

Metodologia de Estimação de Estados de Redes de Distribuição com Penetração de Energia Fotovoltaica^{*}

Thales S. de Almeida^{*} Elisa Oliveira^{**} Pedro C. Fracetti^{***}
Arthur N. de Paula^{****} Leonardo W. de Oliveira[†]
Edimar J. de Oliveira[‡]

^{*} Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: thales.schuabb@engenharia.ufjf.br)

^{**} Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: elisa.oliveira@engenharia.ufjf.br)

^{***} Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: caruso.fracetti@engenharia.ufjf.br)

^{****} Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: arthur.paula@engenharia.ufjf.br)

[†] Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: leonardo.willer@ufjf.edu.br)

[‡] Faculdade de Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: edimar.oliveira@ufjf.edu.br)

Abstract: The present work proposes the association of a state estimator with the technique for generating scenarios known as k-means, with the objective of evaluating the impact of the photovoltaic distributed generation in the problem of state estimation of active distribution networks. The method known as E-OPF of literature, which is based on an optimal power flow, is used in the state estimator, aiming at including in an efficient manner the uncertainties inherent to the photovoltaic generation. Monte Carlo Simulation is used to compare and validate the results obtained from the application of the proposed approach to a test system of literature comprising three photovoltaic plants.

Resumo: O presente trabalho propõe a associação de um estimador de estados com a técnica de geração de cenários denominada k-means, com o objetivo de avaliar o impacto da geração distribuída fotovoltaica no problema de estimação de redes de distribuição ativas. O método denominado E-OPF da literatura, baseado em fluxo de potência ótimo, é utilizado no estimador de estados, a fim de incluir de forma eficiente as incertezas inerentes à geração fotovoltaica. Simulação de Monte Carlo é utilizada para comparação e validação dos resultados, a partir da aplicação da metodologia proposta a um sistema teste da literatura envolvendo três usinas fotovoltaicas.

Keywords: State Estimation; Photovoltaic; Impact; k-means; Distribution System.

Palavras-chaves: Estimação de Estados; Fotovoltaico; Impacto; k-means; Sistema de Distribuição.

1. INTRODUÇÃO

O avanço tecnológico dos últimos anos resultou em expansão e desenvolvimento dos Sistemas Elétricos de Potência (SEP), sobretudo os Sistemas de Distribuição (SDE). Diante deste fato, faz-se necessário o estudo de novas tecnologias para melhorar o monitoramento do estado da rede elétrica (Schweppe and Rom, 1970) a fim de tornar a operação do sistema de distribuição mais flexível e eficiente (Ahmad et al., 2019).

Para tanto, uma alternativa que tem sido investigada é a Estimação de Estados (EE), que visa determinar, da

forma mais aproximada possível, o estado de uma rede elétrica, a partir de um conjunto de medidas disponíveis. Neste sentido, quanto maior a disponibilidade de medidas, melhor é a estimativa obtida. Medidas on-line, como as obtidas através de sistemas SCADA, equipamentos eletrônicos inteligentes, e até mesmo Unidades de Medição Fasorial (UMF) (Qing et al., 2015), (Yang et al., 2012), podem ser utilizadas.

Um dos desafios para a estimação de estados é encontrado quando há pouca disponibilidade de medidas (Korres and Manousakis, 2012), o que pode ocorrer em sistemas de distribuição de energia elétrica. Para contornar tal dificuldade, uma opção é a utilização de técnicas como, por exemplo, a definição de pseudo-medidas (Chilard et al.,

^{*} Os autores deste artigo agradecem ao apoio da FAPEMIG, CNPq, CAPES, INERGE, e ao Grupo de Otimização GOPT.

2009), (Shen and Liang, 2013). Portanto, a estimação de estados de sistemas de distribuição consiste em um problema desafiador.

No cenário atual, a geração distribuída (GD), representada por recursos renováveis de energia distribuídos na rede elétrica, tem recebido atenção devido à crescente penetração em SDE. A GD configura entre 15% e 20%, aproximadamente, do total da energia elétrica produzida no mundo (F. Shabaninia and Vaziri, 2012). Entre as fontes de GD, a energia fotovoltaica vem ganhando grande visibilidade no Brasil. Porém, a GD resulta em alguns problemas para o SDE, como a dificuldade de sua previsibilidade, tornando a análise destes sistemas mais complexa e substancial (Li et al., 2019).

