

Tratamento de Dados Espúrios na Estimação de Estados via Algoritmo de Otimização Aritmética

Renato Andrade Mosqueira Furtado * Igor Delgado de Melo **
Ivo Chaves da Silva Junior ***

* Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: renato.andrade@engenharia.ufjf.br).

** Departamento de Energia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: igor.delgado2008@engenharia.ufjf.br)

*** Departamento de Energia Elétrica, Universidade Federal de Juiz de Fora, MG, (e-mail: ivo.junior@ufjf.edu.br)

Abstract: The objective of this work is to use a recently developed meta-heuristic and not very widespread in the field of electrical power systems, whose name is Arithmetic Optimization Algorithm (AOA), to correct bad data in the state estimation (SE) process. Thus, a SE algorithm is proposed based on the weighted least squares method and, after its convergence, bad data detection and identification procedures are performed by statistical methods based on the maximum normalized residual. Finally, an optimization problem is formulated with the purpose of calculating calibration factors for the suspicious measurements, ensuring a correct estimate of the electrical quantities with low estimation errors when compared with the actual values. Simulations were performed in the IEEE 30 bus transmission system and the results show the applicability and efficiency of the Arithmetic Optimization Algorithm in solving the problem in terms of the optimality of the solution and the computational effort allowing its use for decision making in real time in control centers.

Resumo: O objetivo deste trabalho é utilizar uma meta-heurística desenvolvida recentemente e pouco difundida na área de sistemas elétricos de potência cognominada Algoritmo de Otimização Aritmética (AOA) para fazer a correção de dados espúrios no processo de estimação de estados (EE). Assim, um algoritmo de EE é desenvolvido baseado no método dos mínimos quadrados ponderados e, após sua convergência, é efetuada a detecção e identificação de erros grosseiros usando métodos estatísticos baseados no máximo resíduo normalizado. Por fim, um problema de otimização é formulado com a finalidade de calcular fatores de calibração associados às medidas identificadas como suspeitas, garantindo uma estimativa correta das grandezas elétricas com baixos erros de estimação quando comparados aos valores reais. As simulações foram conduzidas no sistema de transmissão IEEE 30 barras e os resultados mostram a aplicabilidade e eficiência do AOA na resolução do problema em questão no que tange à otimalidade da solução e ao esforço computacional permitindo seu uso para tomadas de decisão em tempo real nos centros de controle.

Keywords: Arithmetic Optimization Algorithm; Bad Data; Power Systems Security; State Estimation; Weighted Least Squares.

Palavras-chaves: Algoritmo de Otimização Aritmética; Dados Espúrios; Segurança de Sistemas de Potência; Estimação de Estados; Mínimos Quadrados Ponderados.

1. INTRODUÇÃO

O uso comercial da energia elétrica teve início por volta de 1870 quando lâmpadas e pequenos sistemas de distribuição eram utilizados exclusivamente para iluminação de casas e ruas. Posteriormente, com os avanços tecnológicos proporcionados pelas revoluções industriais, pequenos sistemas de energia deram lugar a um grande complexo

elétrico que, reúne geração, transmissão em alta tensão e distribuição em baixa tensão, o qual foi cognominado de sistema elétrico de potência. Dessa forma, a função primordial de um sistema de potência é garantir o fornecimento de energia elétrica aos centros consumidores, no nível mais alto de confiabilidade, dentro de limites específicos (tensão, frequência, fluxos de potência em linhas, geração de reativo, etc) com elevado grau de eficiência na operação e controle nos diversos elementos do sistema o que está associado diretamente com o conhecimento do estado operativo real da rede (Kundur, 1994).

* Os autores agradecem ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, ao INERGE, à FAPEMIG, à CAPES e ao CNPQ pelo suporte financeiro para o desenvolvimento deste estudo.

