

ALOCAÇÃO ÓTIMA DE GERADORES DISTRIBUÍDOS PARA REDUÇÃO DE PERDAS EM SISTEMAS ELÉTRICOS DE DISTRIBUIÇÃO CONSIDERANDO INCERTEZAS DA DEMANDA

RODRIGO VIANA BATISTA*, LEANDRO R. DE ARAUJO*, DÉBORA R. R. PENIDO *

*Laboratório de Sistemas de Potência, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora, Campus Universitário, Plataforma 05, Galpão 03 – Bairro São Pedro – Juiz de Fora – Minas Gerais – Brasil – CEP:36036-900

Emails: rodrigo.viana@engenharia.ufjf.br, leandro.araujo@ufjf.edu.br, debora.rosana@ufjf.edu.br

Abstract: This paper presents an approach for the optimal allocation of distributed generators (DG) in power distribution systems for the total loss reduction using the genetic algorithms technique. In the optimization process, the load demand uncertainties and load scenarios along the day were considered aiming an appropriate representation of the real operation of the distribution systems, which allows a wiser evaluation of the optimal bus to allocate the DG. The proposed approach was performed in the IEEE 13, IEEE 34 and IEEE 123 test systems, presenting inherent characteristics from distribution systems.

Resumo: Este artigo apresenta uma abordagem para alocação ótima de geradores distribuídos (GD) em sistemas de distribuição de energia para a redução total de perdas utilizando a técnica de algoritmos genéticos. No processo de otimização, as incertezas da demanda das cargas e os cenários de carregamento ao longo do dia foram considerados, visando uma representação adequada da operação real dos sistemas de distribuição, o que permite uma avaliação mais criteriosa da barra ideal para alocação de GD. A abordagem proposta foi executada nos sistemas teste IEEE 13, IEEE 34 e IEEE 123, que apresentam características inerentes aos sistemas de distribuição.

Keywords: distributed generators; optimization; genetic algorithms; power distribution systems; loss reduction.

Palavras-chaves: geradores distribuídos; otimização; algoritmos genéticos; sistemas de distribuição de energia elétrica; redução de perdas.

1. INTRODUÇÃO

A reestruturação do setor elétrico ocorrida nos últimos anos, não só no Brasil, como em vários países, tem possibilitado que os sistemas de distribuição de energia elétrica venham sendo submetidos a intensas mudanças relacionadas à inserção de novas tecnologias e também melhores práticas das concessionárias de energia no seu gerenciamento. Neste sentido, tem crescido o interesse pela instalação de geradores distribuídos localmente nas redes de distribuição, se destacando pelo fato de apresentarem diversas vantagens para uma operação mais eficiente e econômica das redes de distribuição, podendo estes serem a partir de fontes renováveis, como energia solar e eólica, ou fontes convencionais, como o gás natural utilizado em microturbinas.

Devido à crise energética que ocorreu no Brasil em 2001, a Agência Nacional de Energia Elétrica (ANEEL) tomou medidas emergenciais incentivando a geração de energia elétrica próxima aos centros de carga (Andrade, 2007), tornando assim a geração distribuída (GD) uma interessante alternativa no que condiz ao aumento da eficiência dos sistemas de distribuição e o aumento da confiabilidade do fornecimento de energia, reduzindo as perdas técnicas e custos com interrupção.

A energia elétrica gerada nas grandes usinas, para chegar aos consumidores finais, é transportada por extensas linhas de transmissão, onde uma parcela dessa energia é perdida. A maior parte dessa energia é perdida em forma de calor, devido ao efeito Joule nas linhas de transmissão e transformadores.

Essas perdas contribuem substancialmente para o aumento dos custos operacionais dos sistemas elétricos.

A operação dos geradores distribuídos nos sistemas de distribuição, reduz de forma significativa as perdas totais nos sistemas elétricos de potência, isto porque ao se gerar a energia elétrica próxima dos consumidores, é possível reduzir o carregamento das linhas de transmissão, de distribuição, e também dos transformadores, permitindo, além da redução de perdas, que sua capacidade de transmissão de energia seja aumentada, postergando os investimentos na expansão dos sistemas de transmissão e distribuição para atender o crescente aumento de cargas nos sistemas. Isso é atrativo do ponto de vista econômico também, pelo fato de que os investimentos e tempo necessários para instalação e entrada em funcionamento de GDs são menores quando comparados para grandes usinas de geração.

Entretanto, a instalação de GDs também pode ocasionar problemas para a operação das redes de distribuição dependendo da sua localização de instalação. Alguns dos impactos negativos são: elevação de tensão, que pode acarretar danos aos equipamentos e aumento das reclamações nas concessionárias; flutuação de tensão, devido à intermitência de fontes como solar e eólica, causando flicker e maior atuação dos reguladores de tensão, aumentando o desgaste destes equipamentos; fluxo reverso de potência, afetando a operação dos reguladores e também do sistema de proteção; aumento de distorções harmônicas, devido aos inversores associados; possibilidade de sobrecarga nos alimentadores.

