

ALOCAÇÃO ÓTIMA DE MEDIDORES PARA A ESTIMAÇÃO DE ESTADO CONSIDERANDO A RECONFIGURAÇÃO DA REDE DE DISTRIBUIÇÃO

ANTONIO A. M. RAPOSO, ANSELMO B. RODRIGUES, MARIA G. DA SILVA

Av. dos Portugueses, Bacanga, CEP: 65065-545, São Luís, MA, BRASIL

Laboratório de Confiabilidade e Qualidade, Universidade Federal do Maranhão – UFMA

E-mails: antonioamraposo@gmail.com, anselmo.ufma@gmail.com, guia@dee.ufma.br

Abstract— This paper proposes a methodology for optimal allocation of meters oriented to state estimation in distribution networks. The proposed methodology considers that the allocation of meters is carried out simultaneously with the distribution network reconfiguration (DNR) to minimize resistive losses. This formulation of the allocation problem prevents the accuracy of the state estimator (SE) from deteriorating when the grid topology is modified. These objectives were achieved using a fuzzy multi-objective formulation that minimizes resistive losses, the number of meters installed and the risk of violating the accuracy of the estimator. The accuracy of the estimator is calculated analytically without using Monte Carlo Simulation (MCS). The optimization problem described above was solved through the Biased Random-Key Genetic Algorithm (BRKGA). The results demonstrate that the solutions obtained by the proposed method are of good quality and establish an acceptable compromise with the objectives, i. e., topologies with significant reductions in losses and accurate measurement plans with low installation costs.

Keywords— State Estimation, distribution networks, meter placement, reconfiguration, Biased Random-Key Genetic Algorithm, fuzzy sets, multi-objective optimization.

Resumo— Este artigo propõe uma metodologia para alocação ótima de medidores orientada a estimação de estado em redes de distribuição. A metodologia proposta considera que a alocação de medidores é realizada de forma simultânea com a reconfiguração da rede de distribuição (RCRD) para minimizar perdas resistivas. Esta formulação do problema de alocação evita que a precisão do estimador de estado (EE) seja deteriorada quando a topologia da rede elétrica é modificada. Estes objetivos foram alcançados usando-se uma formulação multiobjetivo fuzzy que minimiza as perdas resistivas, o número de medidores instalados e o risco de violar a precisão do estimador. A precisão do estimador é calculada analiticamente sem o uso da simulação Monte Carlo (SMC). O problema de otimização descrito acima foi solucionado através do Algoritmo Genético de Chaves Aleatórias Viciadas (AGCAV). Os resultados demonstram que as soluções obtidas pelo método proposto tem boa qualidade e estabelecem um compromisso aceitável com os objetivos, isto é, topologias com reduções significativas nas perdas e planos de medição precisos e com baixo custo de instalação.

Palavras-chave— Estimação de estado, redes de distribuição, alocação de medidor, reconfiguração, Algoritmo Genético de Chaves Aleatórias Viciadas, conjuntos fuzzy, otimização multiobjetivo.

1 Introdução

O principal pré-requisito para as funções dos modernos centros de operação da distribuição (COD) (por exemplo, gerenciamento de dispositivos de armazenamento de energia, despacho de carga e geração e avaliação do impacto da conexão de veículos elétricos) é a determinação do estado da rede elétrica (módulo e fase das tensões nodais) em tempo real a partir de dispositivos de medição nela instalados. Esta tarefa é realizada por ferramentas de estimação de estado. Entretanto, algumas limitações do COD como (por exemplo, o número limitado de dispositivos de medição instalados na rede e o desconhecimento da demanda em tempo real de cada ponto de carga) diminuem a precisão e reduzem a confiabilidade do EE. Desta forma, deve-se alocar medidores na rede de distribuição para a precisão do EE. Por outro lado, melhorar índices de desempenho da rede de distribuição com o mínimo custo de investimento é o principal objetivo de qualquer concessionária de energia elétrica durante o processo de planejamento da rede elétrica. Uma das alternativas para satisfazer estes objetivos é a reconfiguração da rede de distribuição (RCRD). A RCRD pode ser realizada tanto na

fase de planejamento como na fase de operação e tem como principal vantagem a melhoria dos índices de desempenho sem a necessidade de instalar novos equipamentos na rede. Na fase de operação a RCRD geralmente é realizada na restauração e no controle var/volt (Vaahedi, 2014). Na restauração, a RCRD é usada para isolar uma seção na qual ocorreu a falha e para transferir cargas após uma interrupção do fornecimento de energia. No controle var/volt, a RCRD é aplicada para reduzir as perdas ativas e para melhorar o perfil de tensão. Por outro lado, na fase de planejamento a RCRD é usada para alcançar vários objetivos: maximização de confiabilidade (Brown, 2009); mitigação dos afundamentos de tensão de curta duração (Bahadoorsingh et al., 2007); minimização de perdas resistivas (Tahboub, Pandi and Zeineldin, 2015); controle de nível de curto-circuito (Esmaeili, Esmaeili and Hojabri, 2016) e alocação de geração distribuída (Martins and Borges, 2011). Devido a isso, alguns softwares comerciais incluíram a RCRD como ferramenta para auxiliar o planejamento da rede de distribuição de energia. Por exemplo, o CYME possui uma ferramenta de RCRD que pode ser aplicada no planejamento var/volt para reduzir perdas ativas e minimizar os custos com a instalação de bancos de capacitores (EATON, 2018). Além disso, recomenda-se o uso desta ferramenta para melho-

rar a confiabilidade através da transferência e divisão de circuitos entre alimentadores. De acordo com (Souza, 2017), o problema da RCRD pode ser resolvido por três tipos de algoritmos: heurísticas (Baran and Wu, 1989), meta-heurísticas (Brown, 2009; Bahadoorsingh et al., 2007; Martins and Borges, 2011) e programação matemática (Lavorato et al., 2012). No entanto, os algoritmos meta-heurísticos são preferidos para modelar funções objetivas complexas (como índices de confiabilidade e qualidade de tensão) devido à sua flexibilidade e fácil implementação (Brown, 2009; Bahadoorsingh et al., 2007; Martins and Borges, 2011).