Com a relevância da supervisão e do controle contínuo, o principal pré-requisito para uma boa funcionalidade dos centros de operação é dispor de medições das grandezas elétricas a fim de estimar qual o estado mais provável da rede (Raposo et al., 2019). Para tanto, a operação em tempo real é regulada por informações manipuladas pelo sistema supervisório e aquisição de dados (*Supervisory Control And Data Acquisition - SCADA*) o qual processa as informações lógicas e analógicas advindas dos medidores, para o operador (Bragança et al., 2021). Esse processo é conhecido como estimação de estados cujo propósito é determinar o estado mais provável do sistema elétrico de potência (magnitude de tensões, ângulos e fluxo de potência nas linhas) com um número suficiente de medições que torne a rede observável. Além disso, as equações básicas que regem o estimador de estados são as mesmas no problema de fluxo de potência sendo a diferença entre eles os dados manipulados pelo estimador, os quais estão sujeitos à erros aleatórios associados à classe de exatidão dos equipamentos medidores (Monticelli, 1983).

Nesse contexto, a acurácia do processo de estimação de estados, bem como as limitações de sua aplicação, dependem diretamente da veracidade dos dados presentes no plano de medição (Massignan et al., 2020). Sabe-se que qualquer medição elétrica efetuada na prática está sujeita a erros aleatórios, que são estatisticamente pequenos, advindos de possíveis interferências nos canais de comunicação ou da classe de exatidão dos equipamentos. Em contrapartida, os erros grosseiros, também chamados de erros sistemáticos ou dados espúrios, são desvios significativos em relação ao valor da medição real que podem ser introduzidos por falhas de calibração, falha no processamento de dados, ataques cibernéticos ou conexão errada nos diversos elementos do sistema de medição (Melo, 2022). Desse modo, a presença de erros grosseiros, no plano de medição utilizado na estimação de estados, pode ocasionar tomadas de decisões equivocadas baseadas em uma estimativa errônea da rede em análise, levando, em muitas vezes, a situações críticas que podem comprometer a estabilidade e segurança da operação do sistema (Melo, 2022). Portanto, o sucesso da estimação de estados também depende de procedimentos para detecção, identificação e tratamento de erros grosseiros para que, mesmo com a observabilidade de um sistema comprometida, haja uma boa estimativa das grandezas elétricas da rede (Abur, 2004).

Dada a necessidade do pré-processamento das informações coletadas por medições, o tratamento de erros grosseiros seguem tratativas diversas, como: (i) eliminação da medida suspeita do plano de medição considerando uma abordagem de estimação de estados em sistemas de transmissão com plena redundância de informações (Da Cunha et al., 2022); (ii) aplicação do critério de máxima entropia (CMC), por apresentarem propriedades naturais de resiliência contra erros grosseiros, a fim de constituir um novo módulo de fusão de estimativas (Ascari, 2022); (iii) utilização de heurísticas de busca local como o recozimento simulado em (Augusto et al., 2010) e o GPSA (do inglês *Generalized Pattern Search Algorithm*) em (Melo and Antunes, 2022) para a calibração de erros grosseiros no processo de estimação de estados.

Na busca por métodos para atenuar medidas errôneas no processo de estimação de estados, em (Melo, 2022), fala-se

que o processo ideal é corrigi-las por meio de fatores de calibração. Porém, tal método não é trivial pois adiciona uma não linearidade nas equações da estimação de estados, fazendo com que métodos clássicos apresentem problemas de convergência devido à mal condicionamento matricial ou pontos de singularidade das matrizes utilizadas no processo. Nesse contexto, a maior dificuldade é encontrar um algoritmo que proponha uma busca em um processo de otimização que forneça resultados em um tempo computacional vantajoso e faça que os estados sejam estimados com boa acurácia. Assim, o uso de meta-heurísticas torna-se uma alternativa eficaz por serem capazes de explorar uma solução factível em diferentes espaços de busca (local e global) através da combinação de escolhas aleatórias e inteligência populacional (Shaheen et al., 2018).