Neste contexto, é de interesse das concessionárias de energia que a alocação dos geradores distribuídos seja

estratégica e apropriada, para que os benefícios para a operação da rede sejam alcançados respeitando seus limites físicos e operacionais, uma vez que uma alocação não apropriada pode trazer os inconvenientes já citados.

Muitos trabalhos na literatura propõem métodos de otimização para resolução do problema da alocação de GDs de modo a se obter boas soluções para uma determinada função objetivo, podendo ser esta, a redução de custos totais associados à instalação e operação de GDs, violações de tensão, desequilíbrios, perdas, entre outros. Em (Oliveira et al., 2015) é proposta uma metodologia de otimização meta-heurística para alocação otimizada de GDs, baseadas em fontes renováveis, para reduzir os custos totais de investimento e operação, empregando a técnica de algoritmos genéticos. Em (Pisica et al., 2009), é proposto um algoritmo genético para maximizar uma função objetivo que define a relação custo e benefício de uma concessionária de distribuição. Em (Tautiva et al., 2009), também é proposto um algoritmo genético para alocação de GDs de modo a minimizar os custos associados a estas e também as perdas elétricas no sistema. Em (Ismael et al., 2018), é utilizado o método Crow Search Algorithm para otimização da alocação e dimensionamento de GDs. Em (Sookananta et al., 2010), é utilizado o método de otimização meta-heurístico de colônia de formigas para alocação de GDs buscando a minimização das perdas. Em (Prabha et al., 2012), o problema de otimização é resolvido pela técnica de enxame de partículas, buscando a alocação e dimensionamento ótimos de GDs na rede elétrica. Em (Zulpo et al., 2014), busca-se minimizar as perdas elétricas e os desvios de tensão na rede utilizando técnicas de programação linear como método de otimização.

Neste trabalho, é abordado um método para a alocação de geradores trifásicos distribuídos em sistemas elétricos de distribuição, buscando minimizar as perdas ativas totais dos sistemas. O método de otimização é baseado na técnica meta-heurística do algoritmo genético, sendo o principal diferencial desta abordagem, a consideração das possibilidades de aleatoriedade (incertezas) na demanda das cargas e os cenários de carregamento inclusos na resolução do fluxo de potência, viabilizando uma representação mais próxima da operação real dos sistemas de distribuição de energia elétrica.

Assumindo isto, o objetivo deste trabalho é indicar as barras estratégicas para alocação de GDs que proporcionem as menores perdas elétricas nos sistemas analisados, e ainda, avaliar quais as barras ótimas para cada um. Para a solução do problema de otimização é utilizado um programa para inclusão das GDs e cálculo do fluxo de potência trifásico, sendo este acoplado a uma rotina do algoritmo genético.

2. PREMISSAS BÁSICAS

2.1 Geradores Distribuídos

A Resolução Normativa nº 482/2012 da ANEEL estabelece as condições de acesso às instalações de geração distribuída de pequeno porte, podendo estas serem caracterizadas como microgeração, possuindo capacidade instalada de até 75 kW, e minigeração, com capacidade instalada acima de 75 kW e menor ou igual a 5 MW.

Neste trabalho, a potência despachada pelos geradores síncronos pode ser de 50, 100, 150 e 200 kW, todos com fator de potência unitário, conectados somente em barras trifásicas, servindo como fonte de potência ativa para o sistema. A Fig. 1 mostra uma representação de máquina síncrona para geradores distribuídos em sistemas de distribuição.




Fig. 1 – Representação de GD conectada a uma barra de um sistema elétrico.

A implementação das máquinas e a resolução do fluxo de potência para as redes é realizada através do OpenDSS. As máquinas são modeladas com injeção constante de potência ativa para um fator de potência especificado, e assume-se que as potências geradas são equilibradas entre as fases. O programa modela os geradores síncronos como cargas de potência negativa.

2.2 Aleatoriedade da demanda e cenários de carregamento

Na operação real dos sistemas elétricos de distribuição, a demanda das cargas possui um determinado grau de incerteza, devido a erros de medição e também à incessante variação do carregamento em cada barra (Wang et al., 1992)-(Borkowska, 1974), além disso, existem também as condições de carregamento (leve, médio e pesado) das redes ao longo do dia.

Desta forma, torna-se necessária a incorporação da aleatoriedade da demanda e os cenários de carregamento no fluxo de potência para uma análise mais realística dos sistemas de distribuição. Essa aleatoriedade pode ser introduzida ao multiplicar-se as potências das cargas em cada nó dos sistemas por um conjunto de números sorteados de maneira randômica dentro de faixas de valores que representem, além da incerteza da demanda, o cenário de carregamento da rede. O sorteio dos números pode ser implementado através de uma função no Matlab®, assim como o arquivo para definição das potências das cargas em cada simulação, que será incluído no OpenDSS.

3. MÉTODO PROPOSTO PARA A REDUÇÃO DE PERDAS NOS SISTEMAS DE DISTRIBUIÇÃO

O problema abordado neste trabalho pode ser definido como a determinação das barras ótimas para instalação de GDs levando-se em consideração as incertezas na demanda e os níveis de carregamento dos sistemas ao longo do dia, e ainda, respeitando os limites estabelecidos pela ANEEL dos níveis de tensão em cada barra, de maneira que as perdas elétricas totais sejam reduzidas.