A precisão de um plano de medição para o EE pode ser significativamente comprometida caso ocorra uma mudança na configuração da rede ou os custos com a instalação de medidores podem ser reduzidos caso a precisão se mantenha em níveis aceitáveis após a alteração topológica. Desta forma, os problemas de RCRD e alocação de medidores são correlacionados e, portanto, devem ser tratados concomitantemente. Um crescente interesse em torno do problema de alocar medidores simultaneamente à reconfiguração tem motivado diversas pesquisas sobre este tema. Dentre os trabalhos correlatos, (Abdelsalam et al., 2014) analisaram o impacto da RCRD na alocação de unidades de medição fasorial (PMUs – *Phasor Measurement Units*). A desvantagem da técnica proposta está na abordagem unilateral do problema. Isto é, o problema de alocar PMUs e reconfigurar a rede não é resolvido de forma simultânea em uma modelagem multiobjetivo. Ao invés disso, algumas poucas topologias foram escolhidas para alocação das PMUs. Adicionalmente, a precisão do estimador é desconsiderada.

(Damavandi, Krishnamurthy and Marti, 2015) propuseram uma metodologia para alocação de medidores de magnitude de tensão e PMUs que é robusta para diversas configurações da rede de distribuição. Embora os autores tenham considerado a precisão do EE, a topologia da rede não é otimizada para melhorar índices de desempenho tais como as perdas resistivas.

(Wang, Zhang and Liu, 2018) introduziram um método de alocação robusta baseado em técnicas de saturação da medição e em um algoritmo heurístico. Os resultados obtidos mostram que a técnica proposta é computacionalmente eficiente para garantir a precisão do EE. Entretanto, os autores não consideraram o efeito da correlação entre medições de potência e a avaliação da acurácia do EE é realizada através da Simulação Monte Carlo (SMC) que aumenta o custo computacional da técnica proposta.

(Liu et al., 2014) apresentaram um método para alocar medidores em redes de distribuição com a incerteza na potência de saída da geração distribuída. A técnica proposta incorpora PMUs e medidores inteligentes na estimação de estado da rede e é estendida para múltiplas configurações da rede. Porém, poucas topologias foram escolhidas para alocação

dos medidores inteligentes e das PMUs. Além disso, não foi considerado o efeito da correlação entre medições de potência e a avaliação da precisão do EE é realizada através da SMC.

(Muscas et al., 2006) desenvolveram uma metodologia para alocação de medidores multicanais considerando a natureza estocástica da demanda, bem como as incertezas associadas com os erros de medição. Assim como nos trabalhos anteriores, poucas topologias foram escolhidas para alocação dos medidores. Embora, a precisão do estimador seja considerada, a solução desacoplada da reconfiguração e da alocação não assegura que a observabilidade e a precisão do estimador sejam adequadas para uma dada configuração da rede.

A partir da revisão bibliográfica, nota-se que, com relação à topologia, as metodologias existentes apresentam uma alocação robusta somente para um número limitado de configurações. Ou seja, os medidores são alocados para assegurar a precisão do EE para um conjunto específico de configurações da rede elétrica. Neste contexto, pode ser necessário instalar medidores adicionais para restaurar a precisão do EE após a RCRD ou reduzir o custo com a aquisição de medidores caso a precisão do estimador seja aceitável. Adicionalmente, o uso da SMC aumenta o custo computacional da avaliação da precisão do estimador na alocação de medidores. Desta forma, o principal objetivo deste artigo é propor uma metodologia para alocação de medidores considerando medições correlacionadas simultaneamente à RCRD. Este problema de otimização multiobjetivo foi solucionado usando o AGCAV. O AGCAV busca minimizar as perdas ativas da rede de distribuição sem sacrificar a precisão do EE concomitantemente à redução de custos de instalação de medidores. Estes objetivos são combinados em uma única função objetivo usando-se a técnica de conjuntos fuzzy. Os resultados dos testes em uma rede de distribuição com 69 barras demonstraram que a combinação do AGCAV com os conjuntos fuzzy produziu soluções de alta qualidade, ou seja, planos de medição com baixo custo de instalação de medidores e topologias com reduções significativas nas perdas.

2 Reconfiguração da Rede de Distribuição

Geralmente, quando o problema de reconfiguração é mono-objetivo, busca-se minimizar as perdas ativas do sistema. Além disso, podem ser citados como benefícios ou objetivos da RCRD o balanceamento de carga, a melhoria no perfil de tensão, o aumento da margem de estabilidade de tensão e da confiabilidade da rede, bem como a melhoria na qualidade da energia fornecida aos consumidores (Brown, 2009).

