

Algoritmo BPSO para Alocação de Medidores em Redes de Distribuição Considerando a Indisponibilidade dos Medidores

Antonio A. M. Raposo*. Maria G. da Silva.**
Anselmo B. Rodrigues**

**Instituto Federal de Educação, Ciência e Tecnologia de São Paulo – IFSP, Av. dos Universitários, 145, Tupã, SP, Brasil (e-mail: antonio.raposo@ifsp.edu.br).*

***Universidade Federal do Maranhão – UFMA, Av. dos Portugueses, 1966, São Luís, MA, Brasil (e-mails: guia.maria@ufma.br, anselmo.rodrigues@ufma.br)*

Abstract: This paper proposes a methodology for meters placement for state estimation in distribution networks. The proposed methodology considers that the allocation of meters is subject to the unavailability of up to two multifunctional meters. This formulation of the allocation problem prevents the accuracy of the state estimator from being degraded by the unavailability of the meters. Considering the effect of the correlation between power measurements, the meter placements was carried out using a multi-objective fuzzy formulation that maximizes the accuracy of the estimator and minimizes the number of meters installed in the distribution network. The optimization problem described above was solved using the Binary Particle Swarm Optimization Algorithm (BPSO). The results in the 95 nodes test system demonstrated that the proposed methodology obtained good quality solutions to the meters placement problem considering their unavailability.

Resumo: Este artigo propõe uma metodologia para alocação de medidores para a estimação de estado em redes de distribuição. A metodologia proposta considera que a alocação de medidores está sujeita a indisponibilidade de até dois medidores multifuncionais. Esta formulação do problema de alocação evita que a acurácia do estimador de estado seja degradada pela indisponibilidade dos medidores. Considerando-se o efeito da correlação entre as medições de potência, a alocação de medidores foi realizada usando-se uma formulação multiobjetivo fuzzy que maximiza a precisão do estimador e minimiza o número de medidores instalados na rede elétrica. O problema de otimização descrito acima foi solucionado através do Algoritmo de Otimização por Enxame de Partículas Binário (OEPB). Os resultados no sistema teste de 95 nós demonstraram que a metodologia proposta obteve soluções de boa qualidade para o problema de alocação de medidores considerando as suas indisponibilidades.

Keywords: Distribution networks, state estimation, meter placement, meter failures, multi-objective fuzzy, particle swarm optimization.

Palavras-chaves: Redes de distribuição, estimação de estado, alocação de medidor, falha nos medidores, otimização multiobjetivo fuzzy, otimização por enxame de partículas.

1. INTRODUÇÃO

O planejamento adequado da expansão e operação de uma rede elétrica inteligente exige novas considerações técnicas que, no âmbito de sistemas de distribuição, devem ser consideradas como, por exemplo: a estabilidade – devido à instalação de geração distribuída –, o despacho de carga e geração, o gerenciamento de dispositivos de armazenamento de energia e a avaliação do impacto da conexão de veículos elétricos na rede de distribuição. O principal pré-requisito para muitas destas novas funções do centro de operação da distribuição (COD) é a determinação do estado da rede elétrica (módulo e a fase das tensões nodais) em tempo real a partir de dispositivos de medição instalados nela. Nos centros de controle de sistemas de transmissão esta tarefa é realizada através do estimador de estado (EE). Uma vez presente um conjunto de medidores na rede, o COD coleta as suas respectivas medições através de diversos meios de

comunicação. Entretanto, apesar de usar tecnologias de comunicação avançadas, estes dados podem ser perdidos, corrompidos ou sofrerem atrasos devido a falhas intencionais ou involuntárias, ou mesmo pela infraestrutura de comunicação disponível. As falhas de comunicação involuntárias incluem indisponibilidade total do dispositivo de medição, falha em alguns canais de medição (indisponibilidade parcial), mau funcionamento do medidor, erro humano, arquitetura inadequada de comunicação, desastres naturais, dentre outros. Por outro lado, as falhas intencionais podem ser causadas por situações de ataques físicos ou cibernéticos, etc. (Meza et al., 2015; Gu and Jirutitijaroen, 2015).

Além do planejamento, o monitoramento e a operação adequada de uma rede elétrica inteligente são essenciais para garantir um serviço de boa qualidade aos consumidores e agentes que a compõe. Desta forma, é necessário que se conheça, com relativa precisão, o estado da rede de

distribuição. Por outro lado, uma vez presente um conjunto de medidores, a precisão do estado estimado pode ser bastante comprometida caso ocorra alguma contingência neste plano de medição, seja ela intencional ou involuntária. A alocação de medidores considerando os mais variados tipos de indisponibilidade é um tema que tem atraído pesquisadores nos últimos anos. Dentre os trabalhos associados, (Mosbah and El-Hawary, 2017) propuseram um método para melhorar a precisão de um estimador de estado dinâmico (EED) no nível de transmissão tendo como ferramenta de previsão de carga uma rede neural artificial *perceptron* multicamada. A validação da técnica proposta é realizada em cenários contendo erros nas medições e cenários com falhas na comunicação. Entretanto, o algoritmo proposto não busca melhorar a precisão do estado estimado concomitantemente à redução de dispositivos de medição, isto é, a técnica é aplicada considerando um plano de medição previamente definido.

