

Metodologia para Estimação de Estados em Sistemas de Distribuição com Geração Distribuída utilizando o OpenDSS e Metaheurísticas

Thiago B. Amaral*. Bruna G. S. Oliveira*. Matheus F. S. Mendes*. Wesley Peres*. Francisco C. R. Coelho*. Raphael P. B. Poubel**

*Departamento de Engenharia Elétrica, Universidade Federal de São João del Rei – UFSJ, São João del-Rei, Minas Gerais, Brasil (e-mail: th1boldrini@gmail.com; brunags.oliveira98@gmail.com; matheusfs.mendes@gmail.com; wesley.peres@ufsj.edu.br; franciscocoelho@ufsj.edu.br)

** Departamento de Engenharia Elétrica, Centro Federal de Educação Tecnológica de Minas Gerais – CEFET-MG, Belo Horizonte, Brasil (e-mail: poubel@cefetmg.br)

Abstract: This paper presents an optimization approach for unbalanced three-phase distribution system state estimation, taking the power loads and generations as state variables. Phasor Measurements Units placed at strategic locations of the distribution feeders provide the set of measurements used. Three metaheuristics are employed to solve the problem, and their results are compared with the ones provided by a numerical method. Finally, the OpenDSS software is used to evaluate the solutions during the optimization problem.

Resumo: O presente trabalho apresenta uma metodologia de otimização para a estimação de estados em sistemas de distribuição trifásicos desequilibrados em que as variáveis de estado são as demandas de potência e as gerações de potência das unidades de geração distribuída. São consideradas medidas fasoriais de tensão e corrente em pontos estratégicos do alimentador. Para a solução do problema, três metaheurísticas são empregadas e comparadas com um método numérico baseado em derivadas. Para avaliação das soluções das metaheurísticas, o *software* OpenDSS é adotado durante o processo de solução.

Keywords: Distribution System State Estimation; Distributed Generation; Metaheuristics; OpenDSS; Phasor Measurements Units; Smart Distribution System.

Palavras-chaves: Estimação de Estados em Sistemas de Distribuição; Geração Distribuída; Metaheurísticas; OpenDSS; Unidades de Medição Fasorial Sincronizadas; Redes Inteligentes.

1. INTRODUÇÃO

1.1 Estimação de Estados em Sistemas de Distribuição

Os Sistemas de Distribuição de Energia Elétrica (SDEE) têm passado por grandes transformações, como por exemplo, a alta penetração de Geração Distribuída (GD) e Sistemas de Armazenamento (Baterias). Nesse contexto, ferramentas para o auxílio na operação em tempo real dos SDEE são essenciais para a garantia de uma operação segura, confiável e econômica. Uma dessas ferramentas é o Estimador de Estados (EE) (Ahmad et al., 2018; Dehghanpour et al., 2019).

A Estimação de Estados para os sistemas de transmissão está bem estabelecida devido aos estudos e aplicações práticas desde a década de setenta (Abur & Exposito, 2004). Entretanto, para os SDEE, os estudos começaram em meados da década de noventa (Baran & Kelley, 1994). Adicionalmente, as aplicações práticas da EE em SDEE são limitadas, principalmente por questões de infraestrutura de medição (Huang et al., 2012).

Os Sistemas de Transmissão e Distribuição são muito diferentes entre si, sendo as maiores diferenças: (i) o número de medidores é reduzido nos SDEE; (ii) para a garantia de observabilidade, pseudomedidas de injeções de potência baseadas em histórico de cargas são usadas; (iii) alta relação R/X que comprometem a convergência de metodologias convencionais; (iv) estrutura radial ou fracamente malhada; (v) operação desbalanceada. Nesse contexto, os estimadores dos sistemas de transmissão não podem ser diretamente utilizados para os sistemas de distribuição (Ahmad et al., 2018; Dehghanpour et al., 2019).