3.1 Problema de Otimização

O cálculo das perdas elétricas pode ser expresso, matematicamente, conforme definido em (1).

$$P_{perdas,k} = g_{k,ij}|V_{k,i} - V_{k,j}|^2 \quad (1)$$

O problema de otimização pode ser modelado como a equação definida abaixo:

$$FOB = \min \sum_{k=1}^N P_{perdas,k} \quad (2)$$

Sujeito a

$$V_{min,i} \leq V_i \leq V_{max,i} \quad (3)$$

A equação (2) apresenta a função objetivo sujeita à restrição de tensão expressa em (3) para a avaliação dos parâmetros ótimos escolhidos em cada geração do algoritmo genético. Onde:

- N – Conjunto de elementos pertencentes ao sistema;
- k – Elemento do sistema de distribuição;
- $P_{perdas,k}$ – Perda real em kW correspondente ao elemento k;
- $g_{k,ij}$ – Condutância correspondente ao elemento k;
- $V_{k,i}$ – Módulo da tensão da barra i, de onde sai o elemento k;
- $V_{k,j}$ – Módulo da tensão da barra j, para onde vai o elemento k;

Devido à natureza não linear do problema de otimização para minimização das perdas, técnicas clássicas de otimização, apesar da garantia de uma solução ótima, necessitam que todas as possíveis combinações do espaço de busca de soluções sejam avaliadas, acarretando um alto custo computacional, tornando-as inviáveis para sistemas de energia. À vista disto, técnicas meta-heurísticas são adequadas para resolução do problema, possibilitando uma redução conveniente do espaço de busca, implicando uma investigação mais eficiente de soluções próximas da otimalidade, tornando-as computacionalmente viáveis. Entretanto, métodos meta-heurísticos não apresentam garantia de soluções ótimas. Para este trabalho, optou-se pela técnica do Algoritmo Genético (AG).

3.1 Método Proposto

O problema de otimização é resolvido através de um AG, tendo sua rotina implementada em código no Matlab®. A função objetivo do problema busca minimizar as perdas ativas totais nos sistemas testes com a alocação de GDs já configuradas. A sequência da alocação das máquinas e de suas respectivas potências despacháveis nos sistemas são indicadas pelo AG. Após isso, o fluxo de potência é executado no OpenDSS, a partir do qual são obtidas as perdas totais para as respectivas alocações de GDs fornecidas pelo AG. Essas perdas dependem do estado de operação de cada barra em um determinado momento, variando de acordo com a obtenção das tensões, ângulos e injeção de potência das máquinas em cada instante.

Esta seção se dispõe a mostrar como a metodologia abordada funciona. A Fig. 2 exibe o fluxograma do AG e em seguida é feita a descrição de cada etapa da rotina executada.

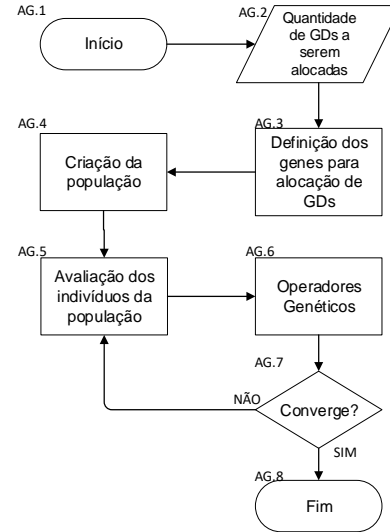


Fig. 2 - Fluxograma do Algoritmo Genético.

AG.1 – Início: Inicialização da rotina do AG no Matlab e definição da quantidade de simulações que se deseja.

AG.2 – Quantidade de GDs a serem alocadas: A quantidade de GDs a serem alocadas nos sistemas é definida como um dado de entrada pelo usuário.

AG.3 – Definição do cromossomo: a estrutura do cromossomo proposto que será utilizado no processo de otimização é constituído das possibilidades de alocações (barras dos sistemas) e das possibilidades de despachos de potências das máquinas, como mostrado no vetor abaixo:

$$x_n = [Barra_1|Pot_1|Barra_2|Pot_2| \dots |Barra_n|Pot_n]$$

Onde n é correspondente ao número de máquinas a serem alocadas e suas respectivas potências a serem despachadas.

O cromossomo apresenta as premissas de interesse para cada indivíduo da população avaliada na função objetivo (FOB), as barras de alocação e potências disponibilizadas. Cada indivíduo oferece uma nova configuração para o sistema, onde cada máquina alocada em barras (somente barras trifásicas) do sistema irá contribuir na injeção de potência ativa de acordo com a potência indicada pelo AG.

AG.4 – Criação da população: Nesta etapa, a população inicial de indivíduos (cromossomos) é criada, sendo que na primeira iteração, os genes são sorteados de maneira aleatória. A partir daí, os operadores genéticos – descritos no **AG.6** – atuam para atualização dos indivíduos.