Na literatura especializada, o impacto da energia fotovoltaica em SE tem sido investigado. Em (Dehghanpour et al., 2019), os futuros impactos e desafios da alta inserção de energia renovável no sistema são discutidos, considerando um monitoramento da rede elétrica com suporte de estimação de estado. Destaca-se que a alta inserção de fontes renováveis afeta o perfil de tensão do SDE, requerendo um monitoramento mais avançado.

Em (Cheng et al., 2019), um método de estimação de estados para redes de distribuição ativas é proposto, com base na previsão de energia fotovoltaica, onde são realizadas medições em tempo real coletadas pelo sistema SCADA. Pseudo-medidas e medições virtuais são usadas para estimar o estado da rede, usando o algoritmo de Mínimos Quadrados Ponderados (MQP).

O presente trabalho propõe a aplicação de uma metodologia de estimação de estados associada a uma técnica de geração de cenários para representar o comportamento de GD fotovoltaica no sistema. Os cenários referem-se à irradiação solar, cuja característica é estocástica, gerados a partir de uma série de agrupamentos através do algoritmo k-means (MacQueen et al., 1967). A metodologia de estimação de estados (E-OPF) é recente na literatura e baseia-se em um modelo de fluxo de potência ótimo modificado (Duque et al., 2017). Esta metodologia acomoda o elevado nível de incerteza de SDE, incluindo de geração fotovoltaica. A principal contribuição deste artigo é representar o impacto da geração fotovoltaica no problema de estimação de estados, através de um número reduzido de cenários, proporcionado pelo algoritmo k-means. Testes realizados com um sistema de 33 barras da literatura, envolvendo três usinas solares fotovoltaicas, comprovam a eficácia da metodologia integrada proposta, associando o método E-OPF ao algoritmo k-means. Para esta comprovação, utiliza-se o a Simulação de Monte Carlo (SMC), amplamente divulgada para problemas envolvendo variáveis aleatórias, como a irradiação solar.

2. METODOLOGIA PROPOSTA

A metodologia proposta para resolver a EE do sistema de distribuição com geração de energia fotovoltaica é descrita nas subseções abaixo, onde será apresentado como os cenários de potência foram gerados e a formulação do estimador de estado.

2.1 Geração de Cenários de Potência Fotovoltaica

Para inserir a potência das usinas solares no modelo E-OPF, é necessário gerar cenários probabilísticos de irradiação. Dessa forma, este artigo propõe o uso de um modelo estocástico de operação de parques solares fotovoltaicos para representar o comportamento intermitente e a correlação fotovoltaica de três parques solares de regiões distintas. O modelo estocástico é obtido pelo agrupamento de dados históricos de despacho de energia fotovoltaica por meio do algoritmo de agrupamento k-means. Para isso, são utilizados dados históricos de um mês de irradiação solar discretizados em minutos (INPE, 2019). A partir dos dados de irradiação obtêm-se a potência de saída do módulo fotovoltaico conforme apresentados por Atwa et al. (2009). Os dados foram medidos no mesmo período, essa peculiaridade permite incluir a correlação da irradiação entre as regiões, proporcionando uma análise mais realista.

A técnica k-means (MacQueen, 1967) agrupa os dados em clusters K , minimizando a distância entre as observações (dados horários) pertencentes a um cluster e seu centróide. Dessa forma, os centróides são usados como cenários de expedição de parques solares fotovoltaicos e o número de observações agrupadas fornece a probabilidade de ocorrência do cenário. As principais etapas do algoritmo k-means aplicadas à geração de cenário são brevemente descritas abaixo.

- Etapa 1:** Leitura da série histórica de irradiação. Para as três séries utilizadas, cada observação (ponto) é representada por um vetor tridimensional representando um despacho correlato de geradores de energia fotovoltaica;
- Etapa 2:** Obtêm uma amostragem aleatória da série para representar os K centróides da primeira iteração;
- Etapa 3:** Medição da distância euclidiana entre cada dado e cada centróide;
- Etapa 4:** Uma observação é atribuída para pertencer ao grupo representado pelo centróide mais próximo;
- Etapa 5:** Atualização do centróide dos grupos usando o valor médio de suas observações;
- Etapa 6:** Cálculo da probabilidade dos cenários;
- Etapa 7:** Verificação do critério de convergência interrompendo o k-means se as observações de cada grupo estiverem estabilizadas. Se os centróides alteraram seus valores na Etapa 5, vá para a Etapa 3 para executar outra iteração k-means.