Em meados da década de noventa (Baran & Kelley, 1995) propuseram o Estimador de Estados baseado nas Correntes dos Ramos (EECR). Essa formulação, baseada no método dos Mínimos Quadrados Ponderados e que considera as partes real e imaginária das correntes nos ramos como variáveis, apresenta boa característica de convergência (velocidade e estabilidade numérica). O EECR mostrou-se adequado para a EE em SDEE trifásicos, radiais, desbalanceados e com alta relação R/X. Na última década, o EECR foi aprimorado para: (i) inclusão de medidas de magnitude de tensão; (ii) inclusão de medidas provenientes de *Advanced Metering Infrastructure*; (iii) estimação topológica; (iv) representação

das correntes em forma polar, etc. Em (Peres et al., 2014) é feita uma revisão a respeito das aplicações dos EECR e um estudo da estabilidade numérica desse método. Por fim, em (Pau et al., 2013) o EECR foi aprimorado para a inclusão de medidas fasoriais de tensão e corrente fornecidas por *Phasor Measurement Units* (PMU). As medições fasoriais fornecem maior precisão ao processo de estimação conforme (Korres & Manousakis, 2011). Uma revisão mais aprofundada a respeito dos métodos de EE para SDEE pode ser encontrada em (Ahmad et al., 2018; Dehghanpour et al., 2019).

Em relação à garantia de observabilidade, foi anteriormente citada a necessidade de pseudomedidas de injeção baseadas em histórico de cargas. Esse fato se deve aos extensos ramais de distribuição e ao baixo número de medidores. Como resultado, o processo de EE pode ser comprometido. De forma a contornar esse problema, em (de Oliveira et al., 2018) foi proposta uma metodologia de otimização em que as pseudomedidas de injeção são tratadas como restrições de desigualdade. As variáveis são as correntes nos ramos na forma retangular.

Embora a solução do processo de Estimação de Estados por métodos numéricos (tais como o Gauss-Newton e Método dos Pontos Interiores) seja recorrente na literatura (Abur & Exposito, 2004), a aplicação de metaheurísticas tem sido investigada.

Em (Tungadio et al., 2015) o método *Particle Swarm Optimization* (PSO) é usado para a solução de dois problemas de otimização para estimação de estados em sistemas de transmissão: o “*Weighted Least Square* (WLS)” e o “*Weighted Least Absolute Value* (WLAV)”.

Em (Nanchian et al., 2017) o PSO é utilizado para a estimação de estados em sistemas de distribuição considerando as tensões complexas e os tapas dos transformadores como variáveis.

1.2 Proposta do Presente Trabalho

O presente trabalho resolve o problema de EE em SDEE trifásico e desbalanceado através de um modelo de otimização em que as cargas e as gerações de potência ativa (das unidades de Geração Distribuída – GD) são as variáveis devidamente tratadas como restrições de desigualdade (restrições de canalização ou banda) em que os limites mínimos e máximos são definidos com base no valor nominal (valor central). O objetivo é minimizar uma função objetivo determinada pelo somatório das diferenças quadráticas ponderadas entre valores de medição e seus correspondentes valores estimados. Medidas fasoriais das tensões nodais e correntes nos ramos (em pontos estratégicos dos alimentadores) são consideradas. Para a solução do problema, faz-se a aplicação de metaheurísticas populacionais, em que os indivíduos são avaliados pelo OpenDSS (Dugan & McDermott, 2011).

O estudo de caso, considerando uma rede trifásica de 13 barras (Schneider et al., 2018) apontam para a aplicabilidade da implementação computacional desenvolvida.

2. METODOLOGIA PROPOSTA

2.1 Breve Introdução à Metodologia Proposta

A metodologia proposta consiste em um problema de otimização em que se deseja minimizar uma função objetivo determinada pelo somatório das diferenças quadráticas ponderadas entre valores de medição e seus correspondentes valores estimados, calculados em função das variáveis de estados baseado no método dos Mínimos Quadrados Ponderados (*Weighted Least Square* (WLS)) (Abur & Exposito, 2004). As variáveis de otimização são: (i) as cargas ativa e reativa em cada barra e, (ii) a geração de potência ativa nas barras com Geração Distribuída (considera-se geradores com fator de potência unitário). Ao se considerar as cargas como variáveis de otimização, permite-se que o problema de otimização faça os ajustes destas dentro de uma faixa pré-especificada (centrada no valor nominal ou no valor obtido a partir de previsão de carga) visando minimizar a função objetivo, haja vista que o conhecimento do valor exato e em tempo real das cargas (e gerações distribuídas) não é possível devido ao baixo número de medidores a serem alocados na rede (de Oliveira et al., 2018).