Uma metodologia para avaliar a precisão de um EED em situações em que há falhas de comunicação e perdas de medições é proposta por (Gu and Jirutitijaroen, 2015). A abordagem combina o filtro de Kalman estendido com o modelo do tempo de avanço de Kriging para prever a perda de dados de medições e, assim, melhorar a precisão do estado filtrado. Os resultados demonstraram que o EED é mais preciso do que o estimador convencional em vários cenários de falhas. Entretanto, à medida que os erros de medições aumentam o estimador convencional torna-se competitivo com o EED, principalmente com relação a precisão do ângulo da tensão. Além disso, os autores não consideraram a correlação entre medições de potência.

(Anandini and Gupta, 2016) fornecem uma técnica para estimar a perda de medições devido às falhas de comunicação através da correlação entre medições reais e pseudo-medições. Sob o cenário de perda de medição, o algoritmo proposto pelos autores utiliza as correntes nos ramos como variáveis de estado (magnitude e fase) e particiona o conjunto de medições em medições ativas, nas quais não há indisponibilidade, e medições inativas, que representam medições que foram perdidas. Os resultados no sistema teste demonstraram que a técnica proposta é capaz de reduzir os erros relativos de fase e magnitude de tensão.

(Meza et al., 2015) investigam o impacto na observabilidade de sistemas de potência sujeitos a falhas na infraestrutura da transmissão. Os autores propõem uma metodologia que permite quantificar o risco da não-observabilidade na estimação de estado quando distúrbios naturais ou ataques cibernéticos afetam a topologia e a disponibilidade das medições presentes no sistema. Para isto, os autores definem camadas no sistema de potência e comunicação a fim de classificar a natureza da contingência, bem como a interação entre as diversas arquiteturas que compõem ambos os sistemas. Os resultados obtidos servem de suporte na tomada de decisão do operador do sistema de potência.

Um EE robusto em malha fechada é investigado por (Wu et al., 2013). O estimador foi projetado para ser robusto aos erros, tipo, localização e precisão das medições, bem como falha temporária do sistema de comunicação de medição

inteligente. A saída do estimador de estado é então realimentada para a função de aprendizado de máquina criando um fluxo de informações em malha fechada que melhora o desempenho do EE.

(Li and Scaglione, 2013) desenvolveram uma técnica de Gauss Newton baseada no algoritmo de fofocas para a avaliação de um sistema de energia por meio de um esquema de estimação de estado ponderado adaptativo e totalmente descentralizado por meio de fofocas em rede, mitigando o efeito de dados espúrios através de variações de erros atualizáveis em tempo real e reponderação de suas contribuições de forma adaptativa para a estimação do estado da rede. A vantagem desta técnica sobre outras é a incorporação do modelo de comunicação que se adapta às mudanças devido à reconfiguração e à falhas aleatórias, desde que a rede de comunicação esteja conectada.

A partir da revisão bibliográfica, observa-se que as metodologias existentes obtêm uma alocação robusta no sentido de manutenção da observabilidade e falhas na estrutura de comunicação do EE, sendo que estas metodologias são mais empregadas no âmbito dos sistemas de transmissão de energia. Em virtude disto, deve-se estabelecer um compromisso aceitável entre os objetivos da alocação e redução de custo de implementação de um projeto de estimação de estado robusto à indisponibilidade de medidores para redes de distribuição. Deste modo, este artigo tem como objetivo propor uma técnica multiobjetivo para alocar medidores tendo em vista o aumento da precisão do EE, redução dos custos de instalação e inclusão das falhas nos medidores. Este problema de otimização multiobjetivo foi solucionado usando o BPSO. O BPSO busca minimizar os custos de instalação de medidores sem sacrificar a precisão do EE. 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 95 nós demonstraram que a combinação do BPSO com os conjuntos fuzzy produziu soluções de alta qualidade, ou seja, planos de medição com baixo custo de instalação de medidores e precisão aceitável do EE.

2. ALOCAÇÃO DE MEDIDORES CONSIDERANDO A CORRELAÇÃO ENTRE AS MEDIÇÕES DE POTÊNCIA

O custo computacional para avaliar índices de precisão no problema de alocação de medidores (PAM) pode ser significativamente reduzido substituindo-se a Simulação Monte Carlo (SMC) por uma técnica analítica. Esta tarefa pode ser obtida a partir das condições de otimalidade de primeira ordem da função objetivo do problema de estimação de estado sob restrições de igualdade, definida em (1) e da expansão de Taylor de primeira ordem $h(\hat{x})$ em torno do vetor de estado verdadeiro (x^{true}) (Monticelli, 1999).

$$\begin{aligned} \min \quad & J(x) = \frac{1}{2} [z - h(x)]^T W_z [z - h(x)] \\ \text{sujeito a:} \quad & c(x) = 0 \end{aligned} \quad (1)$$

Onde: z é o vetor de medições; $h(x)$ é o vetor de equações não-lineares que relacionam as medições e variáveis de estado, W_z é a inversa da matriz de covariância associada às medicões e $c(x) = 0$ representa o vetor de medicões virtuais que são excluídas de $h(x)$.