2.2 Método de Estimação de Estados

No modelo E-OPF proposto em (Duque et al., 2017), as variáveis de estado da rede a serem estimadas são definidas em coordenadas polares. Portanto, as variáveis de otimização envolvem as estimativas do estado da rede \hat{x} , incluindo módulo e ângulo de fase das tensões, como (1).

$$\hat{x} = [\hat{\theta}_k, \hat{\theta}_{k+1}, \dots, \hat{\theta}_{Nb}, \hat{V}_k, \hat{V}_{k+1}, \dots, \hat{V}_{Nb}] \quad (1)$$

Onde:

- \hat{x} Vetor das variáveis estimadas;
- \hat{V}_k Módulo de tensão estimada para a barra k ;

$\hat{\theta}_k$ Ângulo de fase de tensão estimada para a barra k ;
 Nb Número de barras do sistema.

O vetor dos valores medidos x^* é obtido a partir dos fasores de tensão obtidos através de UMFs. A localização e o número de UMFs a serem usadas na rede são definidos pela busca exaustiva do modelo E-OPF. Medidas convencionais do sistema SCADA, simultâneas às provenientes de UMFs, também podem ser usadas em x^* , o que estende a aplicabilidade da metodologia. Entretanto, a metodologia proposta não contempla medidas obtidas em instantes de tempo distintos, como em (S. Huang and Lo, 2015).

A partir das medições disponíveis, o E-OPF proposto para estimar o estado do sistema de distribuição é formulado de (2) a (12), onde as variáveis estimadas $\hat{\theta}_k$ e \hat{V}_k são tratados como variáveis de otimização independentes, conforme mostrado a seguir:

$$FOB = \min [x^* - h(\hat{x})]^T W^{-1} [x^* - h(\hat{x})] \quad (2)$$

Sujeito a:

$$\hat{P}g_k + \hat{P}f_k^i - \hat{P}l_k + \sum_{m \in \Omega_k} \hat{p}_{km} = 0 \quad (3)$$

$$\hat{Q}g_k + \hat{Q}f_k^i - \hat{Q}l_k + \sum_{m \in \Omega_k} \hat{q}_{km} = 0 \quad (4)$$

$$\hat{p}_{km} = \hat{V}_k^2 g_{km} - \hat{V}_k \hat{V}_m g_{km} \cos(\hat{\theta}_k - \hat{\theta}_m) - \hat{V}_k \hat{V}_m b_{km} \sin(\hat{\theta}_k - \hat{\theta}_m) \quad (5)$$

$$\hat{q}_{km} = \hat{V}_k^2 (b_{km} - b_{km}^{sh}) + \hat{V}_k \hat{V}_m b_{km} \cos(\hat{\theta}_k - \hat{\theta}_m) - \hat{V}_k \hat{V}_m g_{km} \sin(\hat{\theta}_k - \hat{\theta}_m) \quad (6)$$

$$\hat{I}_{km} = \sqrt{(g_{km}^2 + b_{km}^2)(\hat{V}_k^2 + \hat{V}_m^2 - 2\hat{V}_k \hat{V}_m \cos(\hat{\theta}_k - \hat{\theta}_m))} \quad (7)$$

$$\hat{P}l_{min_k} \leq \hat{P}l_k \leq \hat{P}l_{max_k} \quad (8)$$

$$\hat{Q}l_{min_k} \leq \hat{Q}l_k \leq \hat{Q}l_{max_k} \quad (9)$$

$$0 \leq \hat{P}g_k \leq \hat{P}g_{max_k} \quad (10)$$

$$\hat{Q}g_{min_k} \leq \hat{Q}g_k \leq \hat{Q}g_{max_k} \quad (11)$$

$$\hat{V}_{min_k} \leq \hat{V}_k \leq \hat{V}_{max_k} \quad (12)$$

Onde:

x^*	Vetor de valores medidos;
$h(\hat{x})$	Função não linear de equações do modelo de rede que relaciona as variáveis de estado com as medidas;
W	Matriz de covariância de erros de medição;
$\hat{P}g_k, \hat{Q}g_k$	Gerações de potência ativa e reativa na barra k , respectivamente;
$\hat{P}f_k^i, \hat{Q}f_k^i$	Energia fotovoltaica ativa e reativa gerada na barra k no cenário i , respectivamente;
$\hat{P}l_k, \hat{Q}l_k$	Demanda de carga ativa e reativa na barra k , respectivamente;
$\hat{p}_{km}, \hat{q}_{km}$	Fluxo de potência ativa e reativa no trecho km , respectivamente;
\hat{I}_{km}	Corrente no trecho km ;