2.2 Formulação do Problema de Otimização

A função objetivo é detalhada em (1), sendo Ω_M o conjunto de medições; z_i é a i -ésima medida; $h_i(x)$ é relação não linear entre a i -ésima medição e os estados do sistema; σ_i é o desvio padrão da i -ésima medida.

$$\min J(x) = \frac{1}{2} \cdot \sum_{i \in \Omega_M} \left(\frac{z_i - h_i(x)}{\sigma_i} \right)^2 \quad (1)$$

As restrições de igualdade são dadas em (2)-(4): estas estão associadas ao balanço de potência nas barras do sistema bem como à referência angular.

$$P_{gk,p} - P_{dk,p} - P_{k,p}(V, \theta) = 0 \quad (p \in \Omega_{\phi_k}) \quad (k \in \Omega_B) \quad (2)$$

$$0 - Q_{dk,p} - Q_{k,p}(V, \theta) = 0 \quad (p \in \Omega_{\phi_k}) \quad (k \in \Omega_B) \quad (3)$$

$$\theta_{ref} = 0 \quad (p \in \Omega_{\phi_{ref}}) \quad (4)$$

em que: Ω_{ϕ_k} é o conjunto de fases da barra k (que pode ser trifásica, bifásica ou monofásica); Ω_B é o conjunto de barras do sistema; $P_{gk,p}$ é a geração de potência ativa na fase p da barra k ; $P_{dk,p}$ e $Q_{dk,p}$ são as demandas de potência ativa e reativa na fase p da barra k ; $P_{k,p}$ e $Q_{k,p}$ são as injeções de potência ativa e reativa na fase p da barra k calculadas em função do vetor de tensões (V) e de fases do sistema (θ); $\Omega_{\phi_{ref}} = \{1,2,3\}$ é o conjunto de fases da barra de referência; $\theta_{ref,p}$ denota a referência angular do sistema (barra ref).

Ressalta-se que em (3) adota-se a geração de potência reativa nula ($Q_{gk,p} = 0$) pelo fato de se considerar geradores distribuídos com fator de potência unitário. Para as barras que não possuem geradores distribuídos, considera-se $P_{gk,p} = 0$ em (2).

As equações (5)-(7) denotam os limites máximo e mínimo de todas as variáveis de otimização.

$$P_{dk,p}^{min} \leq P_{dk,p} \leq P_{dk,p}^{max} \quad (p \in \Omega_{\phi_k}) \quad (k \in \Omega_B) \quad (5)$$

$$Q_{dk,p}^{min} \leq Q_{dk,p} \leq Q_{dk,p}^{max} \quad (p \in \Omega_{\phi_k}) (k \in \Omega_B) \quad (6)$$

$$P_{gk,p}^{min} \leq P_{gk,p} \leq P_{gk,p}^{max} \quad (p \in \Omega_{\phi_k}) (k \in \Omega_B) \quad (7)$$

Os valores de tensões nodais não são restritos por serem estimados. Em relação as cargas e gerações distribuídas, conhecendo-se os valores nominais $P_{dk,p}^{nom}$, $Q_{dk,p}^{nom}$ e $P_{gk,p}^{nom}$, pode-se definir os limites como em (8)-(13) em que λ é um fator que permite modelar a incerteza da carga: $\lambda = 0,30$ indica que a carga pode variar 30% abaixo ou acima do valor nominal conhecido (de Oliveira et al., 2018). O valor nominal pode ser substituído por resultados provenientes de estudos de previsão de carga e geração: considerando modelos de previsão mais precisos, pode-se utilizar menores valores de λ .

$$P_{dk,p}^{min} = (1 - \lambda) \cdot P_{dk,p}^{nom} \quad (p \in \Omega_{\phi_k}) (k \in \Omega_B) \quad (8)$$

$$P_{dk,p}^{max} = (1 + \lambda) \cdot P_{dk,p}^{nom} \quad (p \in \Omega_{\phi_k}) (k \in \Omega_B) \quad (9)$$

$$Q_{dk,p}^{min} = (1 - \lambda) \cdot Q_{dk,p}^{nom} \quad (p \in \Omega_{\phi_k}) (k \in \Omega_B) \quad (10)$$

$$Q_{dk,p}^{max} = (1 + \lambda) \cdot Q_{dk,p}^{nom} \quad (p \in \Omega_{\phi_k}) (k \in \Omega_B) \quad (11)$$

$$P_{gk,p}^{min} = (1 - \lambda) \cdot P_{gk,p}^{nom} \quad (p \in \Omega_{\phi_k}) (k \in \Omega_B) \quad (12)$$

$$P_{gk,p}^{max} = (1 + \lambda) \cdot P_{gk,p}^{nom} \quad (p \in \Omega_{\phi_k}) (k \in \Omega_B) \quad (13)$$

2.3 Metodologia Proposta para a Estimação de Estados

Para a solução do problema descrito na seção anterior, nesse trabalho, utilizam-se métodos metaheurísticos populacionais capazes de fornecer soluções de boa qualidade em um tempo computacional reduzido (Yang, 2014).