Neste artigo, a RCRD é realizada considerando-se uma demanda fixa e tem como objetivo minimizar

as perdas ativas atendendo às restrições operacionais segundo (1)-(4).

$$\min P^{loss} = F_1(X) = \sum_{b=1}^{NR} X_b \times R_b \times I_b^2 \quad (1)$$

sujeito a:

$$V_{\min} \leq V_k \leq V_{\max} \quad \forall k = 1, \dots, NB \quad (2)$$

$$I_b \leq I_{\max} \quad \forall b = 1, \dots, NR \quad (3)$$

$$\sum_{b=1}^{NR} X_b = NB - 1 \quad (4)$$

Onde: X é o vetor de variáveis de decisão. A dimensão de X é igual ao número de ramos da rede (NR) com seus elementos dados por: $X_b = 1$ ($X_b = 0$) se o ramo b está conectado à rede (se não está conectado à rede); I_b é a magnitude da corrente do b -ésimo ramo; P^{loss} é a função objetivo correspondente às perdas ativas, em kW, calculada para uma dada configuração da rede; V_{\min} e V_{\max} são as restrições mínima e máxima de tensão na k -ésima barra da rede, respectivamente; NB é o número de barras da rede; I_b^{\max} é a máxima corrente, em A, que pode circular no b -ésimo ramo.

3 Formulação Matemática do Problema de Alocação de Medidores

3.1 Técnica Analítica para Calcular Índices de Precisão do EE

O custo computacional para avaliar índices de precisão no problema de alocação de medidores pode ser significativamente reduzido substituindo-se a SMC por uma técnica analítica. A estimação analítica de índices de precisão consiste em obter as distribuições de probabilidade associadas com as variáveis de estado. O primeiro passo para se ter estas distribuições é obter uma relação de sensibilidade linear entre o vetor de variáveis de estado estimadas (\hat{x}) e o vetor de erro de medições (e_z). Esta relação é gerada a partir das condições de optimalidade de primeira ordem da função objetivo do problema de EE, definida em (5), e da expansão de Taylor de primeira ordem de $h(\hat{x})$ em torno do vetor de estado verdadeiro (x^{true}) (Monticelli, 1999).

$$J(x) = \frac{1}{2} [z - h(x)]^T W_z [z - h(x)] \quad (5)$$

Onde: z é o vetor de medições; $h(x)$ é o vetor de equações não-lineares que relacionam as medições e variáveis de estado e W_z é a inversa da matriz de covariância associada às medições.

Consequentemente, tem-se a seguinte relação linear entre \hat{x} e e_z (Abur and Gómez-Expósito, 2004):

$$\hat{x} = x^{true} + A \cdot e_z \quad (6)$$

Onde: $A = [H(x^{true})^T W_z H(x^{true})]^{-1} H(x^{true}) W_z$ e $H(x^{true})$ é a matriz Jacobiana associada com o vetor $h(x^{true})$, isto é, $H(x^{true}) = \nabla h(x^{true})$.

A equação (6) mostra que a distribuição de probabilidade do estimador \hat{x} pode ser obtida através de uma transformação linear das variáveis aleatórias associadas com os erros nas medições. Este procedimento também pode ser aplicado quando há correlação nos erros das medições (Abur and Gómez-Expósito, 2004). Finalmente, pode-se calcular índices de precisão para o EE baseado nas distribuições de probabilidade do vetor de estado estimado.

Um dos objetivos principais do problema de alocação de medidores em redes de distribuição é aumentar a precisão do EE. Uma das formas de se avaliar essa precisão é através do risco dos erros entre os valores estimados e verdadeiros das variáveis de estado violarem limites especificados (Raposo, Rodrigues and Da Silva, 2017). O risco de violar valores especificados para o erro relativo entre os valores verdadeiros e estimados das variáveis de estado pode ser definido como:

$$R_k = \Pr \left\{ \left| \frac{\hat{V}_k - V_k^{true}}{V_k^{true}} \right| \geq \varepsilon_V, \left| \frac{\hat{\theta}_k - \theta_k^{true}}{\theta_k^{true}} \right| \geq \varepsilon_\theta \right\} \quad (7)$$

Onde: R_k é o risco de violação na k -ésima barra; $k \in \Omega_B^*$; Ω_B^* é o conjunto de barras do sistema excluindo-se a barra slack; $\Pr\{x \geq c_1, y \geq c_2\}$ indica a probabilidade das variáveis aleatórias x e y serem maiores ou iguais a c_1 e c_2 , respectivamente; V_k^{true} e θ_k^{true} são os valores verdadeiros do módulo e ângulo da tensão na k -ésima barra, respectivamente; \hat{V}_k e $\hat{\theta}_k$ são os valores estimados do módulo e ângulo da tensão na k -ésima barra, respectivamente e ε_V e ε_θ são os valores especificados para o erro relativo de magnitude e fase da tensão, respectivamente.

3.2 Alocação de Medidores para Maximizar a Precisão do EE

Com o objetivo de aumentar a precisão do EE, define-se a função objetivo associada com a minimização do risco máximo de violar os erros relativos de acordo com:

$$\min R^{\max} = F_2(Y) = 100 \times \max \{R_k(Y)\} \quad (8)$$

sujeito a:

$$R^{\max} \leq \bar{R} \quad (9)$$

Onde: $k \in \Omega_B^*$, \bar{R} é o valor máximo tolerável para o risco de violar os limites referentes aos erros relativos e R^{\max} é o máximo risco nodal associado a um plano de medição representado pelo vetor de variáveis de decisão Y . A dimensão de Y é igual a NB com seus elementos dados por: $Y_k = 1$ ($Y_k = 0$) se existe (se não existe) um medidor instalado na barra k .