Neste sentido, destaca-se a contribuição deste trabalho que é utilizar uma meta-heurística cognominada Algoritmo de Otimização Aritmética (AOA) para fazer o tratamento de erros grosseiros no processo de estimação de estados. Para tanto, será mostrada a formulação matemática da estimação de estados, a função objetivo do problema de otimização para correção de erros grosseiros, a metodologia da otimização aritmética, resultados advindos das simulações e as conclusões. As aplicações foram feitas no sistema de transmissão IEEE 30 barras com plano de medição contendo apenas medições sincronizadas fornecidas por PMUs (do inglês *Phasor Measurement Units*).

2. FORMULAÇÃO MATEMÁTICA

2.1 Estimação de Estados usando MQP

A estimação de estados usando o método dos Mínimos Quadrados Ponderados (MQP) tem como formulação matemática a minimização de uma função objetivo que é definida como o somatório das diferenças quadráticas ponderadas. Em (1), há a representação do problema onde $\hat{\mathbf{x}}$ representa as variáveis a serem estimadas (magnitudes e ângulos de tensão em cada barra do sistema monitorado), m é a quantidade total de medições obtidas através de medidores instalados em campo, σ_i é o valor do desvio padrão associado aos erros aleatórios de cada medição, z_i é o valor mensurado e $h(\hat{\mathbf{x}})$ é uma função não linear que relaciona uma medição z_i com o vetor de variáveis de estados $\hat{\mathbf{x}}$.

$$\text{Min } J(\hat{\mathbf{x}}) = \sum_{i=1}^m \left(\frac{z_i - h_i(\hat{\mathbf{x}})}{\sigma_i} \right)^2 \quad (1)$$

Considerando o plano de medição com m medidas e um vetor de variáveis de estados de tamanho n , pode-se reescrever (1) na forma matricial como mostrado em (2) onde \mathbf{R} é uma matriz diagonal de dimensão $m \times m$ cujos valores são as variâncias de cada medição m . Ademais, \mathbf{z} e \mathbf{h} são, respectivamente, os vetores de medição e o vetor da função não linear, ambas com dimensão $m \times 1$ (Melo, 2022).

$$\mathbf{J}(\hat{\mathbf{x}}) = [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})]^T \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})] \quad (2)$$

Para a minimização de (2), deseja-se que a derivada de primeira ordem de J em relação a $\hat{\mathbf{x}}$ seja igual a zero conforme explicitado em (3).

$$\mathbf{g}(\hat{\mathbf{x}}) = \frac{\partial \mathbf{J}(\hat{x})}{\partial \hat{\mathbf{x}}} = -[\mathbf{H}(\hat{\mathbf{x}})]^T \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})] = 0 \quad (3)$$

A matriz \mathbf{H} , chamada de matriz Jacobiana das medições, é formada pelas derivadas parciais da função $h(\hat{x})$ associadas à cada medição em relação às variáveis de estados, possuindo, portanto, dimensão $m \times n$.

Para a solução de (3), deve-se expandi-la em termos da série de Taylor. Logo, pode-se calcular a derivada de $\mathbf{g}(\hat{\mathbf{x}})$. Aproveitando o resultado de (3) e calculando sua derivada, chega-se em (4) onde a matriz $\mathbf{G}(\hat{x}^k)$ é chamada matriz de ganho com dimensão $n \times n$. Nesse contexto, surge a aplicação do método de Gauss-Newton. Assim, em cada iteração, é possível calcular o vetor variáveis de estados sendo que o critério de parada é uma tolerância que deve ser ajustada a partir da estagnação da resposta. Geralmente, o processo é finalizado quando a diferença dos valores estimados entre uma iteração e outra forem todos menores que 10^{-5} pu.

$$\hat{\mathbf{x}}^{k+1} = \hat{\mathbf{x}}^k + [\mathbf{G}(\hat{x}^k)]^{-1} [\mathbf{H}(\hat{x}^k)]^T \mathbf{R}^{-1} [\mathbf{z} - \mathbf{h}(\hat{x}^k)] \quad (4)$$

$$\mathbf{G}(\hat{x}) = [\mathbf{H}(\hat{\mathbf{x}})]^T \mathbf{R}^{-1} [\mathbf{H}(\hat{\mathbf{x}})] \quad (5)$$

Como solução, o estado operativo mais provável da rede é obtido através do cálculo das magnitudes e ângulos estimados das tensões em cada barramento do sistema, que são representados no vetor de variáveis $\hat{\mathbf{x}}$.

