

Uma nova abordagem para correção de erros grosseiros em estimação de estados utilizando algoritmo genético^{*}

Jeanderson Soares Mingorança^{*} Igor Delgado de Melo^{*}
Matheus Pereira Antunes^{*} Braulio César de Oliveira^{*}
Matheus Alberto de Souza^{*}

^{*} Faculdade de Engenharia Elétrica, Universidade do Federal de Juiz de Fora, MG, (e-mails: jeanderson.mingoranca@engenharia.ufjf.br, igor.delgado2008@engenharia.ufjf.br, matheus.antunes@engenharia.ufjf.br, braulio.oliveira@cefet-rj.br, matheus.alberto@ufjf.edu.br)

Abstract: This paper presents a new methodology for correcting gross errors in power distribution systems state estimation (SE). A SE algorithm is developed based on the Weighted Least Squares (WLS) using a hybrid approach in which non-synchronized measurements and PMUs (Phasor Measurement Units) are used together. At the end of the process, the Normalized Residuals (NRs) are calculated for each measurement and the existence of gross errors is detected based on statistical analysis of the NRs. Suspicious measurements are identified by the highest values of NRs. A calibration factor is associated with each suspected measurement to estimate the system state and correct the gross errors. In order to determine the exact values of the calibration factors, a new formulation of an optimization problem is proposed, being the solution provided by genetic algorithm. Simulations are conducted using the IEEE 33-bus test system to validate the proposed method proving its efficiency and robustness.

Resumo: Este artigo apresenta uma nova metodologia para a correção de erros grosseiros no processo de estimação de estados (EE) em sistemas de distribuição de energia elétrica. Um algoritmo de EE é desenvolvido baseado no método dos Mínimos Quadrados Ponderados (MQP) usando uma abordagem híbrida por meio de medições não sincronizadas e provenientes de PMUs (*Phasor Measurement Units*) utilizadas conjuntamente. Ao final do processo, os Resíduos Normalizados (RNs) são calculados para cada medição e detecta-se a existência de erros grosseiros através de análises estatísticas considerando os RNs. As medições suspeitas são identificadas avaliando os maiores valores de RNs. Um fator de calibração é associado às medições identificadas como suspeitas com o intuito de estimar o estado do sistema corrigindo os erros grosseiros. A fim de se determinar os valores exatos dos fatores de calibração, um problema de otimização é formulado, sendo resolvido com o auxílio da técnica do Algoritmo Genético (AG). Simulações são conduzidas utilizando um sistema teste de distribuição do IEEE de 33 barras para validar o método proposto atestando sua eficiência e robustez.

Keywords: State Estimation; WLS; PMUs; Smart Meters.

Palavras-chaves: Estimação de Estados; MQP; PMUs; Medidores Inteligentes.

1. INTRODUÇÃO

A estimação de estados (EE) é uma ferramenta essencial para a operação de sistemas de potência, segundo Abur and Expósito (2004). Entretanto, devido à introdução de novas tecnologias e o advento do uso das medições fasoriais sincronizadas, a detecção, identificação e correção de erros grosseiros têm se tornado funcionalidades cada vez mais necessárias segundo Salgado et al. (2015) e Abood (2020).

Desde que foi proposta por Schweppe and Wildes (1970), Schweppe and Rom (1970) e Schweppe (1970), o método dos Mínimos Quadrados Ponderados (MQP) é a principal técnica para a EE de redes elétricas, baseando-se nas medições obtidas em campo e na topologia do sistema.

Os resultados da EE dependem da acurácia das medidas coletadas. Na prática, as medições possuem erros aleatórios os quais são tradicionalmente suavizados pela EE; e, além disso, podem estar sujeitas a erros grosseiros (do inglês, *bad data*), de acordo com (Bretas et al., 2017). Esses últimos, de acordo com Zhao and Mili (2017), introduzem um desvio sistemático significativo em relação ao valor real da medição. Os erros grosseiros podem ocorrer devido à interferência eletromagnética, *cyber-attacks*, falhas no sistema de telecomunicação e equipamentos descalibrados, por exemplo, segundo Ahmadi et al. (2020); Gomez-Expósito et al. (2020); Zhang et al. (2020); Rakpenthai and Uatrongjit (2020).

^{*} Os autores agradecem ao PPEE e UFJF pelo suporte financeiro.

Tradicionalmente, segundo Merrill and Schweppe (1971), realiza-se a detecção de erros grosseiros por teste de qui-quadrada e identificação pelo Máximo Resíduo Normalizado (MRN). O uso de teste de hipóteses é abordado por Schweppe (1970); Stagg et al. (1970); Dopazo et al. (1970).