A minimização de (8) garante que os medidores serão alocados até que o risco de violar os limites de erro relativo esteja abaixo de um limiar estabelecido. Contudo, o número de medidores exigido para obter um nível de precisão especificado pode se tornar elevado. Devido a isto, as concessionárias consideram os custos de instalação dos medidores no planejamento orientado a precisão do EE.

Em geral, as medições são obtidas através de um medidor multifuncional que coleta os sinais analógicos oriundos de um conjunto de transformadores de corrente e potencial. Estes sinais são processados e transmitidos posteriormente ao COD (Singh, Pal and Vinter, 2009; Muscas et al., 2009). Neste artigo, considera-se que um medidor instalado em uma barra da rede de distribuição é capaz de medir a magnitude de tensão e os fluxos de potência ativa e reativa dos ramos conectados a esta barra.

A partir destas considerações, o segundo objetivo do problema de alocação de medidores é garantir que (8) seja satisfeita com o mínimo número de medidores multifuncionais. Assim, a função objetivo associada com os custos de equipamentos de medição é dada por:

$$\min N^{\text{meter}} = F_3(Y) = \sum_{k=1}^{NB} Y_k \quad (10)$$

Onde, N^{meter} é a função objetivo correspondente ao número de medidores multifuncionais, calculada para um dado plano de medição representado pelo vetor de variáveis de decisão Y .

Na solução do problema de alocação de medidores, as medições de tensão e fluxo na subestação foram consideradas como medições reais e as cargas foram modeladas como pseudo-medições. O valor médio (μ_{med}) para estas medições é obtido a partir de um fluxo de carga. Desta forma, para um dado percentual do máximo erro (ε_{μ}^{\max}) sobre a média μ_{med} , o desvio padrão para uma medição é dado por (Raposo, Rodrigues and Da Silva, 2017):

$$\sigma_{\text{med}} = \frac{\mu_{\text{med}} \times \varepsilon_{\mu}^{\max}}{3 \times 100} \quad (11)$$

4 Formulação Multiobjetivo Fuzzy para o Problema de Alocação de Medidores com RCRD

Muitos problemas do mundo real apresentam uma grande quantidade de objetivos a serem otimizados que são, em sua grande maioria, conflitantes entre si. Ou seja, é impossível melhorar algum objetivo sem deteriorar algum outro. Estes problemas são conhecidos como Problemas de Otimização Multiobjetivo (POMs).

A teoria fuzzy é um dos métodos que podem ser empregados para resolver POMs. Neste artigo, um sistema fuzzy é utilizado para obter uma solução que satisfaça as funções objetivo (1), (8) e (10). Entretanto, como foi mencionado anteriormente, (1), (8) e (10) possuem dimensões e unidades distintas. Devido a isto, foi desenvolvido um sistema fuzzy para combinar as metas da RCRD e da alocação de medidores em uma função objetivo através da definição de funções de pertinência fuzzy.

A função de pertinência indica o grau de satisfação de cada função objetivo que compõe o POM. Ela consiste em um intervalo contendo valores mínimo e máximo, juntamente com uma função contínua monotônica para os diferentes objetivos (Esmaili, Esmaili and Hojabri, 2016; Gupta et al., 2010). As funções de pertinência para cada objetivo otimizado neste artigo são descritas a seguir.

4.1 Função de Pertinência para a Redução nas Perdas (μP)

A proposta para esta função de pertinência é reduzir as perdas ativas na rede de distribuição de acordo com (12).

$$\mu P = e^{-\frac{[F_1(X) - P_0^{\text{loss}}]}{P_0^{\text{loss}}}} \quad (12)$$

Onde, P_0^{loss} corresponde às perdas ótimas da rede elétrica. Ou seja, as perdas obtidas com a RCRD sem considerar a precisão do EE. A partir de (12), nota-se que a medida que $F_1(X) \rightarrow P_0^{\text{loss}}$, tem-se $\mu P \rightarrow 1$.

4.2 Função de Pertinência para a Precisão do EE (μR)

O objetivo desta função de pertinência é melhorar a precisão de um plano de medição conforme:

$$\mu R = \frac{100 - F_2(Y)}{100} \quad (13)$$

Como os valores mínimo e máximo que $F_2(Y)$ pode assumir são 0% e 100%, então $0 \leq \mu R \leq 1$. Desta forma, quanto mais preciso for o plano de medição, mais próximo da unidade μR se aproximará.

4.3 Função de Pertinência para o Número de Medidores em um Plano de Medição (μN)

A proposta desta função de pertinência é reduzir o número de medidores como segue:

$$\mu N = \begin{cases} 0, & \text{se } F_3(Y) \geq N_{\text{sup}}^{\text{meter}} \\ 1, & \text{se } F_3(Y) < N_{\text{inf}}^{\text{meter}} \\ \frac{N_{\text{sup}}^{\text{meter}} - F_3(Y)}{N_{\text{sup}}^{\text{meter}} - N_{\text{inf}}^{\text{meter}}}, & \text{caso contrário} \end{cases} \quad (14)$$

Onde: $N_{\text{inf}}^{\text{meter}}$ e $N_{\text{sup}}^{\text{meter}}$ corresponde ao inteiro mais próximo de 5% (95%) de NB , respectivamente. A partir de (14), nota-se que quando $F_3(Y) \rightarrow N_{\text{inf}}^{\text{meter}}$, μN se aproximará da unidade.