Ω_k	Conjunto de barras adjacentes, conectadas por trechos de distribuição, à barra k ;
y_{km}, g_{km}, b_{km}	Admitância, condutância e susceptância do trecho km , respectivamente;
$\hat{P}l_{min_k}, \hat{P}l_{max_k}$	Limites inferior e superior da demanda de carga ativa na barra k , respectivamente;
$\hat{Q}l_{min_k}, \hat{Q}l_{max_k}$	Limites inferior e superior da demanda de carga reativa na barra k , respectivamente;
$\hat{P}g_{max_k}$	Limite superior da geração de potência ativa na barra k ;
$\hat{Q}g_{min_k}, \hat{Q}g_{max_k}$	Limites inferior e superior da geração de potência reativa na barra k , respectivamente;
$\hat{V}_{min_k}, \hat{V}_{max_k}$	Limites inferior e superior da tensão estimada, respectivamente.

A função objetivo (FOB) dada por (2) minimiza os erros ou resíduos ponderados associados às medições, ou seja, a diferença entre as medições e seus respectivos valores calculados usando as equações $h(\hat{x})$. Essa FOB é amplamente utilizada na formulação WLS (Wood et al., 2013). A potência fotovoltaica não está incluída na FOB, sendo considerada na modelagem do E-OPF como injeções de potência ativa e reativa nas barras terminais.

Os balanços de potência ativa e reativa são dados pelas equações (3) e (4), respectivamente. As restrições de (3) a (7) são derivadas das equações de potência para um trecho de rede de distribuição, correspondente ao modelo não linear completo de rede para sistemas de alta/média tensão.

Pode-se destacar que os fluxos de potência \hat{p}_{km} e \hat{q}_{km} e as potências geradas $\hat{P}g_k$ e $\hat{Q}g_k$ também são estimadas pelo modelo, pois são funções das variáveis de estado do E-OPF, $\hat{\theta}_k$ e \hat{V}_k . Da mesma forma, \hat{I}_{km} também é estimado pelo modelo a partir de \hat{p}_{km} e \hat{q}_{km} , bem como das equações genéricas da rede. As restrições (8) a (12) representam os limites inferior e superior das variáveis do modelo.

A principal vantagem do E-OPF é a representação da carga ativa ($\hat{P}l_k$) e reativa ($\hat{Q}l_k$) como variáveis de estado, conforme equações (3) e (4) (Duque et al., 2017). Estas variáveis são propostas dentro dos limites $[\hat{P}l_{min_k}, \hat{P}l_{max_k}]$ e $[\hat{Q}l_{min_k}, \hat{Q}l_{max_k}]$, que são definidos em função de variações admitidas na literatura para pseudo-medidas de carga ativa e reativa. Desta forma, dados históricos ou curvas de carga agregadas podem ser usadas para definir estes limites, cuja abertura entre os valores mínimo e máximo é relativamente grande, retratando a imprecisão da carga. Com isto, as variáveis ($\hat{P}l_k$) e reativa ($\hat{Q}l_k$) excursionam dentro de uma região ampla, sem a necessidade de medições precisas nas barras, o que atende aos requisitos da distribuição, seguindo curvas normais de probabilidades, e o E-OPF busca, de forma eficiente através do Método de Pontos Interiores, o ponto de mínimo desvio entre o valor convergido destas variáveis e os respectivos valores em função do modelo de rede e demais medidas disponíveis.

Medidas virtuais são tratadas como sendo 100% precisas como, por exemplo, os valores de $\hat{P}l_k$ e $\hat{Q}l_k$ em barras com

ausência de carga (barras de passagem). A representação da potência fotovoltaica, por sua vez, como variável a ser estimada, não é adequada, já que a irradiação solar apresenta característica intermitente. Portanto, no presente trabalho, a irradiação solar é representada conforme descrito na subseção 2.1.

2.3 Algoritmo Proposto

As principais etapas para avaliar a estimativa de estado proposta neste trabalho são apresentadas pelo fluxograma da Figura 1 e descritas sucintamente para facilitar o entendimento do método.