AG.5 – Avaliação dos indivíduos: Nesta etapa, os indivíduos são decodificados e é realizada a alocação de GDs para execução do fluxo de potência com cada indivíduo candidato. Feito isso, cada indivíduo tem seu desempenho calculado pela FOB apresentada anteriormente em (2) atribuindo uma aptidão através da função fitness do AG. Os indivíduos mais aptos são aqueles que proporcionam os melhores resultados na avaliação, apresentando maiores

probabilidades de permanência para a futura composição de novas populações.

AG.6 – Operações genéticas: Os operadores genéticos empregados são o *crossover* ou *cruzamento*, que gera novos indivíduos a partir da combinação dos genes dos cromossomos “pais”. A *mutação*, que realiza alterações aleatórias nos genes de cada indivíduo da população. E finalmente, o *elitismo*, que garante a permanência dos indivíduos mais aptos para formarem a próxima população.

As operações genéticas são aplicadas de modo a se obter novos e melhores indivíduos a partir dos que já compõem cada população. Desta forma, enquanto não se obtém a convergência para uma solução viável, os operadores são executados para possibilitar diversidade genética e permitir um espaço de busca mais abrangente.

AG.7 – Critério de convergência: Neste módulo, é verificada a convergência do AG. Os critérios utilizados para convergência podem ser o número máximo de iterações ou estagnação da população. Para este trabalho o critério adotado foi o de estagnação da população.

AG.8 – Finalização e apresentação de resultado: Nesta etapa, após atingido o critério de convergência, é apresentado a solução viável indicada pelo AG com alocação e potência ótimas das máquinas e a perda total minimizada.

A seguir, a Fig. 3 exibe o fluxograma para representação e inclusão das incertezas na demanda de cada carga e ainda os cenários de carregamento ao longo do dia. Em seguida é realizada a descrição de cada etapa da rotina implementada, também em Matlab®.

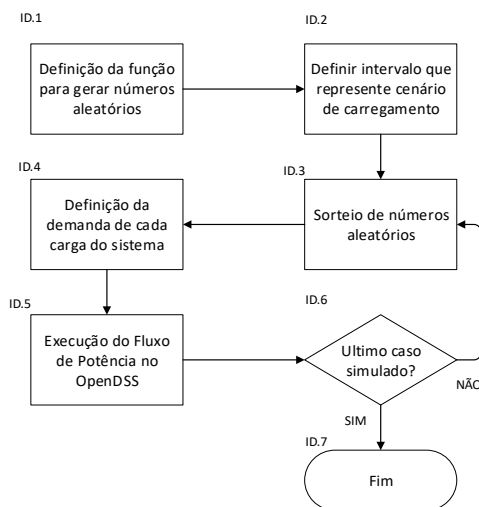


Fig. 3 - Fluxograma para representação das incertezas na demanda.

ID.1 – Função para gerar números aleatórios: Neste trabalho, é utilizada a função *rand* no Matlab para gerar aleatórios entre 0 e 1.

ID.2 – Definição do cenário de carregamento: Nesta etapa, define-se o cenário de carregamento a ser simulado em intervalos entre 0.2 e 1.5. Para o presente trabalho, o intervalo entre 0.2 e 0.5 foi considerado para carregamento leve, o intervalo entre 0.5 e 0.8 para carregamento médio e o intervalo entre 0.8 e 1.0 para carregamento pesado. Foi incluído também um intervalo entre 0.5 e 1.5 abrangendo, além dos carregamentos médio e pesado, as possibilidades de sobrecarga em cargas individuais, definido como cenário de carga aleatória.

ID.3 – Sorteio de números aleatórios: Definido o carregamento desejado, a função *rand* no Matlab é implementada de modo a sortear números aleatórios dentro do intervalo correspondente. Esses números são utilizados para representar, além da incerteza na demanda, o cenário de carregamento a ser simulado e posteriormente definirem as demandas em cada carga para a simulação correspondente.

ID.4 – Definição da demanda: Os números sorteados são multiplicados pelas potências ativa e reativa em cada carga nos sistemas, definindo o carregamento da rede e a aleatoriedade na demanda, que será incorporada ao fluxo de potência.

ID.5 – Execução do fluxo de potência: Nesta etapa, com o cromossomo indicado pelo AG já decodificado, as máquinas alocadas nos respectivos nós e as incertezas incorporadas às demandas, o OpenDSS executa o fluxo de potência.

ID.6 – Verificação de casos simulados: verifica-se se a quantidade de simulações desejadas fora realizada. Se sim, o programa finaliza sua execução, se não, ele retorna à etapa ID.3.

ID.7 – Finalização: ao findar a quantidade de simulações desejadas, é necessário definir o novo cenário de carregamento desejado da rede para que o processo seja reinicializado.

4. RESULTADOS

O método proposto na seção 3. foi testado nos sistemas IEEE 13, IEEE 34 e IEEE 123 barras [11]. As simulações foram executadas em um Intel Core i5, 2,3GHz, 4GB RAM, utilizando sistema operacional Windows 10 Pro, com o Matlab R2015a e o OpenDSS versão 8.1.6.1 (64 bits build). O tempo computacional demandado pelas simulações varia em cada sistema teste.