As metaheurísticas a serem utilizadas nesse trabalho são: *Particle Swarm Optimization* (PSO), *Coyote Optimization Algorithm* (COA) e *Firefly Optimization Algorithm* (FOA). Os resultados obtidos por esses algoritmos serão comparados com os obtidos pelo Método de Pontos Interiores (MPI) considerando diferentes condições iniciais.

Neste trabalho, utiliza-se medidas provenientes de PMU (*Phasor Measurement Units*), a saber: fasores de tensões nodais e fasores de correntes nos ramos conectados à barra com PMU (Korres & Manousakis, 2011).

Cada indivíduo (do PSO, COA ou FOA) ou solução (do MPI) é representado(a) por um vetor de: (i) cargas ativas e reativas para cada fase das barras do sistema; (ii) gerações de potência ativa das barras com GD.

Para avaliação de cada indivíduo (cálculo da função aptidão) ou solução, utiliza-se o Fluxo de Potência Trifásico (FPT) do *software* OpenDSS (Dugan & McDermott, 2011). Como resultado, o OpenDSS retorna (considerando os valores de carga e geração dados pelo indivíduo) os fasores de tensões nodais e de correntes nos ramos. Com base nos valores obtidos, obtém-se o valor da função aptidão do indivíduo, usado pelo método de otimização.

Todos os métodos utilizados são para otimização com restrições, logo os limites das variáveis (5)-(7) são facilmente tratados. As restrições de igualdade (2)-(4) são tratadas

internamente pelo OpenDSS: em caso de divergência do fluxo de potência trifásico, a solução é penalizada. Em caso de convergência, a função aptidão é calculada conforme a equação (1).

2.4 Exemplo Ilustrativo

A Figura 1 apresenta um sistema ilustrativo de 3 barras com uma PMU na barra 2 e uma GD na barra 3.




Fig. 1 Sistema ilustrativo.

O vetor de variáveis de estado x (a ser estimado) é dado na equação (14):

$$x^T = [P_{d1,1} \quad P_{d1,2} \quad P_{d1,3} \dots P_{d3,1} \quad P_{d3,2} \quad P_{d3,3} \dots \\ \dots Q_{d1,1} \quad Q_{d1,2} \quad Q_{d1,3} \dots Q_{d3,1} \quad Q_{d3,2} \quad Q_{d3,3} \dots \\ \dots P_{g3,1} \quad P_{g3,2} \quad P_{g3,3}] \quad (14)$$

O vetor de medidas z é composto pelas medições de fasores de tensão na barra 2 e os fasores de corrente, conforme a equação (15).

$$z^T = [V_{2,1} \quad V_{2,2} \quad V_{2,3} \quad \theta_{2,1} \quad \theta_{2,2} \quad \theta_{2,3} \dots \\ \dots I_{2-1,1} \quad I_{2-1,2} \quad I_{2-1,3} \quad \varphi_{2-1,1} \quad \varphi_{2-1,2} \quad \varphi_{2-1,3} \dots \\ \dots I_{2-3,1} \quad I_{2-3,2} \quad I_{2-3,3} \quad \varphi_{2-3,1} \quad \varphi_{2-3,2} \quad \varphi_{2-3,3}] \quad (15)$$

em que o fasor de corrente na “fase” a do “ramo 2-1” é composto pelos valores de magnitude ($I_{2-1,1}$) e fase ($\varphi_{2-1,1}$). Ao se utilizar uma metaheurística para a solução do problema tem-se os seguintes passos que definem a interação desta com o OpenDSS:

1. Cada indivíduo representa uma estimativa para o vetor x dado em (14);
2. Para cada indivíduo executa-se o Fluxo de Potência Trifásico (FPT) do OpenDSS. As cargas do sistema e as gerações das unidades de GD são parâmetros de entrada do OpenDSS;
3. Com base nos valores convergidos do FPT (fasores de tensão e corrente) seleciona-se os de interesse para compor uma estimativa $h(x)$ do vetor de medições z^T dado em (15);
4. A função aptidão do indivíduo é calculada conforme dado em (1).