Consequentemente, tem-se a seguinte relação linear entre \hat{x} e e_z (Raposo et al., 2020):

$$\hat{x} = A \cdot e_z + x^{true} \quad (2)$$

Onde: $A = K \cdot H(x^{true})W_z$ e $H(x^{true}) = H$ é a matriz Jacobiana associada com o vetor $h(x^{true})$, isto é, $H = \nabla h(x^{true})$ e K é uma submatriz da matriz inversa do sistema linear aumentado definido de acordo com a equação (3) (Raposo et al., 2020), sendo $C(x^{true}) = C$ a matriz Jacobiana associada com o vetor $c(x^{true})$.

$$\begin{bmatrix} K & L \\ M & N \end{bmatrix} = \begin{bmatrix} H^T W_z H & C^T \\ C & 0 \end{bmatrix}^{-1} \quad (3)$$

A equação (2) mostra que a distribuição de probabilidade de \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 (Raposo et al., 2017; Raposo et al., 2020). 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 PAM 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 (Singh et al., 2009). A probabilidade de atender limites especificados para o erro relativo entre os valores verdadeiros e estimados das variáveis de estado pode ser definida como:

$$P_k = \Pr \left\{ \left| \frac{\hat{V}_k - V_k^{true}}{V_k^{true}} \right| \leq \epsilon_V, \left| \frac{\hat{\theta}_k - \theta_k^{true}}{\theta_k^{true}} \right| \leq \epsilon_\theta \right\} \quad (4)$$

Onde: P_k é a probabilidade da tensão no k -ésimo nó não violar um limiar pré-estabelecido; $k \in \Omega_B^*$; Ω_B^* é o conjunto de nós do sistema excluindo-se o nó de referência; $\Pr\{x \leq c_1, y \leq c_2\}$ indica a probabilidade das variáveis aleatórias x e y serem menores 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 no k -ésimo nó, respectivamente; \hat{V}_k e $\hat{\theta}_k$ são os valores estimados do módulo e ângulo da tensão no k -ésimo nó, respectivamente, e; ϵ_V e ϵ_θ os valores especificados para o erro relativo de magnitude e fase da tensão, respectivamente.

Com o objetivo de aumentar a precisão do EE, define-se a função objetivo associada com a maximização da probabilidade mínima de violar os erros relativos de acordo com:

$$\begin{aligned} \max \quad & F_1(X) := P^{min} = \min_{k \in \Omega_B^*} P_k(X) \\ \text{sujeito a:} \quad & P^{min} \geq \bar{P} \end{aligned} \quad (5)$$

Onde: P^{min} é o menor valor de $P_k(X) \forall k \in \Omega_B^*$ associado com o plano de medição representado pelo vetor de variáveis de decisão X e \bar{P} é o limite inferior de P^{min} . A dimensão de X é igual ao número de nós da rede (NB) com seus elementos dados por: $X_k = 1$ ($X_k = 0$) se existe (se não existe) um medidor instalado no nó k .

A maximização de (5) 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 (Abur and G.-Expósito, 2004). 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 (5) seja satisfeita com o mínimo número de medidores multifuncionais. Assim, a função objetivo associada com os custos de equipamentos de medição é dada por:

$$\min \quad F_2(X) := M_A = \sum_{k=1}^{NB} X_k \quad (6)$$

Onde: M_A é a função objetivo correspondente ao número de medidores multifuncionais alocados na rede, calculada para um dado plano de medição representado pelo vetor de variáveis de decisão X .

O índice P^{min} definido em (5) considera que todos os M_A medidores do plano de medição estejam disponíveis. Entretanto, se for considerada a indisponibilidade de até m medidores e que estes eventos são independentes, então P^{min} será igual ao valor esperado obtido a partir dos estados de falhas dos medidores. A probabilidade individual de um estado de falha para um plano de medição composto por M_A medidores é obtida de acordo com (7).

$$\mathbb{P}(\mathbf{x}^i) = \prod_{j=1}^{M_A} \mathbb{P}(\mathbf{x}_j^i) \quad (7)$$

Onde: \mathbf{x}^i é o vetor de estado de falha i para o plano de medição X ; $\mathbf{x}_j^i = 1$ ($\mathbf{x}_j^i = 0$) se o medidor j está operando (falhado) no estado \mathbf{x}^i ; $\mathbb{P}(\mathbf{x}^i) = 1 - \mathbb{U}_j$ ($\mathbb{P}(\mathbf{x}^i) = \mathbb{U}_j$), se $\mathbf{x}_j^i = 1$ ($\mathbf{x}_j^i = 0$); \mathbb{U}_j representa a indisponibilidade (probabilidade de falha) do medidor j .

Deste modo, tem-se que o valor esperado do índice P^{min} considerando-se falhas envolvendo até N_F medidores é dado por:

$$\mathbb{E}[P^{min} | m \leq N_F] = \sum_{m=0}^{N_F} \sum_{i \in \Theta_m} \mathbb{P}(\mathbf{x}^i | m \leq N_F) \times P^{min}(\mathbf{x}^i) \quad (8)$$

Onde: Θ_m é o conjunto de estados do plano de medição com m medidores falhados, com $|\Theta_m| = \binom{M_A}{m}$, sendo que $\binom{M_A}{m}$ é o número de combinações de m medidores tomadas a partir de M_A ; $\mathbb{E}[P^{min} | m \leq N_F]$ é o valor esperado condicional do índice P^{min} considerando que $m \leq N_F$; $\mathbb{P}(\mathbf{x}^i | m \leq N_F) = \frac{\mathbb{P}(\mathbf{x}^i)}{\sum_{m=0}^{N_F} \sum_{i \in \Theta_m} \mathbb{P}(\mathbf{x}^i)}$, e; $P^{min}(\mathbf{x}^i)$ é o valor do índice P^{min} para o estado \mathbf{x}^i .