4.4 Grau de Satisfação Fuzzy do POM (μ_{POM})

Na teoria de conjuntos fuzzy, os objetivos que formam o POM podem ser alcançados de forma simultânea definindo-se o grau de satisfação fuzzy do POM através da aplicação de operadores nos objetivos individualizados, tais como: *max-min*, *máxima soma ponderada*, *máximo produto* ou *máxima média geométrica* (Gupta et al., 2010). Neste artigo, a obtenção do grau de satisfação fuzzy do POM, μ_{POM} , se baseia no operador de máxima média geométrica definido em (15).

$$\mu_{POM} = \left(\prod_{i \in \Omega_F} \mu_i \right)^{1/|\Omega_F|} \quad (15)$$

Onde: Ω_F é o conjunto de funções de pertinência; $|\Omega_F|$ é a cardinalidade de Ω_F e μ_i é a i -ésima função de pertinência. No modelo proposto neste artigo, tem-se que: $\Omega_F = \{\mu P, \mu R, \mu N\}$ e $|\Omega_F| = 3$.

O processo de reconfiguração simultaneamente à alocação de medidores busca minimizar as perdas ativas da rede de distribuição sem sacrificar a precisão do EE concomitantemente à redução de custos de instalação de medidores. A partir de (15), estas metas podem ser alcançadas através da solução do seguinte problema de otimização mono-objetivo:

$$\max \mu_{POM} = F_4(X, Y) = \sqrt[3]{\mu P \times \mu R \times \mu N} \quad (16)$$

sujeito a: Restrições (2), (3), (4) e (9).

A topologia da rede e plano de medição com máximo μ_{POM} representará a melhor solução para o problema de RCRD com alocação de medidores para melhorar a precisão do EE.

5 Formulação do Problema via AGCAV

A técnica proposta para maximizar (16) se baseia no AGCAV (Gonçalves and Resende, 2011). O AGCAV é uma meta-heurística evolutiva para problemas de otimização combinatória, cujas soluções são representadas por um vetor de n chaves aleatórias, onde uma chave aleatória é um número real, gerado aleatoriamente, no intervalo contínuo $[0,1)$. Um decodificador mapeia este vetor em uma solução do problema de otimização e calcula o custo desta solução. A população do AGCAV é composta de P vetores de chaves aleatórias. A cada geração, os vetores são particionados em um pequeno conjunto com os melhores indivíduos, chamado de conjunto elite (\mathcal{E}), e o restante é alocado em um conjunto denominado não-elite ($\bar{\mathcal{E}}$). Todos os elementos de \mathcal{E} são copiados sem alteração para a população da próxima geração. Um número pequeno de vetores de chaves aleatórias sofre mutação e também são adicionados à população da próxima geração. O restante da população da próxima geração é composto de soluções geradas pela combinação uniforme de pares de soluções, na qual uma solução é elite e a outra não-elite (Gonçalves and Resende, 2011).

Um cromossomo C_i e uma solução (X_i, Y_i) no AGCAV são definidos como sendo $C_i = [c_{i1}, \dots, c_{iD}]$ e $(X_i, Y_i) = [x_{i1}, \dots, x_{iNR}, y_{i1}, \dots, y_{iNB}]$, respectivamente. Em que $D = NR + NB$ é a dimensão do espaço de busca. É importante mencionar que é necessário desenvolver operadores especiais (crossover, mutação e decodificação) para o AGCAV para evitar a violação da restrição de radicalidade (4).

A decodificação de uma solução no AGCAV pode ser dividida em duas partes: uma para a RCRD e outra para alocação de medidores.

Para o processo de reconfiguração, um ramo j de um cromossomo i está conectado à rede se $c_{ij} = P_{CR}$ para $j = 1, \dots, NR$, onde: $P_{CR} = (NR - NB + 1) / NR$ é a probabilidade de conectividade de um ramo da rede de distribuição. Se $c_{ij} < P_{CR}$, então este ramo encontra-se desconectado. Dessa forma, se $c_{ij} \geq P_{CR}$, então $x_{ij} \leftarrow 1$. Caso contrário, $x_{ij} \leftarrow 0$.

Para o processo de alocação de medidores, uma barra j de um cromossomo i contém um medidor se $c_{ij} \geq P_{EM}$ para $j = NR + 1, \dots, D$, onde: $P_{EM} = 0,5$ é a probabilidade de existir um medidor em uma barra da rede de distribuição. Se $c_{ij} < P_{EM}$, então não há medidor instalado nesta barra. Dessa forma, se $c_{ij} \geq P_{EM}$, então $y_{ij} \leftarrow 1$. Caso contrário, $y_{ij} \leftarrow 0$.

Para as operações de mutação e crossover, a técnica proposta para gerar novas configurações radiais baseia-se nos algoritmos de mutação e crossover propostos em (Raidl, 2000).

O processo de reinicialização também pode ser incluído na estrutura do AGCAV (Gonçalves and Resende, 2011). Nesta fase, o AGCAV é reiniciali-

zado a cada 50 gerações. O pseudocódigo do AGCAV usado para solucionar (16) é ilustrado na Fig. 1.