2.5 Breve Descrição das Metaheurísticas Utilizadas

O método *Particle Swarm Optimization* é inspirado no comportamento social de bandos de pássaros e cardumes de peixes na busca de alimento. Os indivíduos (partículas) se movem no espaço de busca com base na experiência própria (cognitiva) e do grupo (social) (Kennedy & Eberhart, 1995).

O *Coyote Optimization Algorithm* é inspirado no comportamento social da espécie *canis latrans*, em que os indivíduos (coiotes) evoluem tendo em vista a troca de experiência entre eles (Pierezan & Coelho, 2018).

O *Firefly Optimization Algorithm* é bioinspirado no comportamento dos vaga-lumes que emitem luz (de intensidade variável) durante o processo de busca por alimentos (Yang, 2009).

Todos os métodos utilizados foram implementados na plataforma MatLab (versão 2010a). Para comparação, um método numérico (Método dos Pontos Interiores) existente na função *fmincon* da *toolbox* de otimização do MatLab também foi utilizado para a solução do problema.

3. RESULTADOS

3.1 Descrição do Sistema

A rede de teste de 13 barras do IEEE será utilizada nesse trabalho para avaliação da metodologia desenvolvida. Ilustrado na Figura 2, o sistema é conhecido por sua pequena dimensão, apresentando, contudo, características pertinentes para análise de sistemas de distribuição. É uma rede relativamente carregada, contendo um regulador de tensão na subestação, ramais monofásicos, bifásicos e trifásicos, linhas aéreas e subterrâneas desbalanceadas, dois bancos de capacitores shunt, dois transformadores trifásicos e cargas desequilibradas (Schneider et al., 2018).




Fig. 2 Sistema de 13 barras.

O sistema foi modificado através da inclusão de 3 unidades de Geração Distribuída com fator de potência unitário, nas barras: 652 (500 kW), 671 (1100 kW) e 692 (1000 kW) (Coelho et al., 2020).

3.2 Plano de Medição

Foram consideradas 2 PMU no sistema (barras 632 e 671). Tais barras estão no ramal principal do sistema, motivando a escolha destas. O plano de medição é apresentado na Tabela 1 (observa-se a existência de medições em ramos bifásicos). A partir da solução do Fluxo de Potência via o OpenDSS foram gerados os valores de medições, considerando um erro de 1%

para todas as medidas (haja vista que são todas provenientes das PMU) (Jabr et al., 2009).

Tabela 1. Plano de medição

Medidas de Tensão
$V_{632,p}, \theta_{632,p} \quad p = \{1,2,3\}$
$V_{671,p}, \theta_{671,p} \quad p = \{1,2,3\}$
Medidas de Corrente
$I_{632-645,p}, \varphi_{632-645,p} \quad p = \{2,3\}$
$I_{632-633,p}, \varphi_{632-633,p} \quad p = \{1,2,3\}$
$I_{632-670,p}, \varphi_{632-670,p} \quad p = \{1,2,3\}$
$I_{632-650,p}, \varphi_{632-650,p} \quad p = \{1,2,3\}$
$I_{671-684,p}, \varphi_{671-684,p} \quad p = \{1,3\}$
$I_{671-680,p}, \varphi_{671-680,p} \quad p = \{1,2,3\}$
$I_{671-692,p}, \varphi_{671-692,p} \quad p = \{1,2,3\}$
$I_{671-670,p}, \varphi_{671-670,p} \quad p = \{1,2,3\}$

Considera-se que as cargas e gerações podem variar $\pm 30\%$ em relação ao valor nominal ($\lambda = 0,30$).

3.3 Parâmetros de Simulação

Para os métodos metaheurísticos foram considerados, após testes visando baixa esforço computacional e soluções de boa qualidade, 50 indivíduos e 50 gerações. Os outros parâmetros (devidamente definidos nas referências de cada método) são:

- i. *Coyote Optimization Algorithm*: 10 packs (matilhas) com 5 coiotes cada;
- ii. *Particle Swarm Optimization*: constantes de aceleração igual a 2 e constante de inércia decrescente de 0,9 a 0,4;
- iii. *Firefly Optimization Algorithm*: parâmetro de randomização (α) igual a 0,25, constante de atratividade inicial (β_0) igual a 0,20 e coeficiente de absorção (γ) igual a 1;
- iv. *Método Numérico (Método dos Pontos Interiores)*: tolerância de 0,0001 para convergência.

Para efeitos de comparação, cada método foi executado 50 vezes considerando diferentes condições iniciais (geradas no interior do espaço de busca).