Para os estudos de casos, o AG foi executado 400 vezes em cada sistema, sendo 100 vezes para cada cenário de carga. Em cada simulação, as cargas podem assumir valores distintos dentro do intervalo que define o cenário de operação da rede, fazendo com que o algoritmo genético, ao final de cada simulação, indique barras diferentes. Devido à natureza estocástica do AG em conjunto com a incorporação das incertezas na demanda das cargas, torna-se necessário uma extensiva quantidade de simulações, favorecendo uma avaliação mais prudente das barras ótimas para alocação de GDs em cada sistema. As barras mais indicadas pelo AG serão selecionadas como as barras ótimas em cada sistema estudado. O programa desenvolvido permite que o usuário defina qualquer quantidade de GDs a serem alocadas. Para as simulações, a quantidade de máquinas alocadas foi definida de modo a permitir maior diversidade de indicação de barras. Em todos os casos estudados a quantidade de GDs é igual a 6.

Para fins de validação do método proposto, serão realizadas simulações em casos com máquinas alocadas nas três barras mais indicadas pelo AG em cada sistema. Também serão realizadas simulações para os casos bases, em que não há instalação de GDs. Os cenários escolhidos para simulação serão os cenários de carga pesada e aleatória, por representarem cenários mais críticos para a operação da rede. Para cada caso (base e de alocação) serão executadas dez simulações e feita a média aritmética dos valores obtidos (devido à consideração da aleatoriedade na demanda das cargas), e então, finalmente, os resultados serão expostos em tabelas para comparação de casos e avaliação do método.

4.1 Estudo de caso – Sistema IEEE 13 barras

A Fig. 4 apresenta o circuito unifilar do sistema IEEE de 13 barras, topologia base do sistema em questão. Este é um pequeno modelo de alimentador com tensão nominal de 4.16 kV para análise em sistemas de distribuição. É caracterizado por possuir linhas aéreas e subterrâneas, um regulador de tensão na subestação, capacitores em derivação, um transformador, carga elevada e desequilibrada.

Nas figuras seguintes, são apresentadas as incidências das barras ótimas indicadas pelo AG. Cada uma das figuras corresponde a um cenário de carregamento. A quantidade de incidências para cada barra pode variar de acordo com o cenário de carregamento.




Fig. 4 – Diagrama unifilar do sistema IEEE de 13 barras.




Fig. 5 – Incidências das barras estratégicas no sistema IEEE 13 Barras (Carga leve).




Fig. 6 – Incidências das barras estratégicas no sistema IEEE 13 Barras (Carga média).




Fig. 7 – Incidências das barras estratégicas no sistema IEEE 13 Barras (Carga pesada).




Fig. 8 – Incidências das barras estratégicas no sistema IEEE 13 Barras (Carga aleatória).

De acordo com os resultados obtidos através das simulações executadas, foi possível definir que as barras mais apropriadas para alocação de GDs no sistema teste analisado são, respectivamente, as barras 675, 671 e 692. Em cada cenário as potências indicadas variam, principalmente para carga leve. Entretanto, considerando os demais cenários, a potência mais indicada e selecionada para cada máquina foi de 200 kW.

Na Tabela 1, observa-se que os casos Alocação 01 (carregamento pesado) e Alocação 02 (carregamento aleatório), que representam a alocação ótima de GDs, em comparação com os casos base 01 (carregamento pesado) e 02 (carregamento aleatório), apresentam uma redução nas perdas totais de 28,87% e 28,43%, respectivamente, validando o método abordado.

TABELA 1 - SISTEMA 13 BARRAS
COMPARAÇÃO DE RESULTADOS

Resultados				
	Caso Base 01	Alocação 01	Caso Base 02	Alocação 02
Perdas (kW)	85.552	60.851	109.045	78.042

4.2 Estudo de caso – Sistema IEEE 34 barras

A Fig. 9 apresenta o circuito unifilar do sistema IEEE de 34 barras. Este sistema é um alimentador real, com tensão

nominal em 24.9 kV e caracterizado por ser longo, levemente carregado, possuir dois reguladores de tensão, um transformador para suprir uma curta seção do alimentador em 4.16 kV, capacitores em derivação e cargas desequilibradas.




Fig. 9 – Diagrama unifilar do sistema IEEE 34 barras.

Na Fig. 10, Fig. 11, Fig. 12 e Fig. 13 são apresentadas as incidências das barras ótimas indicadas no sistema IEEE 34 barras, também considerando a disponibilidade de 6 máquinas para alocação na rede.

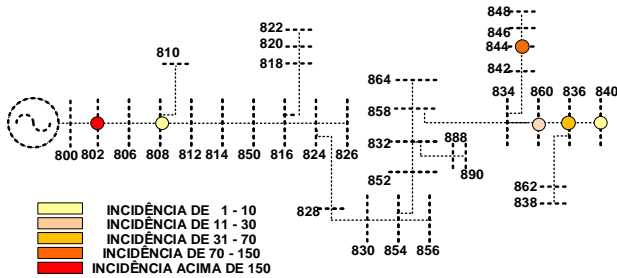


Fig. 10 - Incidências das barras estratégicas no sistema IEEE 34 Barras (Carga leve).