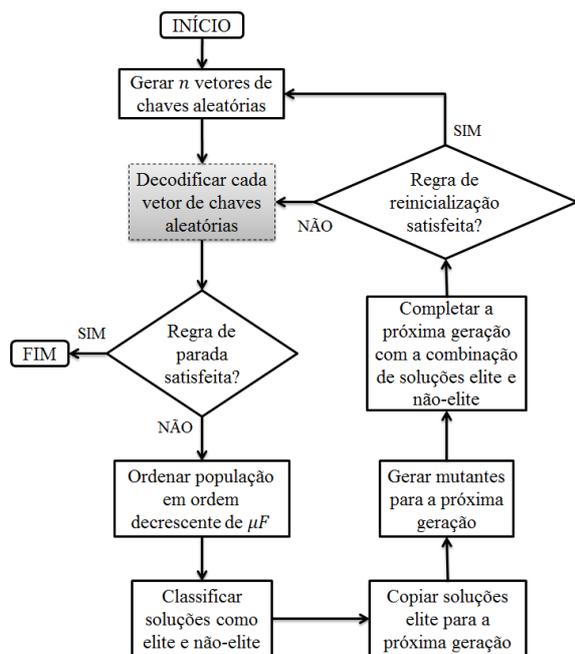


Figura 1. Fluxograma do AGCAV aplicado ao POM definido em (16)

6 Resultados

6.1 Características do Sistema Teste

O algoritmo proposto foi testado no sistema de 69 barras (Savier and Das, 2007) (S69). O S69 contém 73 ramos, tensão nominal de 12,66 kV, tem 3.8019,00 kW e 2.6941,00 kVAr de potência instalada ativa e reativa, respectivamente. Há 5 chaves abertas na sua configuração inicial, localizadas nos ramos 11/43, 13/21, 15/46, 27/65 e 50/59, resultando em perdas de 224,9259 kW.

As simulações no S69 foram realizadas considerando que: a barra da subestação, barra #1, é a barra de referência; os erros relativos especificados de tensão e ângulo são, respectivamente, $\varepsilon_v \leq 1\%$ e $\varepsilon_\theta \leq 5\%$; o valor máximo do risco de violação para os erros relativos nas tensões (\bar{R}) é 5%; os limites de tensão são $V_{\min} = 0,9$ pu e $V_{\max} = 1,05$ pu; considerou-se um erro máximo de 1% associado às medições reais e de 50% associado às pseudo-medições e assumiu-se que o coeficiente de correlação entre medições de potência ativa e reativa é igual a 0,95.

O AGCAV usado para avaliar (16) tem os seguintes parâmetros: tamanho da população $p_t = 60$; tamanho da população elite $p_e = 0,2p_t$; tamanho da população mutante $p_m = 0,2p_t$; taxa de mutação de 50%, e; número máximo de gerações igual a 1000.

A análise do algoritmo proposto para o problema de RCRD e alocação de medidores considerou quatro casos de estudo:

Caso #0 (caso base): há medidores instalados apenas na subestação e a configuração inicial é adotada, ou seja, a RCRD não é realizada.

Caso #1: o AGCAV é aplicado ao caso #0 com o objetivo de minimizar $F_2(Y)$ e $F_3(Y)$. Esse caso é equivalente a alocação convencional de medidores.

Caso #2: o AGCAV busca minimizar apenas $F_1(X)$ com o plano de medição obtido no caso #1, ou seja, o caso #2 corresponde a tradicional RCRD.

Caso #3: o AGCAV é aplicado ao caso #0 com o objetivo de minimizar (16), isto é, este caso reduz simultaneamente as perdas e número de medidores enquanto melhora a precisão do EE.

6.2 Resultados dos Casos de Estudos

Os riscos nodais referentes aos casos de estudo #0, #2 e #3 são ilustrados através de mapas de calor, cujos gradientes das cores são definidos na Fig. 2. De acordo com esta figura, as cores mais quentes, como amarelo e vermelho, indicam maior violação do risco nodal. Por outro lado, cores mais frias, como azul, sugerem que os riscos nodais são menores ou iguais a \bar{R} . As barras do S69 ilustradas nos mapas de calor são divididas em três tipos: subestação – definida por um retângulo azul; barras de carga – definidas por um círculo magenta, e; barras de injeção nula – definidas por um círculo bege.

Para o caso #0, as barras #32 e #33 apresentam os maiores riscos nodais com $R^{\max} = 91,2639\%$. Os riscos nodais para o caso #0 são mostrados na Fig. 3. A partir da Fig. 3, pode ser notado que com apenas um medidor instalado na barra #1 e com a configuração inicial, o S69 apresenta riscos nodais superiores a 5% em praticamente todo o sistema, exceto nas barras mais próximas à subestação, ilustradas em azul. Essa quantidade corresponde a apenas 12% do total de barras do sistema.

Para o caso #1, o AGCAV obteve um plano de medição capaz de atender um risco com nível de significância \bar{R} , utilizando 6 medidores instalados nas barras #1, #4, #12, #28, #33 e #41, com $R^{\max} = 0,9\%$ na barra #66. A solução obtida no caso #1 corresponde a $\mu R = 0,9910$, $\mu N = 0,9524$ e $\mu_{POM} = \mu R \times \mu N = 0,9715$. A partir do plano de medição obtido no caso #1 foi realizada a reconfiguração no S69 (caso #2). As menores perdas obtidas são $P^{\text{loss}} = 98,2229$ kW (com a abertura dos ramos 11/43, 13/21, 14/15, 57/58 e 61/62) e $P^{\text{loss}} = 98,4141$ kW (com a abertura dos ramos 11/43, 13/21, 12/13, 57/58 e 61/62). Para $P^{\text{loss}} = 98,2229$ kW, obteve-se $R^{\max} = 99,5046\%$ que é muito maior do que o obtido no caso #1, como pode ser visto no gráfico superior da Fig. 3. Por outro lado, para $P^{\text{loss}} = 98,4141$ kW, obteve-

se $R^{\max} = 97,1215\%$ que está muito acima do limite de risco $\bar{R} = 5\%$, mesmo com 6 medidores presentes no S69, como pode ser visto na Fig. 4.