3.4 Estimativa das Cargas

Considerando as 50 simulações realizadas, as Figuras 3 a 7 apresentam o *boxplot* para algumas grandezas do sistema, tais como: cargas ativa e reativa na barra 671 (a mais carregada) e as gerações de potências nas GDs. As demais grandezas não foram ilustradas por questões de espaço. A linha tracejada indica o valor exato (nominal) da grandeza. O primeiro ponto a ser analisado refere-se à mediana (linha vermelha no interior da caixa), que indica o valor em que 50% das simulações são maiores que ele. O segundo ponto é a variabilidade das soluções.

O valor de todas as cargas de potência ativa (considerando a mediana de todas as simulações) são apresentadas nas Tabelas 2 a 4. A demanda de potência reativa não foi apresentada por questões de espaço. Por fim, a Tabela 5 apresenta os valores de potência das GD.




Fig. 3 Demanda de Potência Ativa – 671.1.2.3 (kW).

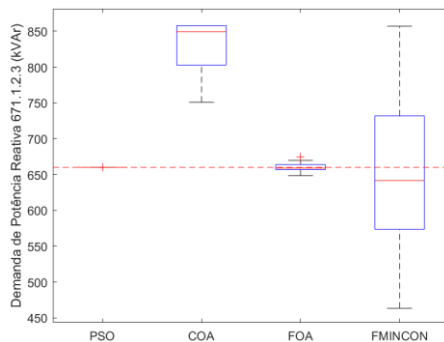


Fig. 4 Demanda de Potência Reativa – 671.1.2.3 (kVAr).




Fig. 5 Geração de Potência Ativa (kW) – GD1 (552).

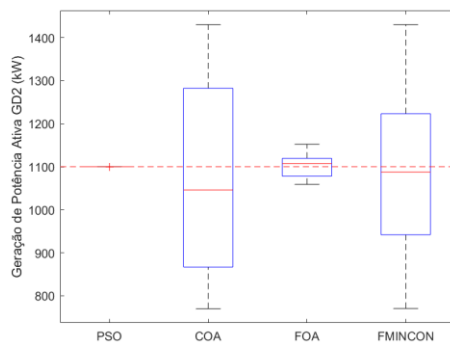


Fig. 6 Geração de Potência Ativa (kW) – GD2 (671).

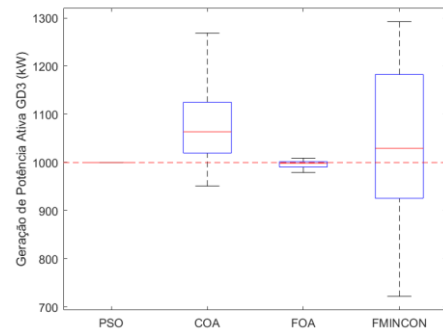


Fig. 7 Geração de Potência Ativa (kW) – GD3 (692).

Tabela 2. Demandas de potência ativa estimadas (kW) – Parte 1

Método	671.1.2.3	634.1	634.2	364.3	645.2
Nominal	1155	160	120	120	170
PSO	1154,98	160,00	120,00	120,00	170,00
COA	1157,19	196,97	153,65	147,86	214,00
FOA	1160,16	160,26	119,72	119,14	170,10
<i>fmincon</i>	1209,48	156,49	118,45	121,45	166,71

Tabela 3. Demandas de potência ativa estimadas (kW) – Parte 2

Método	646.2.3	692.3.1	675.1	675.2	675.3
Nominal	230	170	485	68	290
PSO	230,00	170,01	485,04	68,00	290,01
COA	295,58	148,83	611,87	52,75	365,00
FOA	231,63	167,98	485,90	67,64	291,19
<i>fmincon</i>	225,77	187,39	513,96	69,35	288,37

Tabela 4. Demandas de potência ativa estimadas (kW) – Parte 3

Método	611.3	652.1	670.1	670.2	670.3
Nominal	170	128	17	66	117
PSO	170,00	128,00	17,00	66,00	117,00
COA	208,12	141,39	18,22	70,23	115,47
FOA	169,67	128,43	16,95	66,78	116,86
<i>fmincon</i>	167,18	127,52	16,79	67,90	119,82

Tabela 5. Gerações de potência ativa (kW)

Método	GD1	GD2	GD3
Nominal	500	1100	1000
PSO	500,00	1099,99	999,99
COA	446,92	1046,01	1063,73
FOA	500,22	1107,42	998,44
<i>fmincon</i>	524,38	1087,70	1029,33

3.5 Discussão

Com base nos resultados apresentados, observa-se que o PSO apresentou melhores resultados, com mediana próxima ao valor nominal e com baixa variabilidade, justificando o seu uso no processo de estimação de estados. Em ordem decrescente de qualidade, observa-se o FOA, COA e o método numérico implementado na função *fmincon*.