2.2 Detecção e identificação de erros grosseiros

Após a convergência do estimador de estados, parte-se para a avaliação dos resultados a fim de verificar a presença de dados espúrios. A detecção de erros grosseiros em sistemas de monitoramento é feita geralmente pelo teste da Chi-Quadrada (χ^2) de Pearson. A técnica da Chi-Quadrada baseia-se na observação do somatório do quadrado da diferença entre um valor observado, ou estimado, e um valor esperado.

Após a fase de detecção de erros grosseiros, parte-se para a fase de identificação cujo objetivo é filtrar de forma segura as medições que possam estar contaminadas. Para atingir tal objetivo, a identificação é realizada através do cálculo dos resíduos normalizados (Monticelli and Garcia, 1983). Da estimação de estados e das formulações da matriz \mathbf{H} é possível escrever (6) na qual $\Delta \mathbf{z}$ é o vetor resíduo das medições e $\Delta \hat{\mathbf{x}}$, o vetor resíduo das variáveis estimadas.

$$\Delta \mathbf{z} = \mathbf{H} \Delta \hat{\mathbf{x}} \quad (6)$$

O valor estimado de $\Delta \mathbf{z}$ pode ser dado por (7) na qual \mathbf{K} é cognominada matriz chapéu.

$$\Delta \hat{\mathbf{z}} = \mathbf{K} \Delta \mathbf{z} \quad (7)$$

Manipulando (4) e reorganizando (6), pode-se calcular a matriz chapéu conforme descrito em (8) cuja dimensão é $m \times m$.

$$\mathbf{K} = \mathbf{H} \mathbf{G}^{-1} \mathbf{H}^T \mathbf{R}^{-1} \quad (8)$$

Como o objetivo é apontar as medições suspeitas, pode-se calcular os resíduos entre $\Delta \mathbf{z}$ e $\Delta \hat{\mathbf{z}}$ segundo (9) onde \mathbf{I} é a matriz identidade.

$$\mathbf{r} = \Delta \mathbf{z} - \Delta \hat{\mathbf{z}} = (\mathbf{I} - \mathbf{K}) \Delta \mathbf{z} \quad (9)$$

Uma forma comum de avaliar a influência das classes de exatidão das medições é multiplicar a matriz $\mathbf{I} - \mathbf{K}$ pela matriz \mathbf{R} , originando a matriz de covariância residual descrita em (10).

$$\mathbf{\Omega} = (\mathbf{I} - \mathbf{K}) \mathbf{R} \quad (10)$$

Finalmente, pode-se calcular os resíduos normalizados de cada medição i de acordo com (11) em que Ω_{ii} é o elemento diagonal da matriz covariância residual associado à medição i .

$$r_i^N = \frac{[z_i - h_i(\hat{x})]}{\sqrt{\Omega_{ii}}} \quad (11)$$

Com os resíduos normalizados de cada medição calculados, pode-se selecionar os maiores resíduos como medições suspeitas. Então, no âmbito deste trabalho, considerando as medições advindas das PMUs no sistema IEEE 30 barras, calculam-se os resíduos normalizados e verifica-se, para cada medida, aquelas cujo resíduo normalizado é maior do que a média acrescida do desvio padrão de todos os resíduos associados às medições consideradas. Dessa forma, tem-se um grupo de medições suspeitas as quais podem estar sujeitas a erro grosseiro.