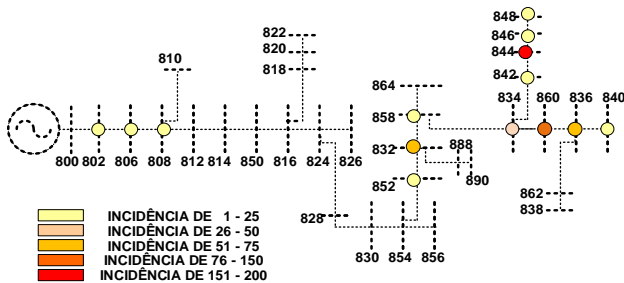


Fig. 11 - Incidências das barras estratégicas no sistema IEEE 34 Barras (Carga média).




Fig. 12 - Incidências das barras estratégicas no sistema IEEE 34 Barras (Carga pesada).

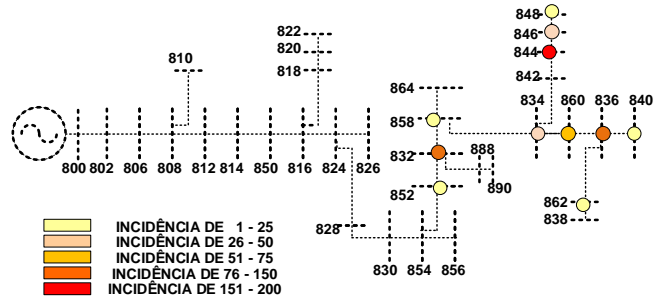


Fig. 13 - Incidências das barras estratégicas no sistema IEEE 34 Barras (Carga aleatória).

Para as simulações neste sistema obteve-se as barras 844, 836, 832 e 860 como ótimas. Novamente, as potências indicadas variam conforme o cenário de carga, porém, considerando todos os cenários, a potência ótima indicada para cada máquina foi de 200 kW.

Os resultados da Tabela 2 mostram, como esperado, uma redução significativa das perdas ativas na rede, sendo de 56,17% para o cenário de carga pesada e de 39,96% para o de carga aleatória.

TABELA 2 - SISTEMA 34 BARRAS
COMPARAÇÃO DE RESULTADOS

Resultados				
	Caso Base 03	Alocação 03	Caso Base 04	Alocação 04
Perdas (kW)	225.78	98.95	290.80	174.57

4.2 Estudo de caso – Sistema IEEE 123 barras

A Fig. 14 mostra o unifilar do sistema IEEE 123 barras, que opera a uma tensão nominal de 4.16 kV, fornecendo problemas relacionados a quedas de tensão que devem ser resolvidos através da instalação de equipamentos e atuação de dispositivos de controle. O sistema é caracterizado por possuir linhas aéreas e subterrâneas, reguladores de tensão, cargas desequilibradas com natureza de potência, impedância e corrente constantes.




Fig. 14 - Diagrama unifilar do sistema IEEE de 123 barras.

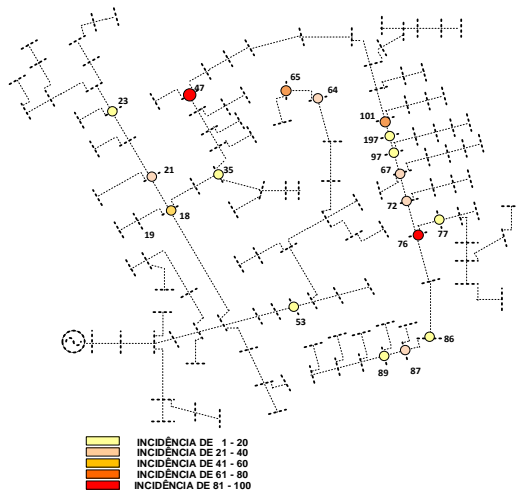


Fig. 15 - Incidências das barras estratégicas no sistema IEEE 123 Barras (Carga leve).

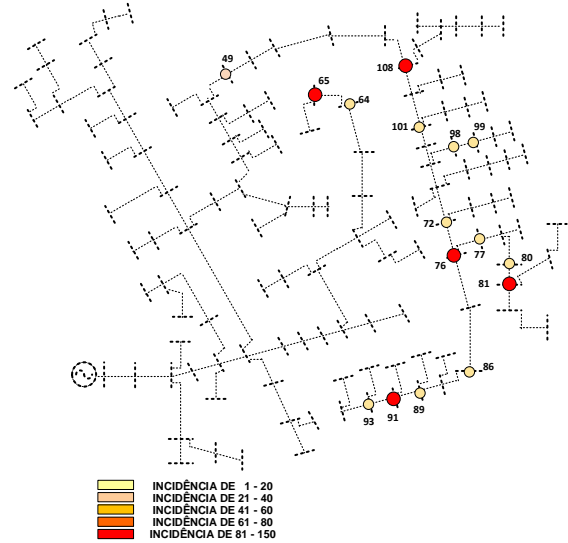


Fig. 18 - Incidências das barras estratégicas no sistema IEEE de 123 barras (Carga aleatória).