No contexto de redes elétricas inteligentes, Baran and McDermott (2009) propõem uma metodologia para tratamento de erros grosseiros considerando dados provenientes das denominadas *Advanced Metering Infrastructure* (AMI). Com os medidores inteligentes (do inglês, *Smart Meters* - SM) nessa estrutura de medição, tem-se a possibilidade de desenvolver sistemas de monitoramento robustos para redes de média e baixa tensão. Além do uso de SMs, é possível também mesclar diferentes tipos de medição como os medidores sincronizados fasorialmente (micro-PMUs - *Phasor Measurements Units*) por meio da abordagem de estimação de estados híbrida conforme descrito por Kumar et al. (2020); Melo et al. (2017); de Souza et al. (2020).

Os SMs instalados na baixa tensão possibilitam monitorar consumo (medição de potência ativa e reativa) em intervalos de tempo regulares, o que torna possível uma previsão de carga ao longo do dia para cada ponto notável da rede, segundo Primadianto and Lu (2016); Melo et al. (2019). Já as medições fasoriais sincronizadas, apesar de serem associadas a maiores custos, possuem acurácia maior segundo Kumar et al. (2020); Farajollahi et al. (2018); Aminifar et al. (2014). Quando os dois tipos de medições são usadas, observa-se maior robustez no processo de monitoramento, como descrito por Primadianto and Lu (2016).

Neste trabalho, é proposta uma nova abordagem para a correção de erros grosseiros em estimação de estados de redes de distribuição. Detecta-se a presença de erros grosseiros em um conjunto de medições suspeitas as quais são identificadas através de análises estatísticas. Um novo problema de otimização é formulado considerando um fator de calibração associado a cada medida suspeita. Os valores desses fatores são calculados usando algoritmo genético, sendo a determinação dos fatores de calibração a principal contribuição desta pesquisa.

Este artigo é dividido em cinco seções principais além desta de caráter introdutório. Na segunda seção, é apresentada a metodologia proposta integralmente. Na terceira, resultados de simulações são mostrados a fim de validar o método proposto. Conclusões são descritas na última seção.

2. METODOLOGIA PROPOSTA

2.1 Estimação de Estados usando o método MQP

O processo da estimação de estados se baseia na Equação (1) em que \mathbf{z} é o vetor de medições aquisitadas; $\hat{\mathbf{x}}$ é o vetor de variáveis de estados (magnitudes e ângulos de tensão em todos os barramentos do sistema); ϵ é o vetor de erros correspondentes às medições e $\mathbf{h}(\hat{\mathbf{x}})$ é a função não linear que relaciona \mathbf{z} e $\hat{\mathbf{x}}$.

$$\mathbf{z} = \mathbf{h}(\hat{\mathbf{x}}) + \epsilon \quad (1)$$

No método proposto neste artigo, é considerado o vetor de medições formado tanto por medições sincronizadas provenientes de micro-PMUs (denotado por z_{pmu} , quanto por medições de *Smart Meters* (SMs) (z_{sm}), como representado pela Equação (2), sendo as medições de cada

equipamento sujeitas aos erros aleatórios correspondentes ϵ_{pmu} e ϵ_{sm} , os quais são relacionados ao vetor de variáveis de estados, como apresentado nas Equações (3) e (4), respectivamente:

$$\mathbf{z} = [\mathbf{z}_{pmu} \quad \mathbf{z}_{sm}] \quad (2)$$

$$\mathbf{z}_{pmu} = \mathbf{h}_{pmu}(\hat{\mathbf{x}}) + \epsilon_{pmu} \quad (3)$$

$$\mathbf{z}_{sm} = \mathbf{h}_{sm}(\hat{\mathbf{x}}) + \epsilon_{sm} \quad (4)$$

Desta forma, o propósito do estimador de estados consiste em minimizar a função objetivo $J(\hat{\mathbf{x}})$, de acordo com a Equação (5) em que N_m é o número total de medições, σ_j é o desvio padrão da amostragem supondo que a medição aquisitada esteja sujeita a erros aleatórios com distribuição Gaussiana de média zero e \mathbf{R} é uma matriz diagonal contendo os valores de σ_j .

$$\min J(\hat{\mathbf{x}}) = \sum_{j=1}^{N_m} \left(\frac{z_j - h_j(\hat{\mathbf{x}})}{\sigma_j} \right)^2 = [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})]^T \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})] \quad (5)$$

As condições de otimalidade devem ser satisfeitas para o problema formulado, como indicado na Equação (6) em que $\mathbf{H}(\hat{\mathbf{x}}) = \frac{\partial \mathbf{h}(\hat{\mathbf{x}})}{\partial \hat{\mathbf{x}}}$ e, segundo Abur and Expósito (2004), é chamada de matriz Jacobiana das medições.