Com o objetivo de aumentar a precisão do EE, dado que no máximo N_F medidores de X estejam indisponíveis, define-se a seguinte função objetivo:

$$\begin{aligned} \max \quad & F_3(X) := \mathbb{E}[P^{min} | m \leq N_F] \\ \text{sujeito a:} \quad & \mathbb{E}[P^{min} | m \leq N_F] \geq \bar{P} \end{aligned} \quad (9)$$

3. FORMULAÇÃO MULTIOBJETIVO FUZZY PARA O PROBLEMA DE ALOCAÇÃO DE MEDIDORES SOB CONDIÇÕES DE FALHA

Vários problemas do mundo real apresentam uma grande quantidade de objetivos a serem otimizados que, em sua grande maioria, são conflitantes entre si. 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 (5), (6) e (9). Entretanto, como foi mencionado anteriormente, (5), (6) e (9) possuem dimensões e unidades distintas. Devido a isto, foi desenvolvido um sistema fuzzy para combinar as metas do problema 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 et al., 2016; Gupta et al., 2010). As funções de pertinência para cada objetivo otimizado neste artigo são descritas a seguir.

3.1 Funções de Pertinência para $F_1(X)$ e $F_2(X)$

A proposta da função de pertinência associada com a precisão do EE dado que todos os medidores estejam sempre disponíveis é dada por:

$$\mu_N^P(X) = \frac{1 - e^{-F_1(X)}}{1 - e} \quad (10)$$

Como os valores mínimo e máximo que $F_1(X)$ pode assumir são 0 e 1, então $0 \leq \mu_N^P(X) \leq 1$. Desta forma, quanto mais preciso for o plano de medição ($F_1(X) \rightarrow 1$), mais próximo da unidade $\mu_N^P(X)$ se aproximará.

A função de pertinência associada com o custo do plano de medição é definida de acordo com (11).

$$\mu_N^M(X) = \frac{e^{-\frac{F_2(X)}{NB}} - e^{-1}}{1 - e^{-1}} \quad (11)$$

Com esta definição, quando $F_2(X) \rightarrow 0$, tem-se $\mu_N^M(X) \rightarrow 1$ e, como $1 \leq F_2(X) \leq NB$, quando $F_2(X) \rightarrow NB$, $\mu_N^M(X) \rightarrow 0$.

3.2 Grau de Satisfação Fuzzy do POM Considerando a Indisponibilidade Nula

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* (Raposo et al., 2018). Neste artigo, a obtenção do grau de satisfação fuzzy do POM, μ^{POM} , se baseia no operador de máxima média geométrica definido em (12).

$$\mu^{POM} = \left(\prod_{i \in \Omega_F} \mu_i \right)^{\frac{1}{|\Omega_F|}} \quad (12)$$

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. Nos modelos propostos neste artigo, tem-se que $|\Omega_F| = 2$.

O processo de alocação de medidores busca minimizar os custos com a instalação de medidores multifuncionais ao mesmo tempo que reduz o risco de violar a precisão do

estimador de estado. A partir de (12), e, considerando que os medidores estejam sempre disponíveis, estas metas podem ser alcançadas através da solução do seguinte problema de otimização mono-objetivo:

$$\begin{aligned} \max \quad & F_4(X) := \mu_N^{POM}(X) = \sqrt{\mu_N^P(X) \cdot \mu_N^M(X)} \\ \text{sujeito a:} \quad & P^{min} \geq \bar{P} \end{aligned} \quad (13)$$

O plano de medição com máximo $\mu_N^{POM}(X)$ representará a melhor solução para o problema de alocação de medidores.

3.3 Grau de Satisfação Fuzzy do POM sob Condições de Falhas nos Medidores

A proposta da função de pertinência associada com a precisão do EE sob condições de indisponibilidade de até N_F medidores é dada por:

$$\mu_F^P(X) = \frac{1 - e^{F_3(X)}}{1 - e} \quad (14)$$

A partir desta definição, o melhor plano de medição que satisfaz ao mesmo tempo os critérios de alta precisão do EE e baixo custo de instalação dos medidores, considerando que até N_F medidores estejam indisponíveis, é obtido de acordo com (15).

$$\begin{aligned} \max \quad & F_5(X) := \mu_F^{POM}(X) = \sqrt{\mu_F^P(X) \cdot \mu_N^M(X)} \\ \text{sujeito a:} \quad & \mathbb{E}[P^{min} | m \leq N_F] \geq \bar{P} \end{aligned} \quad (15)$$

O plano de medição com máximo $\mu_F^{POM}(X)$ representará a melhor solução para o problema de alocação de medidores sob condições de falhas nos medidores.