A justificativa para o bom comportamento do PSO e o FOA é o mecanismo de busca global (exploração do espaço de busca) implementado nesses algoritmos. O COA, embora também tenha um bom mecanismo de busca global, precisa ser

melhorado. O método numérico do *fmincon* é baseado em derivadas: embora apresente rápida convergência é extremamente sensível à condição inicial e não possui mecanismos de busca global.

A Tabela 6 apresenta o tempo médio de simulação em um computador Intel Core i3 2.00 GHz com 4GB de RAM e Sistema operacional Windows 10 64-bit. Observa-se que o Método Numérico de Pontos Interiores baseado na função *fmincon* apresentou o menor tempo, o que é justificado pelo uso de derivadas que aceleram o processo de busca. Entretanto, é um método sensível às condições iniciais, apresentando resultados de baixa qualidade nesse trabalho. Por fim, o PSO apresentou um tempo computacional de 1,39 minutos para o processo de estimação. Esse tempo pode ser reduzido pela aplicação de computação paralela e ajuste do número de indivíduos/gerações que reduza o esforço computacional sem deteriorar a qualidade das soluções.

Tabela 6. Tempo médio de simulação (min)

PSO	COA	FOA	<i>fmincon</i>
1,39	1,58	3,07	0,16

4. CONCLUSÕES

O presente trabalho apresentou uma metodologia de otimização para a estimação de estados em sistemas de distribuição trifásicos desequilibrados em que: (i) as variáveis de estado são as demandas de potência e as gerações de potência das unidades de geração distribuída; (ii) medidas fasoriais de tensão e corrente em pontos estratégicos são utilizadas; (iii) quatro metaheurísticas foram empregadas e comparadas com um método numérico baseado em derivadas; (iv) o *software* OpenDSS (consolidado e amplamente utilizado na academia e nas empresas do setor de energia elétrica) foi adotado para avaliação das soluções durante o processo de solução.

O estudo de caso para o sistema IEEE 13 barras mostrou a aplicabilidade do método bem como as soluções de boa qualidade fornecidas pelo *Particle Swarm Optimization* e o *Firefly Optimization Algorithm*, sendo que esse último consumiu maior tempo computacional. Foi verificado, considerando um conjunto de 50 simulações, que o PSO apresentou resultados com baixa variabilidade e muito próximos aos nominais. Observou-se também que o método numérico é extremamente sensível às condições iniciais.

Os trabalhos futuros estarão focados: (i) na redução do tempo computacional (através de técnica de computação paralela); (ii) testes em outros sistemas; e (iii) avaliação de outras metaheurísticas.

AGRADECIMENTOS

Os autores agradecem à FAPEMIG, CAPES (Finance Code 001), CNPq e PPGEL/UFSJ pelo auxílio financeiro. Agradecimentos ao Programa de Iniciação Científica PIBIC/CNPq também são prestados.

REFERÊNCIAS

Abur, A., & Exposito, A. G. (2004). *Power System State Estimation: Theory and Implementation* (1s ed.). CRC Press.

Ahmad, F., Rasool, A., Ozsoy, E., Sekar, R., Sabanovic, A., & Elitaş, M. (2018). Distribution system state estimation- A step towards smart grid. *Renewable and Sustainable Energy Reviews*, 81, 2659–2671. <https://doi.org/10.1016/j.rser.2017.06.071>

Baran, M. E., & Kelley, A. W. (1994). State estimation for real-time monitoring of distribution systems. *IEEE Transactions on Power Systems*, 9(3), 1601–1609. <https://doi.org/10.1109/59.336098>

Baran, M. E., & Kelley, A. W. (1995). A branch-current-based state estimation method for distribution systems. *IEEE Transactions on Power Systems*, 10(1), 483–491. <https://doi.org/10.1109/59.373974>