$$g(\hat{\mathbf{x}}) = \frac{\partial J}{\partial \hat{\mathbf{x}}} = -\mathbf{H}(\hat{\mathbf{x}})\mathbf{R}^{-1}[\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})] = 0 \quad (6)$$

Expande-se a equação em série de Taylor desconsiderando os termos de ordens mais elevadas, obtendo-se a Equação (7), em que $\hat{\mathbf{x}}^k$ é a solução na iteração k e $\mathbf{G}(\hat{\mathbf{x}})$ é a matriz de ganho, definida na Equação (8).

$$\hat{\mathbf{x}}^{k+1} = \hat{\mathbf{x}}^k - [\mathbf{G}(\hat{\mathbf{x}}^k)]^{-1}g(\hat{\mathbf{x}}^k) \quad (7)$$

$$\mathbf{G}(\hat{\mathbf{x}}^k) = \frac{\partial g(\hat{\mathbf{x}}^k)}{\partial \hat{\mathbf{x}}} = \mathbf{H}^T(\hat{\mathbf{x}}^k)\mathbf{R}^{-1}\mathbf{H}(\hat{\mathbf{x}}^k) \quad (8)$$

Para este artigo, as incertezas aleatórias relacionadas aos SMs são modeladas com valor de $\pm 10\%$. Tal fato representa a imprecisão dos dados obtidos de maneira não sincronizada e como um somatório de vários consumidores alimentados por um mesmo transformador na média tensão, de acordo com Primadianto and Lu (2016).

Já para as barras com micro-PMUs, consideram-se disponíveis em tempo real os valores de tensão (magnitude V_k e ângulo θ_k) da barra bem como as correntes passantes nos ramos conectados a essa unidade de medição (I_{km} e δ_{km} , sendo respectivamente magnitudes e ângulos). Como as medições sincronizadas são mais precisas, considera-se a classe de exatidão de, no máximo, até 1%. Esses valores são tipicamente adotados conforme de Oliveira et al. (2018) e Phadke and Thorp (2008).

Na abordagem proposta neste artigo, toda vez que o estimador de estados for computado pelo MQP, o estado operativo do sistema em regime permanente é obtido.

2.2 Detecção de erros grosseiros

Após a convergência do estimador, é realizado o cálculo dos Resíduos Normalizados (RNs) como descrito em Abur and Expósito (2004), para cada medição. Primeiramente, é levado em consideração o valor dos resíduos de medição,

como dado pela Equação (9) e depois calculam-se os resíduos normalizados pela Equação (10) em que S é a matriz que representa a sensibilidade das medidas residuais para os erros de medição conforme (11):

$$r_j = z_j - h_j(\hat{x}) \quad (9)$$

$$r_j^N = \frac{|r_j|^N}{\sigma_j} = \frac{|r_j|}{\sqrt{\Omega_{jj}}} = \frac{|r_j|}{\sqrt{R_{jj}S_{jj}}} \quad (10)$$

$$S = (I - K) = (I - HG^{-1}H^T R^{-1}) \quad (11)$$

Desta forma, neste artigo, é proposta a detecção de erros grosseiros de acordo com o equacionamento (12) em que $\mu(r_j^N)$ é a média dos resíduos normalizados.

$$r_j^N \geq \mu(r_j^N) \quad (12)$$

Neste caso, calculam-se os resíduos normalizados e é verificado se algum dos mesmos é maior ou igual à média de todos os resíduos normalizados. Dessa forma, detecta-se a presença de erro grosseiro assumindo-se que os resíduos normalizados ficarão acima do valor esperado em relação ao caso em que não há intrusão de erros grosseiros, conforme descrito em Abur and Expósito (2004).

2.3 Identificação de erros grosseiros

Nesta etapa, é feita a identificação das medições suspeitas de acordo com o equacionamento (13) em que o conjunto de medições suspeitas, denotado por \bar{z} , está contido no vetor de medições coletadas da rede tal que o resíduo normalizado da medição suspeita seja superior à média mais três vezes o desvio padrão dos RNs. Desta forma, selecionam-se os maiores resíduos normalizados e esses são associados às medições identificadas como suspeitas com erros grosseiros, como mostrado pela Equação (13) considerando que $\sigma(r_j^N)$ é o desvio padrão dos resíduos normalizados.

$$\bar{z} \in z \forall r_j^N \geq \mu(r_j^N) + 3 \cdot \sigma(r_j^N) \quad (13)$$

2.4 Correção dos erros grosseiros

Uma vez que as medições suspeitas foram identificadas, será atribuído à cada uma delas um fator de calibração λ_j o qual deverá ter seu valor exato determinado conforme um problema de otimização proposto neste trabalho. O problema de otimização é descrito pela minimização da função objetivo (14) sujeito às restrições (15).