4. FORMULAÇÃO DO PAM VIA BPSO

A técnica proposta para maximizar (13) e (15) baseia-se no BPSO. O BPSO é uma meta-heurística evolutiva para problemas de otimização em um espaço de busca discreto, cujo domínio contém variáveis finitas (Kennedy and Eberhart, 1997). Como na otimização de enxame de partículas, o BPSO é inspirado no comportamento social das populações biológicas. O comportamento do enxame é influenciado pelas informações contidas em cada indivíduo (partícula) pertencente a ele. O movimento dos indivíduos é determinado por um vetor chamado vetor de velocidade. Cada partícula atualiza sua velocidade com base em sua velocidade atual, na melhor posição que foi explorada e na melhor posição explorada pelo enxame. A atualização da velocidade de uma partícula é dada por:

$$\begin{aligned} v_{*j}(t+1) = & \omega \cdot v_{*j}(t) + \\ & c_1 \cdot r_{*j}^{u1}(t) \cdot [\bar{\xi}_{*j}^{best} - \xi_{*j}(t)] + \\ & c_2 \cdot r_{*j}^{u2}(t) \cdot [\bar{\xi}_{*j}^{best} - \xi_{*j}(t)] \\ \text{para } j = & 1, \dots, N^{part} \end{aligned} \quad (16)$$

Onde: $\xi_{*j}(t) = [\xi_{1j}(t) \dots \xi_{N^{dim}j}(t)]^T$ e $v_{*j}(t) = [v_{1j}(t) \dots v_{N^{dim}j}(t)]^T$ são os vetores de posição e velocidade, respectivamente, da partícula j para a iteração t ; $\xi_{ij}(t)$ e $v_{ij}(t)$ são, respectivamente, a posição e a velocidade da partícula j na dimensão i para a iteração t ; $N^{dim} = NB$ é o número das dimensões do espaço de busca; ω é o coeficiente de inércia; c_1 e c_2 são constantes positivas para a aceleração usada para ponderar as contribuições dos fatores cognitivos e sociais, respectivamente; $r_{*j}^{u1}(t)$ e $r_{*j}^{u2}(t)$ são vetores de números aleatórios uniformemente distribuídos no intervalo $[0,1]$; $\bar{\xi}_{*j}^{best}$ é a melhor posição encontrada pelo enxame; ξ_{*j}^{best} é a melhor posição encontrada pela partícula j ; N^{part} é o número de partículas no enxame.

No BPSO, cada partícula tem sua posição representada por valores binários: zero ou um. O algoritmo básico consiste em procurar a solução ótima dentro de um espaço multidimensional no qual cada partícula ocupa uma posição específica com uma velocidade que indica seu movimento. O espaço multidimensional do PAM equivale ao número de nós da rede de distribuição, isto é, NB .

A atualização da posição de cada partícula j , na dimensão i , é obtida conforme (17).

$$\xi_{ij}(t+1) = \begin{cases} 1, & \text{se } r_{ij}^{u3}(t) < \frac{1}{1 + e^{-v_{ij}(t)}} \\ 0, & \text{caso contrário} \end{cases} \quad (17)$$

Onde: $r_{ij}^{u3}(t)$ é um número aleatório uniformemente distribuído no intervalo $[0,1]$.

O pseudocódigo do BPSO usado para solucionar (13) e (15) é ilustrado na Fig. 1.

5. RESULTADOS

5.1 Características do Sistema Teste

O algoritmo proposto foi testado no sistema de 95 nós (S95) (Singh et al., 2009). O S95 possui 37 nós de injeções nulas, o que corresponde a aproximadamente 38,95% do total de nós. Além disso, possui tensão nominal de 11 kV, tem 3,576 MW e 2,201 MVar de potência instalada ativa e reativa, respectivamente.

As simulações no S95 foram realizadas considerando que: o nó da subestação, nó #1, é o nó de referência; os erros relativos especificados de tensão e ângulo são, respectivamente, $\epsilon_V \leq 1\%$ e $\epsilon_\theta \leq 5\%$; $\bar{P} = 0,95$; 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 BPSO usado para avaliar (13) e (15) tem os seguintes parâmetros: $N^{part} = 40$; $\omega = 0,7$; $c_1 = c_2 = 2$, e; número máximo de gerações igual a 1000.

A análise do algoritmo proposto para o PAM considerou quatro casos de estudo:

Caso #0 (caso base): o plano de medição é composto de um medidor instalado na subestação e pseudo-medições.

Caso #1: o BPSO é aplicado ao caso #0 para maximizar $F_4(X)$. Esse caso é equivalente a alocação convencional em que todos os medidores alocados estejam disponíveis.

Caso #2: Teste de robustez a falhas do plano de medição obtido no caso #1 considerando indisponibilidades \mathbb{U} de 5%, 10%, 15% e 20%.

Caso #3: o BPSO é aplicado ao caso #0 para maximizar $F_5(X)$, isto é, este caso reduz simultaneamente o número de medidores enquanto melhora a precisão do EE sob condições de falha de até $N_F = 2$ medidores. Com $N_F = 2$, amplia-se os valores propostos por (Meza et al., 2015). Para o caso #3 é realizada a sensibilidade do método para indisponibilidades \mathbb{U} de 5%, 10%, 15% e 20%.

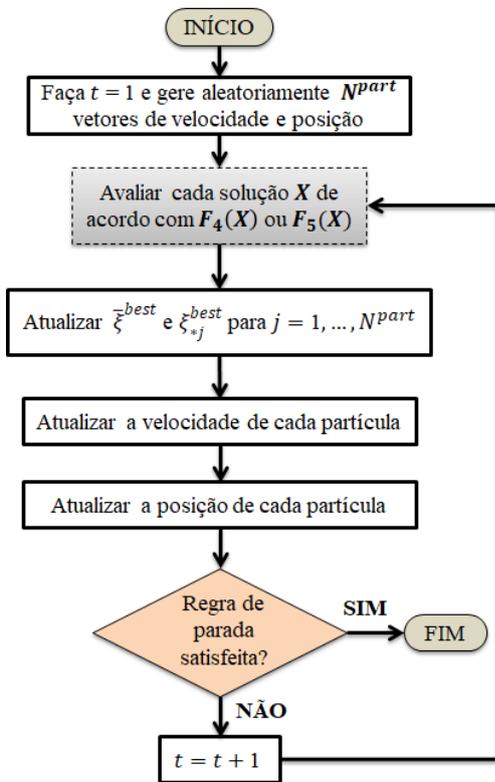


Fig. 1. Fluxograma do BPSO aplicado aos PAMs (13) e (15).