Coelho, F. ., Peres, W. ., Silva Júnior, I. C. ., & Dias, B. H. (2020). Empirical continuous metaheuristic for multiple distributed generation scheduling considering energy loss minimisation, voltage and unbalance regulatory limits. *IET Generation, Transmission & Distribution*, 14(16), 3301–3309. <https://doi.org/10.1049/iet-gtd.2019.1860>

de Oliveira, B. C., Pereira, J. L. R., de O. Alves, G., Melo, I. D., de Souza, M. A., & Garcia, P. A. N. (2018). Decentralized three-phase distribution system static state estimation based on phasor measurement units. *Electric Power Systems Research*, 160, 327–336. <https://doi.org/10.1016/j.epsr.2018.03.010>

Dehghanpour, K., Wang, Z., Wang, J., Yuan, Y., & Bu, F. (2019). A Survey on State Estimation Techniques and Challenges in Smart Distribution Systems. *IEEE Transactions on Smart Grid*, 10(2), 2312–2322. <https://doi.org/10.1109/TSG.2018.2870600>

Dugan, R. C., & McDermott, T. E. (2011). An open source platform for collaborating on smart grid research. *2011 IEEE Power and Energy Society General Meeting, Ipv*, 1–7. <https://doi.org/10.1109/PES.2011.6039829>

Huang, Y.-F., Werner, S., Huang, J., Kashyap, N., & Gupta, V. (2012). State Estimation in Electric Power Grids: Meeting New Challenges Presented by the Requirements of the Future Grid. *IEEE Signal Processing Magazine*, 29(5), 33–43. <https://doi.org/10.1109/MSP.2012.2187037>

Jabr, R. A., Pal, B. C., & Singh, R. (2009). Choice of estimator for distribution system state estimation. *IET Generation, Transmission & Distribution*, 3(7), 666–678. <https://doi.org/10.1049/iet-gtd.2008.0485>

Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. *Neural Networks, 1995. Proceedings., IEEE International Conference On*, 4, 1942–1948 vols.4–1948 4.

Korres, G. N., & Manousakis, N. M. (2011). State estimation

and bad data processing for systems including PMU and SCADA measurements. *Electric Power Systems Research*, 81(7), 1514–1524. <https://doi.org/10.1016/j.epsr.2011.03.013>

- Nanchian, S., Majumdar, A., & Pal, B. C. (2017). Three-Phase State Estimation Using Hybrid Particle Swarm Optimization. *IEEE Transactions on Smart Grid*, 8(3), 1035–1045. <https://doi.org/10.1109/TSG.2015.2428172>
- Pau, M., Pegoraro, P. A., & Sulis, S. (2013). Efficient Branch-Current-Based Distribution System State Estimation Including Synchronized Measurements. *IEEE Transactions on Instrumentation and Measurement*, 62(9), 2419–2429. <https://doi.org/10.1109/TIM.2013.2272397>
- Peres, W., Pereira, J. L. R., Passos Filho, J. A., & Alves, G. O. (2014). Branch current based state estimation: Equality-constrained wls and augmented matrix approaches. *XX Congresso Brasileiro de Automática*, 3198–3205.
- Pierezan, J., & Coelho, L. S. (2018). Coyote Optimization Algorithm: A New Metaheuristic for Global Optimization Problems. *2018 IEEE Congress on Evolutionary Computation, CEC 2018 - Proceedings*, 7–14. <https://doi.org/10.1109/CEC.2018.8477769>
- Schneider, K. P., Mather, B. A., Pal, B. C., Ten, C.-W., Shirek, G. J., Zhu, H., Fuller, J. C., Pereira, J. L. R., Ochoa, L. F., de Araujo, L. R., Dugan, R. C., Matthias, S., Paudyal, S., McDermott, T. E., & Kersting, W. (2018). Analytic Considerations and Design Basis for the IEEE Distribution Test Feeders. *IEEE Transactions on Power Systems*, 33(3), 3181–3188. <https://doi.org/10.1109/TPWRS.2017.2760011>
- Tungadio, D. H., Numbi, B. P., Siti, M. W., & Jimoh, A. A. (2015). Particle swarm optimization for power system state estimation. *Neurocomputing*, 148, 175–180. <https://doi.org/10.1016/j.neucom.2012.10.049>
- Yang, X.-S. (2009). *Firefly Algorithms for Multimodal Optimization* (pp. 169–178). https://doi.org/10.1007/978-3-642-04944-6_14
- Yang, X.-S. (Ed.). (2014). Nature-Inspired Optimization Algorithms. In *Nature-Inspired Optimization Algorithms* (p. i). Elsevier. <https://doi.org/https://doi.org/10.1016/B978-0-12-416743-8.00016-6>