$$\min J(\hat{x}, \lambda) = \sum_{j=1}^{N_m} \left(\frac{\lambda_j \cdot z_j - h_j(\hat{x})}{\sigma_j} \right)^2 \quad (14)$$

s.a.

$$\begin{cases} \lambda_j^{min} \leq \lambda_j \leq \lambda_j^{max}, & \text{se } z_j \in \bar{z} \\ \lambda_j = 1, & \text{se } z_j \notin \bar{z} \end{cases} \quad (15)$$

Na formulação proposta, cada medição obtida da rede monitorada tem um fator de calibração λ_j associado. Caso a medição tenha sido identificada como suspeita, o fator de calibração poderá ser determinado, sendo uma variável do problema formulado, estando entre limites mínimos e máximos (λ_j^{min} e λ_j^{max} , respectivamente). Caso a medição não seja suspeita, seu fator de calibração é fixado no valor unitário conforme equação (15).

2.5 Uso do AG para a resolução do problema formulado

O AG foi proposto por Holland (1975) e permite modelar computacionalmente processos naturais da evolução e resolver problemas complexos de engenharia em diversas áreas do conhecimento. Baseia-se na criação de possíveis soluções, denominadas de indivíduos, para um determinado problema, sendo cada possível solução usada para o cálculo da função objetivo do problema de minimização. A partir da escolha de melhores candidatos a serem a solução ótima do problema, os melhores indivíduos são capazes de se reproduzir e podem sofrer ação de operadores genéticos como mutação e elitismo a fim de achar a resposta viável numericamente para o problema formulado.

O valor da função objetivo, denominada função aptidão, determina a qualidade de um indivíduo como solução do problema em questão e é uma “nota” dada ao indivíduo na resolução do problema.

Indivíduos com boa ou com maior valor de função aptidão irão ter probabilidade maior de deixar suas características para os seus descendentes em relação àqueles com baixo valor de função aptidão.

A Figura 1 mostra um fluxograma do AG tradicional.

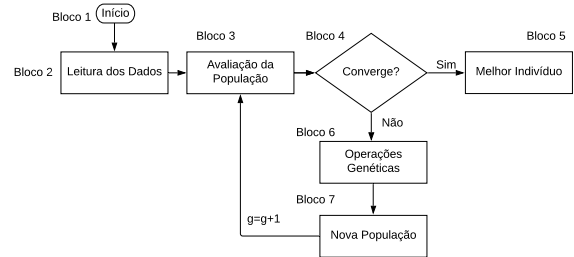


Figura 1. Fluxograma explicativo do AG

O Bloco-1, neste caso, indica a inicialização do algoritmo. No Bloco-2, é realizada a leitura de dados do problema a ser resolvido. Logo depois, tem-se uma população gerada aleatoriamente, em que cada indivíduo (possível solução do problema) é um vetor composto por genes (elementos contidos neste vetor de solução).

Conforme indicado pelo Bloco-3, possível avaliar o valor da função objetivo para cada indivíduo da população e aqueles mais aptos (com maior valor de função objetivo) têm a oportunidade de se reproduzirem e gerarem novos indivíduos até que haja convergência do processo iterativo, conforme indicado pelo Bloco-4.

Os pais, nesse processo, morrem imediatamente na formação dos filhos, mantendo fixo o tamanho da população inicial após a aplicação de operadores genéticos como indicado pelo Bloco-6. Além disso, um processo de mutação pode alterar os genes por meio de operadores genéticos e possibilita a criação de um novo indivíduo (nova solução) que pode ter maior função aptidão.

Ao se considerar o mecanismo de elitismo, uma nova população é formada seja por substituição direta ou parcial de todos os indivíduos. Esse mecanismo permite que sejam mantidas soluções boas de uma geração para a outra.

A cada nova geração g , conforme indicado pelo Bloco-7, com uma nova população, cada indivíduo é novamente avaliado em relação à aptidão na minimização da função objetivo do problema modelado. Ao fim, todos os indivíduos podem se tornar progenitores para formar uma nova população, caso a aptidão dos indivíduos filhos supere à aptidão dos respectivos pais até que se encontre melhores soluções para a resolução de determinado problema, como indicado pelo Bloco-5.

O processo se repete diversas vezes até que algum critério de parada seja satisfeito. Esse critério pode ser por estagnação, número máximo de gerações ou tempo de execução.

Neste trabalho, foi utilizada a *toolbox* GA (*Genetic Algorithm*) do MATLAB para resolver o problema de otimização modelado. Uma população inicial de possíveis candidatos (indivíduos) é criada por meio de um vetor com elementos unitários com mesma dimensão do número de medições suspeitas.