5.2 Resultados dos Casos de Estudo

Os nós do S95 ilustrados nos mapas de calor são divididos em três tipos: subestação – definido por um retângulo azul; nós de carga – definidos por um círculo magenta e nós de injeção nula – definidos por um círculo bege. Para o caso #0, apenas 6 nós do S95 apresentam P_k acima de $\bar{P} = 0,95$, ilustrados em verde no mapa de calor da Fig. 2. Essa quantidade corresponde apenas 6,32% do total de nós do sistema. Com apenas um medidor e pseudo-medições, tem-se $P^{min} = 0,0876$. A partir da Fig. 2, pode-se notar que grande parte do sistema apresentou violações em P_k entre 0,20 e 0,70. Com maiores violações registradas nos nós #81, #82, #92, #93, #94 e #95.

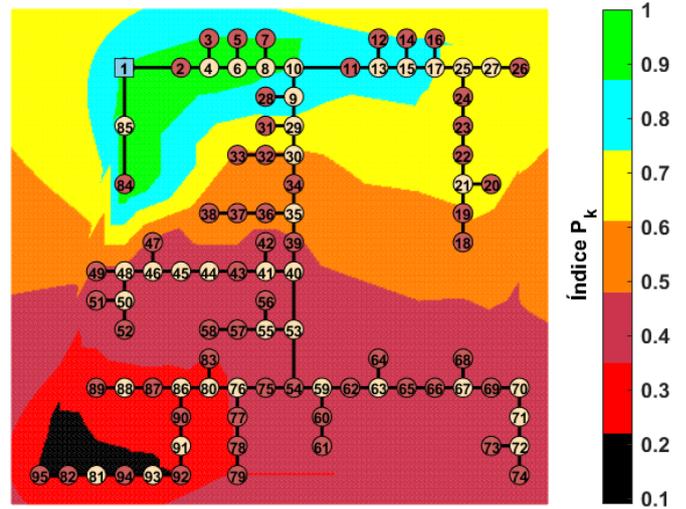


Fig. 2. Probabilidade nodal para o caso #0.

Para o caso #1, o BPSO obteve um plano de medição capaz de atender um risco com nível de significância \bar{P} , utilizando 6 medidores instalados nos nós #1, #8, #10, #53, #82 e #92, resultando em um $P^{min} = 0,9528$. Este resultado corresponde a uma melhoria em torno de 90,8060% do valor de P^{min} obtido a partir do caso #0. Observa-se a partir da Fig. 3, que grande parte do S95 possui $P_k \geq 0,99$ em contraste com o caso #0, no qual há grande quantidade de nós com $0,20 \leq P_k \leq 0,70$.

A robustez com relação a falhas do plano de medição gerado pelo BPSO no caso #1 foi analisada. Esta análise foi realizada considerando a indisponibilidade de, no máximo, dois medidores, isto é, solucionando-se (15). Os resultados do caso #2 são apresentados na Tabela 1. A Tabela 1 mostra os componentes do índice P^{min} associados com cada ordem de falha do plano de medição ótimo do caso #1 para alguns valores de indisponibilidade \mathbb{U} . Essa tabela também mostra o valor esperado resultante do índice P^{min} (soma dos componentes) definido em (8). A partir desta tabela é possível verificar que a precisão do EE é deteriorada pelas falhas dos medidores. A Fig. 4 ilustra o comportamento de $\mathbb{E}[P^{min} | m \leq N_F]$ considerando-se uma falha no medidor localizado no nó #53, bem como a indisponibilidade

simultânea dos medidores situados nos nós #8 e #10. A partir da Fig. 4 é possível verificar porções do sistema com cores em azul, amarelo e laranja, indicando o efeito das contingências na degradação da precisão do EE. Os resultados do caso #2 indicam que é necessário analisar o problema de alocação considerando contingências no plano de medição.

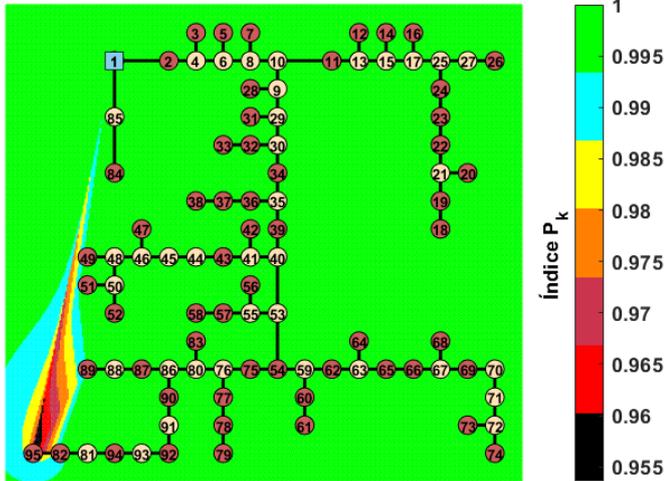


Fig. 3. Probabilidade nodal para o caso #1.