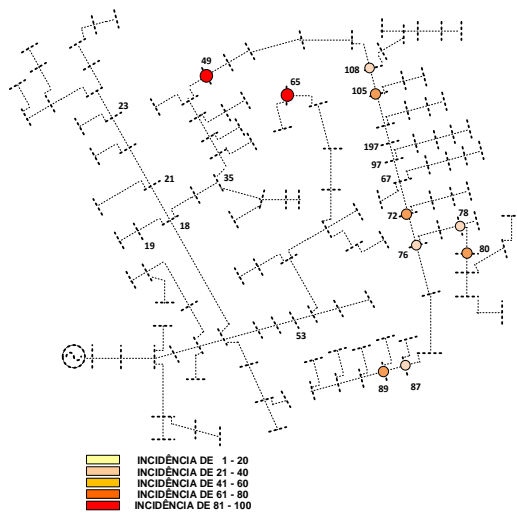


Fig. 16 - Incidências das barras estratégicas no sistema IEEE de 123 barras (carga média).

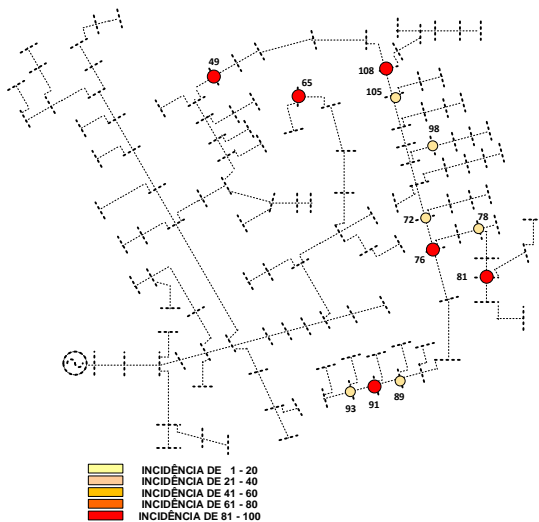


Fig. 17 - Incidências das barras estratégicas no sistema IEEE de 123 barras (Carga pesada).

A Fig. 15, Fig. 16, Fig. 17 e Fig. 18 apresentam as barras indicadas pelo AG e suas incidências para cada condição de carga do sistema.

Para as simulações realizadas no sistema de 123 barras, obteve-se como barras ótimas as barras 65, 76, 49 e 108. Assim como para os demais sistemas estudados, as potências indicadas variam de acordo com o carregamento, sendo no caso do sistema de 123 barras, a maior variedade de indicações acontecendo para o cenário de carga leve. Ainda assim, considerando todos os cenários simulados, a potência ótima indicada e selecionada para cada máquina foi de 200 kW.

Os resultados apresentados na Tabela 3 mostram que para o sistema deste estudo de caso, obteve-se uma redução relevante das perdas ativas totais na rede, sendo para o cenário de carga pesada uma redução de 33,15% e para o de carga aleatória de 35,33%, mais uma vez evidenciando a eficácia do método proposto neste trabalho.

TABELA 3 - SISTEMA 123 BARRAS
COMPARAÇÃO DE RESULTADOS

Resultados				
	Caso Base 05	Alocação 05	Caso Base 06	Alocação 06
Perdas (kW)	76.91	51.41	97.35	62.95

5. CONCLUSÕES

Neste trabalho foi apresentada uma abordagem da alocação ótima de geradores distribuídos em sistemas de distribuição de energia elétrica utilizando-se da técnica de algoritmos genéticos, e no processo de otimização, a consideração das possibilidades de aleatoriedade do carregamento de cada carga, bem como os cenários de carga leve, média e pesada dos sistemas, buscando uma representação

mais próxima da realidade da operação dos sistemas de distribuição. O objetivo da alocação ótima de GDs foi a minimização perdas ativas totais, respeitando as restrições operacionais dos sistemas.

Com este método foi possível obter diversas barras estratégicas para alocação dos geradores, observar quais as barras mais indicadas e mais apropriadas para tal objetivo, e ainda, qual a barra ótima (mais indicada, considerando todos os cenários de carregamento, incluindo sobrecargas) para instalação de GDs. Foi possível também observar a influência dos cenários de carregamento e das incertezas na demanda na indicação das barras ótimas e da potência despachada por cada máquina, mostrando que em cenários com carregamento leve, as potências indicadas variam mais e as indicações das barras para instalação das máquinas acontecem de maneira mais dispersas nos sistemas, e então, conforme o carregamento da rede aumenta, estas se concentram em regiões comuns de cada sistema, mais especificamente ao final dos ramais dos alimentadores. Outra observação foi que algumas barras que antes foram indicadas em alguns cenários de carga não foram indicadas em outros, ou então, foram indicadas com menor incidência.

Os resultados para fins de comparação, avaliação da instalação ótima de GDs e sua contribuição para redução das perdas atestam a eficácia do método abordado com redução significativa de perdas em cada sistema estudado, permitindo a instalação dos geradores de forma eficiente, melhorando o desempenho dos sistemas de distribuição.