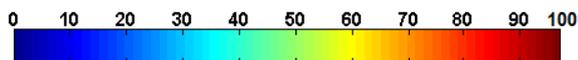


Figura 2. Margem de risco para os casos de estudo.

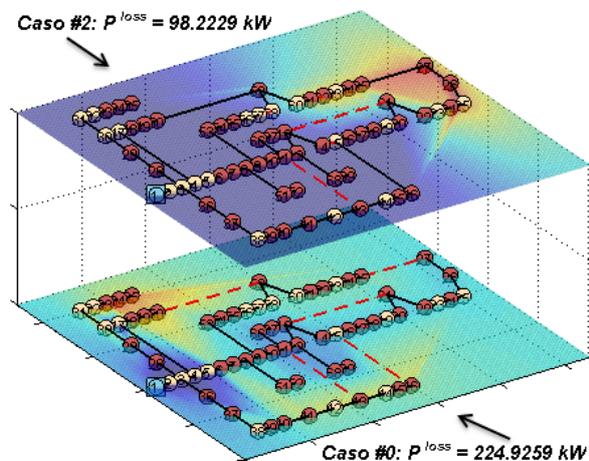


Figura 3. Riscos nodais para os casos #0 e #2

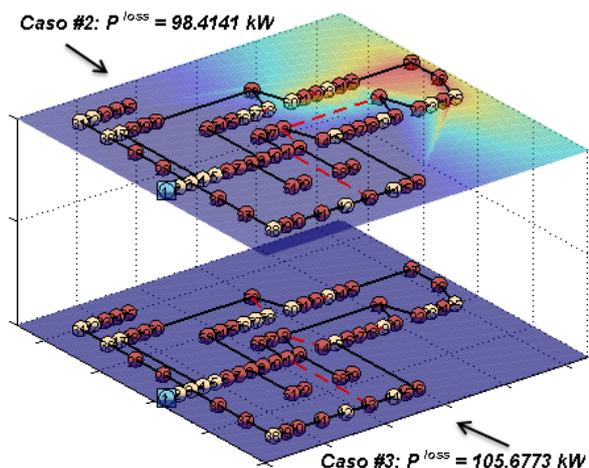


Figura 4. Riscos nodais para os casos #2 e #3

Com o objetivo de mitigar os problemas ocorridos no caso #2, o AGCAV foi aplicado ao caso #0. O algoritmo obteve um plano de medição capaz de atender um risco com nível de significância \bar{R} , utilizando 8 medidores instalados nas barras #1, #12, #23, #28, #33, #43, #48 e #61, com $R^{\max} = 0,4952\%$ na barra #35 e $P^{\text{loss}} = 105,6773 \text{ kW}$ (com a abertura dos ramos 11/43, 13/14, 18/19, 58/59 e 62/63). A solução obtida no caso #3 corresponde a $\mu P = 0,9269$, $\mu R = 0,9950$, $\mu N = 0,9206$ e $\mu_{POM} = \mu P \times \mu R \times \mu N = 0,9469$. Os riscos nodais para o caso #3 são mostrados na Fig. 4. Para o caso #3, o AGCAV melhorou em cerca de 99,4574% o valor de R^{\max} obtido a partir do caso #0. Por outro lado, as perdas ativas ótimas correspondem a uma redução em

torno de 53.0168% do valor das perdas para o caso #0. A característica de convergência do caso #3 é mostrada na Fig. 5. Assim como no caso #1, o AGCAV atinge o estado de convergência após 700 gerações.

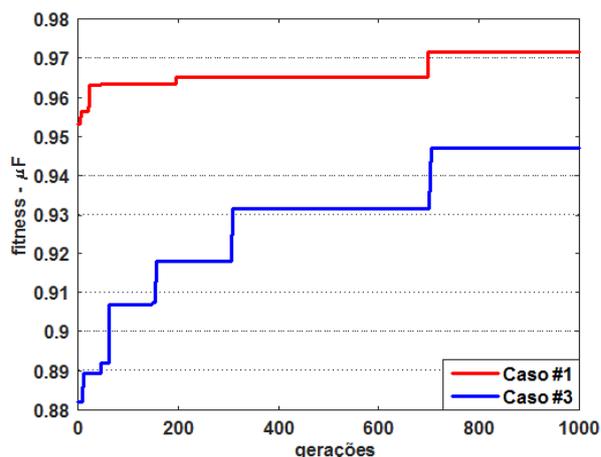


Figura 5. Curvas de convergência dos casos #1 e #3

7 Conclusão

Este artigo apresentou uma metodologia para a solução conjunta dos problemas de alocação de medidores e RCRD. A alocação de medidores tem como metas a maximização da precisão do EE e a minimização dos custos de instalação dos medidores. A reconfiguração é realizada visando à minimização das perdas ativas na rede de distribuição. A otimização concorrente destes objetivos foi realizada usando-se uma versão multi-objetivo do AGCAV. A versão multi-objetivo do AGCAV se baseia na definição de funções de pertinência fuzzy para cada meta e na combinação destas funções através da média geométrica para converter o problema multi-objetivo original em um problema mono-objetivo. Esta formulação dos problemas de alocação de medidores e reconfiguração evita que a precisão do EE seja deteriorada quando a topologia da rede elétrica é modificada.

Os resultados em uma rede de distribuição de 69 barras demonstraram que a precisão do EE é reduzida após a RCRD. Consequentemente, a reconfiguração deixa de ser uma alternativa de projeto de custo nulo (exige somente a abertura e fechamento de chaves), pois será necessário instalar medidores adicionais para restaurar a precisão do EE após a reconfiguração. Por outro lado, o modelo de otimização multi-objetivo proposto neste artigo, baseado no AGCAV fuzzy, obteve soluções de alta qualidade com relação à redução nas perdas sem reduzir a precisão do EE e com um pequeno número de medidores (baixo custo).