2.3 Correção de erros grosseiros

Com um grupo de dados suspeitos já detectados e identificados, parte-se para a fase de correção através de um fator de calibração λ_i , associado à cada medição suspeita, o qual será determinado pelo problema de otimização cuja função objetivo (FOB) é descrita em (12) e suas restrições em (13) e (14). Note que o valor do fator de calibração será igual a 1 caso a medição não seja suspeita. Em contrapartida, o valor deverá ser determinado pelo algoritmo de otimização, a fim de recalibrar a medição garantindo o sucesso do estimador de estados.

$$\text{Min } J(\hat{x}, \lambda) = \frac{1}{2} \cdot \sum_{i=1}^m \left(\frac{\lambda_i \cdot z_i - h_i(\hat{x})}{\sigma_i} \right)^2 \quad (12)$$

Sujeito a:

$$\lambda^{\min} \leq \lambda_i \leq \lambda^{\max} \quad (13)$$

$$\lambda_i = 1, \text{ se } z_i \notin z_{\text{suspeito}} \quad (14)$$

3. ALGORITMO DE OTIMIZAÇÃO ARITMÉTICA

A meta-heurística proposta, intitulada *Arithmetic Optimization Algorithm* ou Algoritmo de Otimização Aritmética em livre tradução da expressão inglesa, usufrui dos principais operadores matemáticos (multiplicação, divisão, subtração e adição) a fim de encontrar uma possível solução usando o conceito de inteligência populacional, ou seja, ao longo do processo iterativo as incógnitas $x_{i,j}$ são atualizadas de acordo com os parâmetros obtidos pela solução ótima x_{best} até então. Ao longo do processo, distinguem-se dois caminhos: diversificação e intensificação. A diversificação é a fase de exploração de possíveis soluções em um amplo espaço de busca enquanto a intensificação é responsável por acentuar o processo de busca ao redor de soluções subótimas, objetivando resultados de melhor qualidade (Abualigah et al., 2021).

A seguir é mostrado um pseudocódigo que esclarece o processo iterativo da otimização aritmética bem como a atualização das variáveis pelos operadores matemáticos.

Algoritmo 1 Pseudocódigo AOA

```

1: Inicializar os parâmetros  $\alpha$  e  $\mu$ .
2: Inicializar randomicamente o conjunto de soluções.
3: Enquanto ( $iter < N_{iter}$ ), faça:
4:   Calcular a FOB para cada conjunto de soluções.
5:   Obter a melhor solução  $x_{best}$ .
6:   Atualizar  $AOM(iter) = Min + iter \cdot \left( \frac{Max - Min}{N_{iter}} \right)$ .
7:   Atualizar  $OMP(iter) = 1 - \frac{iter^{\frac{1}{\alpha}}}{N_{iter}^{\frac{1}{\alpha}}}$ .
8:   para  $i = 1$  até  $N_{solucoes}$ , faça:
9:     para  $j = 1$  até  $N_{variaveis}$ , faça:
10:      Gerar valores aleatórios  $[0, 1](r_1, r_2$  e  $r_3)$ 
11:      se  $r_1 > AOM$ , então:
12:        Busca global
13:        se  $r_2 > 0,5$ , então:
14:           $x_{i,j}(iter) = x_{best}(j) \times OMP \times$ 
15:             $((UB_j - LB_j) \times \mu + LB_j)$ 
16:          senão
17:             $x_{i,j}(iter) = x_{best}(j) \div (OMP + \epsilon) \times$ 
18:               $((UB_j - LB_j) \times \mu + LB_j)$ 
19:          fim se
20:        senão
21:          Busca local
22:          se  $r_3 > 0,5$ , então:
23:             $x_{i,j}(iter) = x_{best}(j) + OMP \times$ 
24:               $((UB_j - LB_j) \times \mu + LB_j)$ 
25:            senão
26:               $x_{i,j}(iter) = x_{best}(j) - OMP \times$ 
27:                 $((UB_j - LB_j) \times \mu + LB_j)$ 
28:            fim se
29:          fim se
30:        fim para
31:      fim para
32:       $iter = iter + 1$ 
33: fim Enquanto
34: Devolve a melhor solução.

```

A escolha do espaço de busca está correlacionada com o Acelerador de Otimização Matemático (AOM) equacionado na linha 6 do pseudocódigo onde $AOM(iter)$ é o valor do acelerador de otimização matemático na iteração atual, Min e Max são seus valores mínimos e máximos respectivamente e N_{iter} é o total de iterações do processo de busca.