AGRADECIMENTOS

Os autores deste trabalho agradecem a CNPq, FAPEMIG, UFJF e Capes pelo apoio e incentivo prestado a esta pesquisa.

REFERÊNCIAS

- Andrade, W. D. S. (2007). Avaliação da confiabilidade de sistemas de distribuição e sub-transmissão considerando geração distribuída. *Rio de Janeiro, Rio de Janeiro, Brasil: Tese de Doutorado, UFRJ*.
- Borkowska, B. (1974). Probabilistic load flow. *IEEE Transactions on Power Apparatus and Systems*, (3), 752-759.
- Chen, C. S., Tsai, C. T., Lin, C. H., Hsieh, W. L., & Ku, T. T. (2011). Loading balance of distribution feeders with loop power controllers considering photovoltaic generation. *IEEE Transactions on Power Systems*, 26(3), 1762-1768.
- Evangelopoulos, V. A., & Georgilakis, P. S. (2013). Optimal distributed generation placement under uncertainties based on point estimate method embedded genetic algorithm. *IET Generation, Transmission & Distribution*, 8(3), 389-400.
- Georgilakis, P. S., & Hatziargyriou, N. D. (2013). Optimal distributed generation placement in power distribution networks: models, methods, and future research. *IEEE Transactions on power systems*, 28(3), 3420-3428.
- IEEE Radial Distribution Test Feeders. Distribution Systems Analysis Subcommittee [online]: <http://sites.ieee.org/pes-testfeeders/>. Accessed: Novembro/2019.
- IEEE Standards Association. (1994). 141-1993. IEEE Recommended Practice for Electric Power Distribution for Industrial Plants (ANSI).
- Ismael, S. M., Aleem, S. H. A., & Abdelaziz, A. Y. (2018). Optimal sizing and placement of distributed generation in Egyptian radial distribution systems using crow search algorithm. In *2018 International Conference on Innovative Trends in Computer Engineering (ITCE)* (pp. 332-337). IEEE.
- Kumawat, M., Gupta, N., Jain, N., & Bansal, R. C. (2017). Optimally allocation of distributed generators in three-phase unbalanced distribution network. *Energy Procedia*, 142, 749-754.
- Oliveira, L. W., Gomes, F. V., Oliveira, E. J., Oliveira, Â. R., Variz, A. M., & Silva, H. A. (2015). Power distribution systems planning with distributed thermal and wind generation. In *2015 IEEE Eindhoven PowerTech* (pp. 1-6). IEEE.
- Oliveira, T. T., Penido, D. R. R., & de Araujo, L. R. (2018). Optimal Allocation and Battery Operations for Voltage Constraint and Loss Reduction. *IEEE Latin America Transactions*, 16(7), 1984-1991.
- Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional. (2010). Módulo 8-qualidade da energia elétrica. *Agência Nacional de Energia Elétrica-ANEEL*.
- Pisica, I., Bulac, C., & Eremia, M. (2009). Optimal distributed generation location and sizing using genetic algorithms. In *2009 15th International Conference on Intelligent System Applications to Power Systems* (pp. 1-6). IEEE.
- Prabha, D. R., Mageshvaran, R., Raghunath, E., & Raghuram, G. (2012). Determining the optimal location and sizing of distributed generation unit using particle swarm optimization algorithm. In *2012 International Conference on Computer Communication and Informatics* (pp. 1-7). IEEE.
- Savio, A., Bignucolo, F., & Caldon, R. (2016). Contribution of MV static distributed generation to voltage unbalance mitigation. In *2016 AEIT International Annual Conference (AEIT)* (pp. 1-6). IEEE.
- Singh, R., Pal, B. C., & Vinter, R. B. (2009). Measurement placement in distribution system state estimation. *IEEE Transactions on Power Systems*, 24(2), 668-675.
- Sookananta, B., Kuanprab, W., & Hanak, S. (2010). Determination of the optimal location and sizing of Distributed Generation using Particle Swarm Optimization. In *ECTI-CON2010: The 2010 ECTI International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology* (pp. 818-822). IEEE.
- Soroudi, A., Ehsan, M., Caire, R., & Hadjsaid, N. (2011). Possibilistic evaluation of distributed generations impacts on distribution networks. *IEEE Transactions on power systems*, 26(4), 2293-2301.
- Tautiva, C., Cadena, A., & Rodriguez, F. (2009). Optimal placement of distributed generation on distribution networks. In *2009 44th International Universities Power Engineering Conference (UPEC)* (pp. 1-5). IEEE.
- Wang, Z., & Alvarado, F. L. (1992). Interval arithmetic in power flow analysis. *IEEE Transactions on Power Systems*, 7(3), 1341-1349.
- Zulpo, R. S., Leborgne, R. C., & Bretas, A. S. (2014). Optimal location and sizing of distributed generation based on power losses and voltage deviation. In *2014 IEEE PES Transmission & Distribution Conference and Exposition-Latin America (PES T&D-LA)* (pp. 1-5). IEEE.