Na abordagem proposta, a solução do AG fornecerá os valores exatos dos fatores de calibração permitindo estimar o estado da rede eliminando o efeito dos erros grosseiros uma vez que será feita uma “estimativa” do quão distorcida a medição errônea está.

Para a aplicação do AG no método proposto, foi utilizado um número de 200 indivíduos em uma população. Como critério de convergência, adotou-se o critério de estagnação da resposta após 20 gerações.

O cruzamento se dá pelo método de torneio, a taxa de mutação é 1% da população com distribuição uniforme e a taxa de elitismo usada é de 10% do número de indivíduos em uma dada geração. Tais parâmetros foram selecionados com base em outras referências e explorando os recursos da *toolbox*.

As simulações foram conduzidas com uso do *software* MATLAB em um computador de 4GHz, i5 com 6GB de RAM e sistema operacional Windows 10.

3. TESTES E RESULTADOS

Para se validar a metodologia proposta, é utilizado o sistema de 33 barras mantendo-se os dados originais da referência Baran and Wu (1989).

Neste artigo, serão consideradas análises para dois casos de estudo com dois planos de medição distintos:

- (1) **Caso 1:** Plano de medição com 16 micro-PMUs:
 - (a) **Caso 1-a:** erro grosseiro na medição de tensão da barra 17;
 - (b) **Caso 1-b:** dois erros grosseiros nas medições das barras 3 e 17;
- (2) **Caso 2:** Plano de medição com 8 micro-PMUs:
 - (a) **Caso 2-a:** um erro grosseiro na medição de tensão da barra 17;
 - (b) **Caso 2-b:** dois erros grosseiros nas medições de tensão das barras 3 e 24.

3.1 Caso 1: Plano de medição com 16 micro-PMUs

Para o primeiro plano de medição, na Figura 2 é mostrada a topologia do sistema de 33 barras, bem como a localização das micro-PMUs.




Figura 2. Sistema de 33 barras com 16 micro-PMUs

A alocação ótima de micro-PMUs são determinadas por meio de programação linear de acordo com Bhonsle and Junghare (2012) e encontram-se nas barras 1, 3, 5, 7, 9, 11, 13, 15, 17, 19, 21, 24, 26, 28, 30 e 32. Dessa maneira, a observabilidade é restaurada considerando-se que nas barras de carga restantes são empregados medidores inteligentes com medidas de potência ativa e reativa, referentes à carga agregada na barra.

Os limites inferiores e superiores, definidos na Equação (15) e relacionados aos fatores de calibração são determinados iguais a 0,1 e 2 para as simulações computacionais, respectivamente, sendo admitidos valores mínimos e máximos dos fatores de calibração iguais a 10% e 100% do valor da medição, conforme anteriormente explicitado.

Considerando-se, primeiramente, a estimativa de estados sem intrusão de erros grosseiros, com medições das micro-PMUs com classes de exatidão de no máximo 1% e dos SMs com classes de exatidão de no máximo 10%, tem-se mostrado na Figura 3 as magnitudes de tensão para cada uma das barras com seus valores reais e estimados correspondentes.




Figura 3. Estimativa de magnitudes de tensão - caso 1

Na Figura 4 são mostrados os erros de estimativa para este caso de estudo considerando os valores de tensão para cada uma das barras.




Figura 4. Erros de estimativa - caso 1

É notório que os erros de estimação são reduzidos, abaixo de 0,12%. Para esse caso sem intrusão de erros grosseiros, a função objetivo é igual a 0,0146.

Caso 1-a: Erro na medição de tensão da barra 17: Considerando um erro grosseiro na medição da magnitude de tensão da barra 17 com 20% (considera-se, neste caso, que a medição é multiplicada por um fator igual a 1,2 para as simulações), observam-se elevados valores de erros de estimação, como mostrado pela Figura 5.




Figura 5. Erros de estimação - caso 1-a

O valor da função objetivo, para este estudo de caso, é de 33,531. A medição com erro grosseiro é devidamente identificada uma vez que possui resíduo normalizado muito maior quando comparado aos resíduos normalizados de todas as medições suspeitas como pode ser visto pela Tabela 1. A medição identificada com erro grosseiro possui valor de resíduo normalizado associado de 5,7670.

Tabela 1. Quatro maiores resíduos normalizados - caso 1-a

Medição	Resíduo Normalizado
V_{17}	5,7670
V_{30}	0,7127
V_{32}	0,6402
I_{7-8}	0,6635

Após o processo de otimização, em que os fatores de calibração são determinados para compensar os erros grosseiros, é possível observar, pela Figura 6, que os erros de estimação são bem reduzidos. O valor da função objetivo após a otimização é de 0,178087.