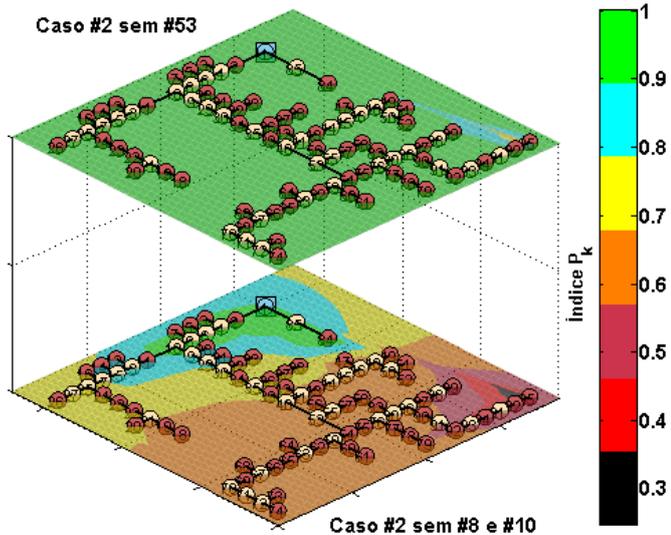


Fig. 4. Probabilidade nodal para contingências de ordem 1 e 2 no plano de medição obtido no caso #1.

Com o objetivo de mitigar os problemas encontrados no caso #2, o BPSO foi aplicado ao caso #0 para diferentes probabilidades de falha dos medidores multifuncionais. Para o caso #3, considerando-se $U = 5\%$, o BPSO adicionou 6 medidores ao plano de medição do caso #0 nos nós #8, #10, #40, #82, #84 e #92. Com um medidor a mais em relação ao caso #1, houve uma melhora da ordem de 6,3360% no índice $\mathbb{E}[P^{min}|m \leq N_F]$ quando comparado ao caso #2 (ver Tabelas 1 e 2). Para $U = 10\%$, o BPSO obteve um plano de medição capaz de atender um risco com nível de significância \bar{P} , utilizando 8 medidores instalados nos nós #1, #8, #10, #40,

#76, #82, #84 e #92. Este resultado aumenta em 33,33% o custo com a instalação de medidores em relação ao caso #1, mas há uma melhora da ordem de 15,3461% no índice $\mathbb{E}[P^{min}|m \leq N_F]$ em relação ao caso #2. Para $U = 15\%$, o BPSO adicionou 1 medidor ao plano de medição do caso #3, considerando $U = 10\%$. Os nós com medidores instalados são #1, #8, #10, #25, #53, #75, #82, #84 e #92. Em comparação com o caso #2, houve uma melhora no índice $\mathbb{E}[P^{min}|m \leq N_F]$ em torno de 23,0455%, mas com um aumento de 160% no custo com equipamentos de medição. Considerando $U = 20\%$, o BPSO adicionou 10 medidores ao plano de medição do caso #0 nos nós #8, #10, #25, #46, #53, #63, #76, #82, #84 e #92, conseguindo melhorar em cerca de 30,6292% o índice $\mathbb{E}[P^{min}|m \leq N_F]$ em relação ao caso #2.

Tabela 1. Valor esperado do índice P^{min} para cada cenário de falha e valor total para $m \leq N_F$ – caso #2.

	Indisponibilidade U (%)			
	5	10	15	20
$\sum_{i \in \Theta_0} \mathbb{P}(\mathbf{x}^i 0 \leq N_F) \times P^{min}(\mathbf{x}^i)$	0,7144	0,5237	0,3839	0,2821
$\sum_{i \in \Theta_1} \mathbb{P}(\mathbf{x}^i 1 \leq N_F) \times P^{min}(\mathbf{x}^i)$	0,1721	0,2664	0,3102	0,3229
$\sum_{i \in \Theta_2} \mathbb{P}(\mathbf{x}^i 2 \leq N_F) \times P^{min}(\mathbf{x}^i)$	0,0147	0,0479	0,0887	0,1309
$\mathbb{E}[P^{min} m \leq N_F]$	0,9012	0,8380	0,7828	0,7359

Tabela 2. Valor esperado do índice P^{min} para cada cenário de falha e valor total para $m \leq N_F$ – caso #3.

	Indisponibilidade U (%)			
	5	10	15	20
$\sum_{i \in \Theta_0} \mathbb{P}(\mathbf{x}^i 0 \leq N_F) \times P^{min}(\mathbf{x}^i)$	0,6926	0,4474	0,2695	0,1389
$\sum_{i \in \Theta_1} \mathbb{P}(\mathbf{x}^i 1 \leq N_F) \times P^{min}(\mathbf{x}^i)$	0,2358	0,3879	0,4204	0,3770
$\sum_{i \in \Theta_2} \mathbb{P}(\mathbf{x}^i 2 \leq N_F) \times P^{min}(\mathbf{x}^i)$	0,0299	0,1313	0,2733	0,4454
$\mathbb{E}[P^{min} m \leq N_F]$	0,9583	0,9666	0,9632	0,9613

Os dados da Tabela 2 indicam que a contribuição do valor esperado de P^{min} para o índice $\mathbb{E}[P^{min}|m \leq N_F]$ aumenta à medida que o número de medidores em estado de falha simultânea aumenta. Este fato deve-se ao elevado número de medidores alocados através do BPSO à proporção que a probabilidade de falha aumenta. Além disso, nota-se que para todas as indisponibilidades U analisadas, o método proposto gera soluções que são capazes de atender um risco com nível de significância \bar{P} de 0,95. Outra característica é que o aumento no número de medidores multifuncionais instalados, devido ao aumento da probabilidade de falha, gera um decaimento, quase exponencial, no número de medições críticas – no senso de perda de precisão do EE – do plano de medição. Este resultado é ilustrado na Fig. 5.