- Etapa 1:** Define o cenário K e a probabilidade correspondente a serem incluídos no E-OPF e no fluxo de potência (PF);
- Etapa 2:** Executa o fluxo de potência com a geração dos três parques solares representada pelo cenário K;
- Etapa 3:** Obtém as medidas feitas através das UMFs;
- Etapa 4:** Resolve o E-OPF com a geração dos três parques solares representadas pelo cenário K;
- Etapa 5:** Armazena o estado da rede, \hat{V}_k e $\hat{\theta}_k$, para o cenário K;
- Etapa 6:** Verifica se todos os cenários foram avaliados. Se não, avalia o próximo cenário. Caso contrário, vá para a Etapa 7;
- Etapa 7:** Calcula o valor esperado da variável de estimativa, conforme descrito em (13).

$$\hat{V}_E = \sum_{k=1}^N (\hat{V}_k \cdot \rho_k) \quad \hat{\theta}_E = \sum_{k=1}^N (\hat{\theta}_k \cdot \rho_k) \quad (13)$$

Onde:

- \hat{V}_E Módulo de tensão estimada ponderada;
- $\hat{\theta}_E$ Ângulo de fase de tensão estimada ponderada;
- N Número de cenários;
- ρ_k Probabilidade do cenário k.

Para cada cenário K, o E-OPF é executado e as variáveis estimadas são ponderadas pela probabilidade de ocorrência do cenário. Para fins comparativos, os resultados do FP também são ponderados pelas probabilidades.

3. RESULTADOS

Aplicando a metodologia proposta ao sistema de 33 barras dado por Baran and Wu (1989), cuja topologia pode ser vista na Figura 2, é possível averiguar o comportamento da rede com a penetração de potência fotovoltaica. Nesta seção, são detalhados os resultados obtidos.

Três unidades fotovoltaicas, de potência nominal de 2 MW cada, foram alocadas nas barras 5, 14 e 27. Dados históricos de irradiação concentrados em 10 cenários diferentes, cujas probabilidades são dadas pelo método k-means, são utilizados na simulação. A Tabela 1 mostra os cenários, suas respectivas probabilidades, bem como a potência em cada unidade geradora, em MW.

Medições de módulo e ângulo de fase de tensão são disponíveis nas barras 33 (subestação), 2 e 22. Erros de 0,4% para módulo, e 0,8% para o ângulo, são inseridos

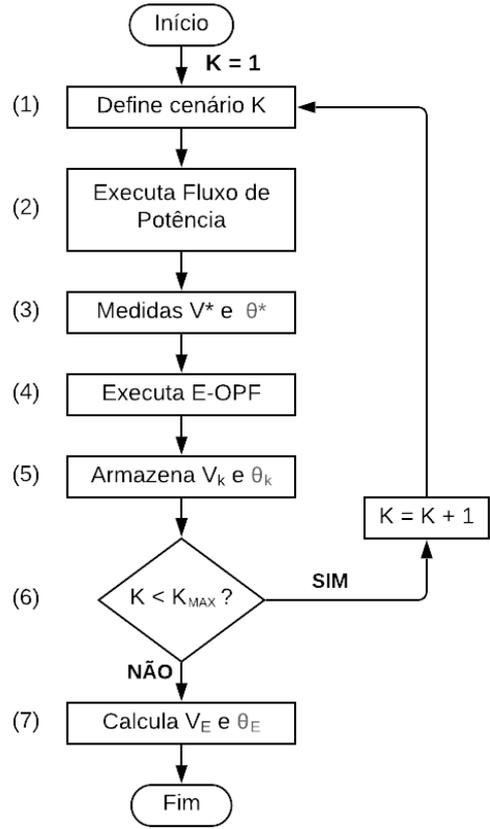


Figura 1. Fluxograma da metodologia proposta.