Figura 6. Erros de estimação após correção dos erros grosseiros - caso 1-a

O fator de calibração resultante do processo de otimização é de 0,8304, corrigindo o erro de 20% introduzido na medição de tensão da barra 17 corretamente.

A Figura 7 mostra a trajetória de convergência do processo de otimização contendo os valores da função objetivo a cada geração do AG. Percebe-se que o valor correspondente ao melhor candidato, dentre de uma população gerada, vai decrescendo até atingir o valor otimizado, ao fim do processo.

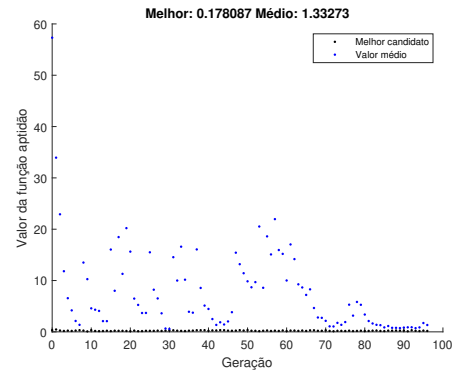


Figura 7. Trajetória de convergência do AG - caso 1-a

Caso 1-b: Erro na medição de tensão das barras 3 e 17 Considera-se, neste caso de estudo, intrusão de *bad data* nas medições de tensão na barra 3 e na barra 17, ambos com erro grosseiro de +20%. Os erros de estimação são mostrados na Figura 8.




Figura 8. Erros de estimação - caso 1-b

A função objetivo para esse caso assume um elevado valor de 77,1225. Para um caso como esse de dois erros grosseiros, o processo de detecção, identificação e correção exige maior esforço computacional. Os resíduos normalizados das medições identificadas com erros grosseiros são bem maiores quando comparados com as outras medições suspeitas como mostrado na Tabela 2, com valores de resíduos normalizados de 5,8769 e 6,0401 para as medições de tensão nas barras 3 e 17, respectivamente.

Tabela 2. Quatro maiores resíduos normalizados - caso 1-b

Medição	Resíduo Normalizado
V_3	5,8769
V_{17}	6,0401
V_{21}	1,3855
I_{9-10}	1,4706

Após o processo de otimização seguindo a metodologia proposta, a estimação de estados é bem sucedida, sendo a função objetivo de 0,190170. Os erros de estimação são mostrados na Figura 9.

Os fatores de calibração resultantes do processo de otimização são 0,8335 e 0,8306 associados às medições de tensão da barra 3 e 17, respectivamente.




Figura 9. Erros de estimação após correção dos erros grosseiros - caso 1-b

A Figura 10 mostra a trajetória de convergência para este caso de estudo.




Figura 10. Trajetória de convergência do AG - caso 1-b

3.2 Caso 2: Plano de medição com 8 micro-PMUs

Neste caso de estudo, adota-se um procedimento de alocação diferente para o sistema teste de 33 barras, conforme descrito na referência de Oliveira et al. (2018).

Neste caso, apenas 8 micro-PMUs são alocadas nas barras 1, 2, 3, 6, 17, 21, 24 e 32, assim como indicado na Figura 11. Nas barras restantes, dados de SMs são considerados.




Figura 11. Diagrama unifilar do sistema de 33 barras com 8 micro-PMUs

Caso 2-a: Erro na medição de tensão na barra 17 Considerando um erro de medição de tensão na barra 17 de +20%, a estimação de estados é associada a um elevado

valor de função objetivo (igual a 31,36) e a erros de estimação elevados, como pode ser constatado pela Figura 12.




Figura 12. Erros de magnitudes de tensão - caso 2-a

A medição com erro grosseiro é detectada e identificada com valor residual muito maior do que o valor encontrado para as outras medições, como mostra a Tabela 3, de acordo com o método proposto, e igual a 5,5988.

Tabela 3. Quatro maiores resíduos normalizados - Caso 2-a

Medição	Resíduo Normalizado
V_3	0,8051
V_6	0,8038
V_{17}	5,5988
V_{32}	0,9133

Após a realização do processo de otimização com algoritmo genético, um fator de calibração de 0,8221 foi obtido. O valor da função objetivo obtido foi de 0,1430.

A Figura 15 mostra os resultados de magnitudes de erros de tensão obtidos após aplicação do método proposto, os quais são bem mais reduzidos em relação ao caso anterior.




Figura 13. Erros de magnitudes de tensão após correção - caso 2-a

Caso 2-b: Erro de medição de tensão nas barras 2 e 24 Considerando dois erros grosseiros de medição de tensão de +15% da barra 2 e +30% da barra 24, observa-se por meio da Figura 14, o impacto deles no processo de estimação mostrando as elevadas magnitudes de erros de estimação.