REFERÊNCIAS

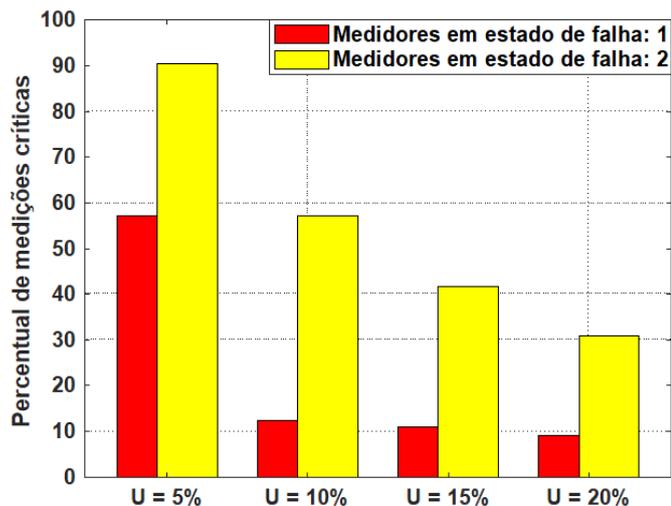


Fig. 5. Percentual de medições críticas para cada probabilidade de falha vs. número de medidores em estado falhado – caso #3.

6. CONCLUSÕES

Este artigo propôs uma metodologia para alocação ótima de medidores para estimação de estado em redes de distribuição. A metodologia proposta considera que a alocação de medidores é realizada de forma simultânea à indisponibilidade de até dois medidores multifuncionais presentes no plano de medição. Esta formulação do problema de alocação evita que a precisão do EE seja degradada quando ocorrem contingências, com grau de redundância $N-2$, que levam a perda completa medidores do plano de medição. Estas metas foram alcançadas usando-se uma formulação multiobjetivo que maximiza a precisão do estimador e minimiza o número de medidores instalados na rede elétrica. A otimização concorrente destes objetivos foi realizada usando-se uma versão multiobjetivo do BPSO. A versão multiobjetivo do BPSO 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 multiobjetivo original em um problema mono-objetivo. Os testes no sistema de 95 nós demonstraram que a estratégia de alocação considerando a indisponibilidade de até dois medidores multifuncionais mostrou-se eficiente em relação a melhoria da precisão do EE. Além disso, foram constatadas reduções significativas na quantidade de medições críticas – no sentido de precisão do EE – à proporção que a probabilidade de falha dos medidores aumenta.

AGRADECIMENTOS

Os autores agradecem o suporte financeiro da FAPEMA.

- Abur, A., and G.-Expósito, A. (2004). *Power System State Estimation: Theory and Implementation*. New York: Marcel Dekker.
- Anandini, G. N., and Gupta, I. (2016). Estimating the lost real-time measurements under communication failure for distribution system state estimation. In: National Power Syst. Conf. (NPSC). Bhubaneswar, pp. 1-5.
- 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.
- Gu, C., and Jirutitijaroen, P. (2015). Dynamic state estimation under communication failure using kriging based bus load forecasting. *IEEE Trans. on Power Systems*, 30(6), pp. 2831–2840.
- 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.
- Li, X., and Scaglione, A. (2013). Robust Decentralized State Estimation and Tracking for Power Systems via Network Gossiping. *IEEE Journal on Selected Areas in Communications*, 31(7), pp. 1184-1194.
- Meza, V., Gomes, X., and Perez, E. (2015). Quantifying observability. In: IEEE PES Innovative Smart Grid Technologies Latin America (ISGT LATAM). Montevideo, pp. 171-176.
- Monticelli, A. (1999). *State Estimation in Electric Power Systems: A Generalized Approach*. Norwell: Kluwer Academic Press.
- Mosbah, H., and El-Hawary, M. E. (2017). Optimization of neural network parameters by Stochastic Fractal Search for dynamic state estimation under communication failure. *Electric Power Systems Research*, Vol. 147, pp. 288–301.
- 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.
- Raposo, A. A. M., Rodrigues, A. B., and Da Silva, M. G. (2018). Alocação Ótima de Medidores para a Estimação de Estado Considerando a Reconfiguração da Rede de Distribuição. In: XXII Congresso Brasileiro de Automática (CBA). João Pessoa, pp. 1-8.
- Raposo, A. A. M., Rodrigues, A. B., and Da Silva, M. G. (2020). Robust meter placement for state estimation considering distribution network reconfiguration for annual energy loss reduction. *Electric Power Systems Research*, Vol. 182, pp. 1-9.
- 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.
- Wu, J., He, Y., and Jekins, N. (2013). A robust state estimator for medium voltage distribution networks. *IEEE Trans. on Power Systems*, 28(2), pp. 1008–1016.