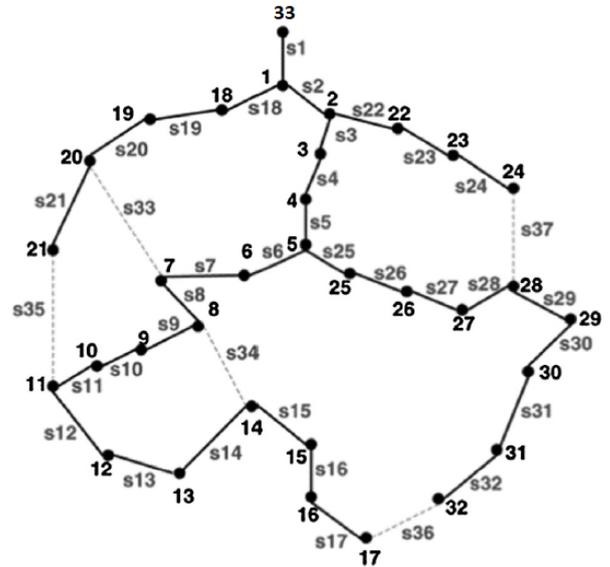


Figura 2. Sistema de Distribuição de 33 Barras.

nas medidas, seguindo Gomez-Exposito and Abur (2004). Destaca-se as medidas na barra 33 podem ser consideradas como provenientes de sistema SCADA, enquanto que as medidas em '2' e '22' podem ser associadas a UMFs instaladas nestas barras. Erros entre +40% e -40% também são considerados para as cargas nas barras.

Simulando cada cenário separadamente, é obtido o módulo de tensão nas barras para cada cenário, que pode ser vista na Figura 3.

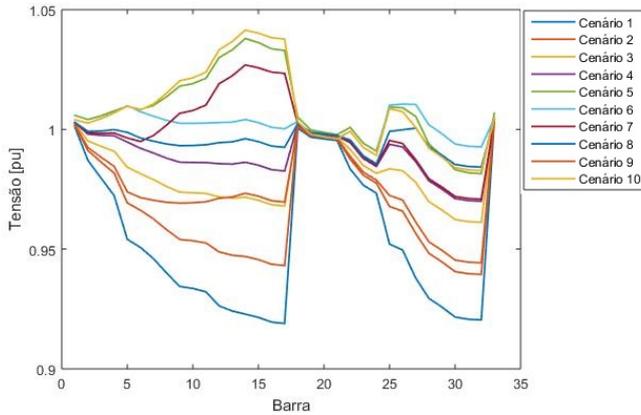


Figura 3. Módulo de tensão estimada para cada cenário

A fim de avaliar a penetração de potência fotovoltaica na estimativa de tensões do sistema, os valores estimados são comparados com o resultado do Fluxo de Potência (FP) do sistema, que é considerado como fonte de referência para a realização do presente estudo. Cada cenário gerado por k-means é submetido ao FP e ao E-OPF, e seu resultado é ponderado de acordo com sua probabilidade de ocorrência.

As figuras Figura 4 e Figura 5 mostram o resultado para os 10 cenários da Tabela 1 já ponderados. Os valores estimados são comparados com os valores de referência obtidos do FP, e demonstram satisfatória precisão.

Com o intuito de validar a metodologia proposta, foi realizada uma Simulação de Monte Carlo como referência. 5000 amostras da série histórica de irradiação solar foram tomadas aleatoriamente, e submetidas ao E-OPF e FP para comparação. A Figura 6 retrata a convergência da SMC e a obtenção do valor da FOB.

Para validar a eficiência do número de clusters dado por k-means, outra simulação, com 200 cenários, foi realizada. A Tabela 2 mostra a comparação entre o valor da FOB calculado para 10 e 200 cenários utilizando k-means, além do resultado da SMC.

Tomando a Simulação de Monte Carlo como referência, é possível constatar a eficácia da metodologia. Os 10 cenários de k-means resultaram em uma FOB próxima do seu valor, ao passo que os 200 cenários produziram uma FOB ainda melhor que a referência. Os resultados

Tabela 1. Cenários de geração solar.

Cenários	Probabilidade	Solar 1 Barra 5	Solar 2 Barra 14	Solar 3 Barra 27
1	0,5689	0,0138	0,0134	0,0142
2	0,0790	0,5296	0,2138	0,3212
3	0,0608	0,7156	0,4514	0,9448
4	0,0489	1,5834	0,5558	0,7442
5	0,0482	1,4000	1,8490	1,8878
6	0,0460	1,8482	0,6824	1,7846
7	0,0410	0,8050	1,6220	0,6540
8	0,0408	0,7254	0,7056	1,7766
9	0,0368	0,2898	0,7616	0,3318
10	0,0294	1,8256	1,7332	0,8100