O valor da função objetivo para este caso é de 65,7879, sendo bem elevada. Para este caso, a dificuldade de se encontrar a solução ótima e estimar o estado da rede é maior, o que resulta em maior esforço computacional com a execução do AG.

O conjunto de medições consideradas com maiores valores de resíduos, sendo detectadas e, posteriormente, também identificadas como suspeitas foram as medições de tensão das barras 2 e 24 com resíduos normalizados 3,5048 e 8,6359, respectivamente. A Tabela 4 mostra os quatro maiores resíduos normalizados encontrados.

Tabela 4. Quatro maiores resíduos normalizados - Caso 2-b

Medição	Resíduo Normalizado
V_1	1,8298
V_2	3,5048
V_{21}	1,8654
V_{24}	8,6169

Após o processo de otimização realizado, seguindo a formulação apresentada e proposta, a função objetivo é bem sucedida e estabelecida com valor de 0,0139 realizando a correção dos dois erros grosseiros intrusos nas medições.




Figura 14. Erros de estimação para caso de dois erros grosseiros - Caso 2-b

A Figura 15 mostra os resultados de erros de estimação obtidos após otimização, podendo-se verificar pequenos valores de erros associados.




Figura 15. Erros de estimação após correção de erros grosseiros - caso 2-b

Os fatores de calibração obtidos na otimização foram 0,8734 para medição de tensão da barra 2 e 0,7707 para medição de tensão da barra 24. Para esse caso de dois erros grosseiros e plano com número de medições limitadas, o esforço computacional é maior.

3.3 Tempos computacionais

A Tabela 5 mostra os tempos computacionais obtidos para cada um dos casos de estudo.

É perceptível que os tempos associados ao processo de otimização para correção de dois erros grosseiros (casos *b*) são maiores que os mesmos relacionados à correção de apenas um erro grosseiro (casos *a*). Além disso, a correção de dois erros grosseiros no sistema com maior limitação de medições fasoriais instaladas em campo (8 micro-PMUs) se mostrou mais custosa, resultando em maior tempo computacional.

Tabela 5. Tempos computacionais

Tempo Computacional	Tempo (s)
Caso 1-a	162,739
Caso 1-b	221,53
Caso 2-a	129,90
Caso 2-b	460,21

4. CONCLUSÕES

Este artigo apresentou uma nova abordagem para a correção de erros grosseiros durante o processo de estimação de estados em redes de distribuição.

O algoritmo tradicional MQP é modificado a fim de se considerar medições sincronizadas e não sincronizadas, a serem utilizadas conjuntamente. A detecção e identificação de erros grosseiros das medições são feitas mediante análises dos resíduos normalizados.

Fatores de calibração são associados às medições suspeitas com erro grosseiro, sendo determinados a partir de um problema de otimização proposto. Seus valores exatos são obtidos através do uso do Algoritmo Genético.

A partir de casos de estudo, foi possível verificar a aplicabilidade e viabilidade do método proposto para determinar os fatores de calibração e compensar erros grosseiros.

Apesar dos resultados promissores, em que os erros de estimação são reduzidos mediante correção de erros grosseiros, trabalhos futuros incluem a exploração dos parâmetros do AG variando-se número de indivíduos e operadores genéticos. Além disso, o uso de processamento paralelo pode ser explorado a fim de reduzir o tempo computacional associado ao método proposto.

AGRADECIMENTOS

Os autores agradecem pelo apoio financeiro à UFJF e ao PPEE (Programa de Pós Graduação em Engenharia Elétrica).

REFERÊNCIAS

- Aboud, H.G. (2020). Monitoring and state estimation of modern power systems. In *Smart Technologies for Smart Cities*, 87–107. Springer.
- Abur, A. and Expósito, A.G. (2004). *Power system state estimation: theory and implementation*. CRC press.
- Ahmadi, N., Chakhchoukh, Y., and Ishii, H. (2020). Power systems decomposition for robustifying state estimation under cyber attacks. *IEEE Transactions on Power Systems*.
- Aminifar, F., Fotuhi-Firuzabad, M., Safdarian, A., Davoudi, A., and Shahidehpour, M. (2014). Synchrophasor