Agradecimentos

Os autores agradecem o suporte financeiro da CAPES.

Referências Bibliográficas

- Abdelsalam, H. A., Abdelaziz, A. Y., Osama, R. A. and Salem, R. H. (2014). Impact of distribution system reconfiguration on optimal placement of phasor measurement units. In: *Power Systems Conference*. Clemson: Clemson University, pp. 1-6.
- Abur, A. and Gómez-Expósito, A. (2004). *Power System State Estimation: Theory and Implementation*. New York: Marcel Dekker.
- Bahadoorsingh, S., Milanovic, J. V., Zhang, Y., Gupta, C. P. and Dragovic, J. (2007). Minimization of voltage sag costs by optimal reconfiguration of distribution network using genetic algorithms. *IEEE Transactions on Power Delivery*, 22(4), pp. 2271-2278.
- Baran, M. E. and Wu, F. F. (1989). Network reconfiguration in distribution systems. *IEEE Transactions on Power Delivery*, 4(2), pp. 1401-1407.
- Brown, R. E. (2009). *Electric Power Distribution Reliability*. 2nd ed. Marcel Dekker, New York – NY.
- Damavandi, M. G., Krishnamurthy, V. and Marti, J. R. (2015). Robust meter placement for state estimation in active distribution systems. *IEEE Transactions on Smart Grid*, 6(4), pp. 1972-1982.
- EATON Power Business Worldwide, (2018). *CYME Applications for Distribution power systems analysis (CYMDIST)*. [online] Available: <http://www.cyme.com/software/cymdist/> [Accessed 2 Jan. 2018].
- Esmaeili, A., Esmaeili, S. and Hojabri, H. (2016). Short-circuit level control through a multi-objective feeder reconfiguration using fault current limiters in the presence of distributed generations. *IET Generation, Transmission & Distribution*, 10(14), pp. 3458-3469.
- Gonçalves, J. F. and Resende, M. G. C. (2011). Biased random-key genetic algorithms for combinatorial optimization. *Journal of Heuristics*, 17(5), pp. 487-525.
- Gupta, N., Swarnkar, A., Niazi, K. R. and Bansal, R. C. (2010). Multi-objective reconfiguration of distribution systems using adaptive genetic algorithm in fuzzy framework. *IET Generation, Transmission & Distribution*, 4(12), pp. 1288-1298.
- Lavorato, M., Franco, J. F., Rider, M. J. and Romero, R. (2012). Imposing radiality constraints in distribution system optimization problems. *IEEE Transactions on Power Systems*, 27(1), pp. 172-180.
- Liu, J., Ponci, F., Monti, A., Muscas, C., Pegoraro, P. A. and Sulis, S. (2014). Optimal meter placement for robust measurement systems in active distribution grids. *IEEE Transactions on Instrumentation and Measurement*, 63(5), pp. 1096-1105.
- Martins, V. F. and Borges, C. L. T. (2011). Active distribution network integrated planning incorporating distributed generation and load response uncertainties. *IEEE Transactions on Power Systems*, 26(4), pp. 2164-2172.
- Monticelli, A. (1999). *State Estimation in Electric Power Systems: A Generalized Approach*. Norwell: Kluwer Academic Press.
- Muscas, C., Pilo, F., Pisano, G. and Sulis, S. (2006). Optimal placement of measurement devices in electric distribution systems. In: *Proceedings of the IEEE Instrumentation Measurement Technology Conference*. Sorrento, pp. 1873-1878.
- Muscas, C., Pilo, F., Pisano, G. and Sulis, S. (2009). Optimal allocation of multichannel measurement devices for distribution state estimation. *IEEE Transactions on Instrumentation and Measurement*, 58(6), pp. 1929-1937.
- Raidl, G. R. (2000). An efficient evolutionary algorithm for the degree-constrained minimum spanning tree problem. In: *Proceedings of the 2000 Congress on Evolutionary Computation*. La Jolla, pp. 104-111.
- Raposo, A. A. M., Rodrigues, A. B. and Da Silva, M. G. (2017). Optimal meter placement algorithm for state estimation in power distribution networks. *Electric Power Systems Research*, Vol. 147, pp. 22-30.
- Savier, J. S. and Das, D. (2007). Impact of network reconfiguration on loss allocation of radial distribution systems. *IEEE Transactions on Power Delivery*, 22(4), pp. 2473-2480.
- Singh, R., Pal, B. C. and Vinter, R. B. (2009). Measurement placement in distribution system state estimation. *IEEE Transactions on Power Systems*, 24(2), pp. 668-675.
- Souza, S. S. F. (2017). *Reconfiguração de sistemas de distribuição de energia elétrica considerando demandas variáveis utilizando algoritmos imunológicos artificiais*, Tese de Doutorado, FEIS-UNESP.
- Tahboub, A. M., Pandi, V. R. and Zeineldin, H. H. (2015). Distribution system reconfiguration for annual energy loss reduction considering variable distributed generation profiles. *IEEE Transactions on Power Delivery*, 30(4), pp. 1677-1685.
- Vaahedi, E. (2014). *Practical Power System Operation*. Hoboken: Wiley-IEEE Press.
- Wang, W., Zhang, W. and Liu, Y. (2018). A robust measurement placement method for active distribution system state estimation considering network reconfiguration. *IEEE Transactions on Smart Grid*, to be published.