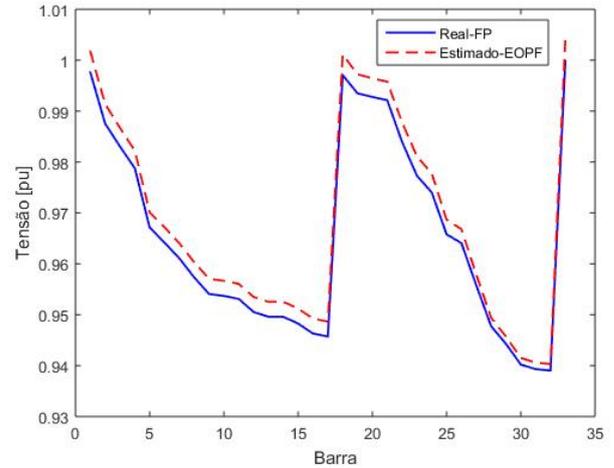


Figura 4. Módulo de tensão no sistema de 33 barras

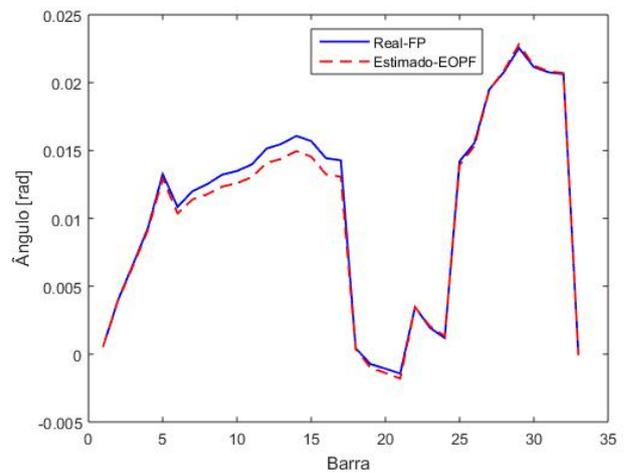


Figura 5. Ângulo de fase no sistema de 33 barras

Tabela 2. Resultados FOB.

Método	k-means 10 cenários	k-means 200 cenários	Monte Carlo 5000 amostras
FOB (%)	1,8189	0,9263	1,1419

demonstram que a metodologia é capaz de estimar o estado operativo de uma rede de distribuição, além de assegurar a capacidade da técnica k-means de representar incertezas de irradiação solar através de um número reduzido de cenários de geração.

4. CONCLUSÃO

O presente trabalho apresentou uma metodologia integrada que associa um algoritmo de estimação de estados com uma técnica de geração de cenários de irradiação solar, a fim de avaliar o impacto de geração fotovoltaica no problema de estimação de estados. Testes com um sistema de 33 barras envolvendo três usinas solares permitiram validar o potencial da metodologia proposta, com base em comparação com a tradicional Simulação de Monte Carlo. Verificou-se que um maior nível de penetração fotovoltaica implica em menor precisão do estimador de estados, pois

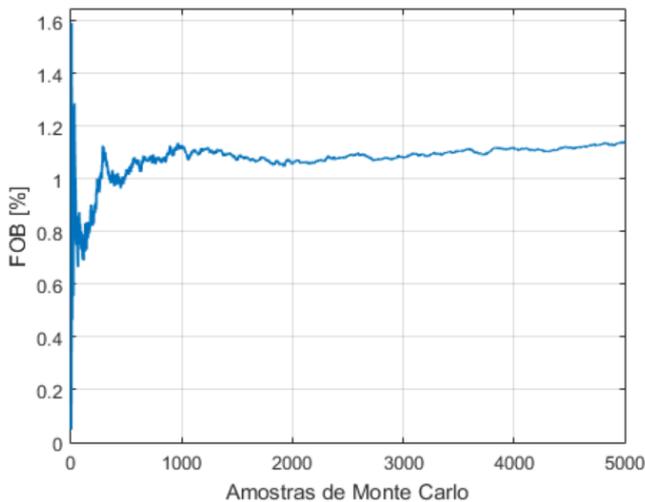


Figura 6. Processo de convergência da metodologia proposta para a Simulação de Monte Carlo.

maior percentual de energia renovável implica em maior nível de incerteza, com impacto consequentemente maior no problema de estimação. Adicionalmente, quanto maior o número de cenários utilizados, maior a precisão do estimador, devido à maior amostragem da variável estocástica de irradiação solar neste caso, contribuindo para a atenuação das incertezas inerentes. A consideração de medidas obtidas em intervalos de tempo distintos é apontada como um aspecto a ser acomodado pela metodologia proposta em contribuições futuras.