- measurement technology in power systems: Panorama and state-of-the-art. *IEEE Access*, 2, 1607–1628.
- Baran, M. and McDermott, T. (2009). Distribution system state estimation using ami data. In *2009 IEEE/PES Power Systems Conference and Exposition*, 1–3. IEEE.
- Baran, M.E. and Wu, F.F. (1989). Optimal capacitor placement on radial distribution systems. *IEEE Transactions on Power Delivery*, 4(1), 725–734.
- Bhonsle, J. and Junghare, A. (2012). A novel approach for the optimal pmu placement using binary integer programming technique. *International Journal of Electrical and Electronics Engineering (IJEEE) ISSN (PRINT)*, 2231–5284.
- Bretas, A., Bretas, N., Braunstein, S., Rossoni, A., and Trevizan, R. (2017). Multiple gross errors detection, identification and correction in three-phase distribution systems wls state estimation: A per-phase measurement error approach. *Electric Power Systems Research*, 151, 174–185.
- de Oliveira, B.C., Pereira, J.L., Alves, G.d.O., Melo, I.D., de Souza, M.A., and Garcia, P.A. (2018). Decentralized three-phase distribution system static state estimation based on phasor measurement units. *Electric Power Systems Research*, 160, 327–336.
- de Souza, M.A., Pereira, J.L., Alves, G.d.O., de Oliveira, B.C., Melo, I.D., and Garcia, P.A. (2020). Detection and identification of energy theft in advanced metering infrastructures. *Electric Power Systems Research*, 182, 106258.
- Dopazo, J., Klitin, O., Stagg, G., and Van Slyck, L. (1970). State calculation of power systems from line flow measurements. *IEEE transactions on power Apparatus and Systems*, (7), 1698–1708.
- Farajollahi, M., Shahsavari, A., Stewart, E.M., and Mohsenian-Rad, H. (2018). Locating the source of events in power distribution systems using micro-pmu data. *IEEE Transactions on Power Systems*, 33(6), 6343–6354.
- Gomez-Exposito, A., Mili, L., and Wu, W. (2020). Guest editorial: State estimation for future cyber-physical power and energy systems: Challenges and solutions. *Journal of Modern Power Systems and Clean Energy*, 8(4), 1–2.
- Holland, J. (1975). Adaptation in natural and artificial systems 1975.
- Kumar, C.S., Rajawat, K., Chakrabarti, S., and Pal, B.C. (2020). Robust distribution system state estimation with hybrid measurements. *IET Generation, Transmission & Distribution*, 14(16), 3250–3259.
- Melo, I.D., Pereira, J.L., Ribeiro, P.F., Variz, A.M., and Oliveira, B.C. (2019). Harmonic state estimation for distribution systems based on optimization models considering daily load profiles. *Electric Power Systems Research*, 170, 303–316.
- Melo, I.D., Pereira, J.L., Variz, A.M., and Garcia, P.A. (2017). Harmonic state estimation for distribution networks using phasor measurement units. *Electric Power Systems Research*, 147, 133–144.
- Merrill, H.M. and Schweppe, F.C. (1971). Bad data suppression in power system static state estimation. *IEEE Transactions on Power Apparatus and Systems*, (6), 2718–2725.
- Phadke, A.G. and Thorp, J.S. (2008). *Synchronized phasor measurements and their applications*, volume 1. Springer.
- Primadianto, A. and Lu, C.N. (2016). A review on distribution system state estimation. *IEEE Transactions on Power Systems*, 32(5), 3875–3883.
- Rakpenthai, C. and Uatrongjit, S. (2020). A robust wlv state estimation based on pseudo-voltage measurements. *IEEE Transactions on Electrical and Electronic Engineering*, 15(6), 854–862.
- Salgado, A.R., Esquivel, C.R.F., and Guizar, J.G.C. (2015). Scada and pmu measurements for improving power system state estimation. *IEEE Latin America Transactions*, 13(7), 2245–2251.
- Schweppe, F.C. (1970). Power system static-state estimation, part iii: Implementation. *IEEE Transactions on Power Apparatus and Systems*, (1), 130–135.
- Schweppe, F.C. and Rom, D.B. (1970). Power system static-state estimation, part ii: Approximate model. *IEEE Transactions on Power Apparatus and Systems*, (1), 125–130.
- Schweppe, F.C. and Wildes, J. (1970). Power system static-state estimation, part i: Exact model. *IEEE Transactions on Power Apparatus and Systems*, (1), 120–125.
- Stagg, G.W., Dopazo, J.F., Klitin, O.A., and Vanslyck, L.S. (1970). Techniques for the real-time monitoring of power system operations. *IEEE transactions on power Apparatus and Systems*, (4), 545–555.
- Zhang, T., Yuan, P., Du, Y., Zhang, W., and Chen, J. (2020). Robust distributed state estimation of active distribution networks considering communication failures. *International Journal of Electrical Power & Energy Systems*, 118, 105732.
- Zhao, J. and Mili, L. (2017). Power system robust decentralized dynamic state estimation based on multiple hypothesis testing. *IEEE Transactions on Power Systems*, 33(4), 4553–4562.