AGRADECIMENTOS

Os autores deste artigo agradecem ao apoio da FAPEMIG, CNPq, CAPES, INERGE, e ao Grupo de Otimização GOPT.

REFERÊNCIAS

- Ahmad, F., Tariq, M., and Farooq, A. (2019). A novel ann-based distribution network state estimator. *International Journal of Electrical Power & Energy Systems*, 107, 200–212.
- Atwa, Y., El-Saadany, E., Salama, M., and Seethapathy, R. (2009). Optimal renewable resources mix for distribution system energy loss minimization. *IEEE Transactions on Power Systems*, 25(1), 360–370.
- Baran, M.E. and Wu, F.F. (1989). Network reconfiguration in distribution systems for loss reduction and load balancing. *IEEE Transactions on Power delivery*, 4(2), 1401–1407.
- Cheng, G., Song, S., Lin, Y., Huang, Q., Lin, X., and Wang, F. (2019). Enhanced state estimation and bad data identification in active power distribution networks using photovoltaic power forecasting. *Electric Power Systems Research*, 177, 105974.
- Chilard, O., Grenard, S., Devaux, O., and de Alvaro Garcia, L. (2009). Distribution state estimation based on voltage state variables: assessment of results and limitations. In *CIGRE 20th International Conference on Electricity Distribution*. IET.
- Dehghanpour, K., Wang, Z., Wang, J., Yuan, Y., and Bu, F. (2019). A survey on state estimation techniques and challenges in smart distribution systems. *IEEE Transactions on Smart Grid*, 10(2), 2312–2322.
- Duque, F.G., de Oliveira, L.W., de Oliveira, E.J., and Augusto, A.A. (2017). State estimator for electrical distribution systems based on an optimization model. *Electric Power Systems Research*, 152, 122 – 129. doi: <https://doi.org/10.1016/j.epsr.2017.07.009>.
- F. Shabaninia, M. Vaziri, S.V. and Vaziri, J. (2012). Novel state estimation formulation for distribution grids with renewable energy sources. *2012 IEEE Power and Energy Society General Meeting*.
- Gomez-Exposito, A. and Abur, A. (2004). *Power system state estimation: theory and implementation*. CRC press.
- INPE (2019). Instituto nacional de pesquisas espaciais. www.inpe.br.
- Korres, G. and Manousakis, N. (2012). State estimation and observability analysis for phasor measurement unit measured systems. *IET generation, transmission & distribution*, 6(9), 902–913.
- Li, Z., Shahidepour, M., Alabdulwahab, A., and Al-Turki, Y. (2019). Valuation of distributed energy resources in active distribution networks. *The Electricity Journal*, 32(4), 27 – 36. Special Issue on Strategies for a sustainable, reliable and resilient grid.
- MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. In *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Volume 1: Statistics*, 281–297. University of California Press, Berkeley, Calif.
- MacQueen, J. et al. (1967). Some methods for classification and analysis of multivariate observations. In *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, volume 1, 281–297. Oakland, CA, USA.
- Qing, X., Karimi, H.R., Niu, Y., and Wang, X. (2015). Decentralized unscented kalman filter based on a consensus algorithm for multi-area dynamic state estimation in power systems. *International Journal of Electrical Power & Energy Systems*, 65, 26 – 33.
- S. Huang, C.L. and Lo, Y. (2015). Evaluation of ami and scada data synergy for distribution feeder modeling. *IEEE Transactions on Smart Grid*, (4), 1639–1647.
- Schweppe, F.C. and Rom, D.B. (1970). Power system static-state estimation. *IEEE Transactions on Power Apparatus and Systems*, (1), 125–130.
- Shen, D. and Liang, H. (2013). Research on distribution system state estimation with photovoltaic generation. *2013 IEEE International Conference of IEEE Region 10*.
- Wood, A.J., Wollenberg, B.F., and Sheblé, G.B. (2013). *Power generation, operation, and control*. John Wiley & Sons.
- Yang, X., Zhang, X.P., and Zhou, S. (2012). Coordinated algorithms for distributed state estimation with synchronized phasor measurements. *Applied Energy*, 96, 253 – 260.