Outro parâmetro utilizado para atualização das variáveis é o Otimizador Matemático de Probabilidade (OMP) que está representado na linha 7 do pseudocódigo onde α é cognominado ajuste de exploração e é determinado de acordo com cada tipo de problema.

Conforme discutido e ilustrado, o espaço de busca é determinado pelo AOM enquanto que as operações em si são escolhidas em cada subespaço por valores randômicos (r_2 e r_3). Nas equações de atualização, μ é um parâmetro fixo de atualização enquanto que LB_j e UB_j são os limites inferiores e superiores de cada variável respectivamente.

4. SIMULAÇÕES

O sistema utilizado neste trabalho foi o sistema IEEE 30 barras cujos dados de barras e de linhas são encontrados em (Al-Roomi, 2015), representados pelo diagrama unifilar da Figura 1. Como o foco do trabalho é a correção de erros grosseiros em uma rede já com as PMUs alocadas, foi considerado que esse sistema é totalmente observável através da utilização de PMUs nas barras 1, 3, 5, 7, 8, 9, 10, 11, 12, 13, 15, 17, 18, 20, 21, 24, 26, 28, 29 e 30 tendo como base trabalhos específicos de alocação (Cruz, 2016). Assim, as informações mensuradas são os valores da tensão fasorial (V_k e θ_k) bem como os fluxos de potência ativa e reativa (P_{km} e Q_{km}) que saem das barras com medições sincronizadas.




Figura 1. Sistema IEEE 30 barras

Aproveitando o plano de medição definido, serão apresentados 2 casos: (i) erro grosseiro de 10 vezes o valor medido do fluxo de potência ativa entre as barras 12 e 15; (ii) erro grosseiro de 20% no módulo da tensão da barra 17 mas também erros de 5 vezes os valores medidos dos fluxos de potências ativas entre as barras 17-16 e 17-10. Em ambos os casos, os valores de erros foram escolhidos a fim de representarem um grande desvio frente ao valor real.

Para solução via otimização aritmética, serão considerados um conjunto de solução cujo tamanho é 5 vezes o número de medidas suspeitas e 100 iterações do processo de busca. Os demais parâmetros estão explicitados na Tabela 1. Os valores mínimos e máximos dos fatores de calibração recebem esse valor, uma vez que valores de tensão nunca devem violar ou chegar próximos desses limites. Ademais, os parâmetros α e μ foram definidos após ajustes finos. Por fim, os cálculos computacionais referentes à estimação de estados, ao fluxo de potência e à otimização aritmética foram implementados no MATLAB®.

Tabela 1. Parâmetros utilizados.

λ_{min}	λ_{max}	α	μ
0,1000	2,0000	4,0500	0,9900

4.1 Caso 1 - Erro grosseiro de 10 vezes o valor medido do fluxo de potência ativa entre as barras 12 e 15

A presença do erro grosseiro de tal dado espúrio, resultou na estimação errônea das tensões de várias barras con-

forme ilustrado na Figura 2 em que as magnitudes de tensão estimadas são comparadas aos valores respectivos verdadeiros (obtidos pelo fluxo de potência). Para esse caso, $J(\hat{x}) = 22463$.




Figura 2. Magnitude das tensões estimadas (Caso 1)

Após aplicar a detecção e identificação dos dados espúrios, esses foram levados para recalibração via otimização aritmética. Assim, a Tabela 2 ilustra os dados suspeitos levantados bem como as respectivas penalizações. A Figura 3 mostra a melhoria da estimação de estados após a correção. O valor final de $J(\hat{x})$ foi 6,2877.

Tabela 2. Fatores de calibração para o caso 1.

Dados suspeitos	Calibração (λ)
P_{12-14}	0,9622
P_{12-15}	0,1022
P_{12-16}	0,7950
P_{15-12}	1,0719
P_{15-14}	1,0400
P_{17-16}	1,0336
P_{18-19}	1,9444
P_{20-19}	1,1476

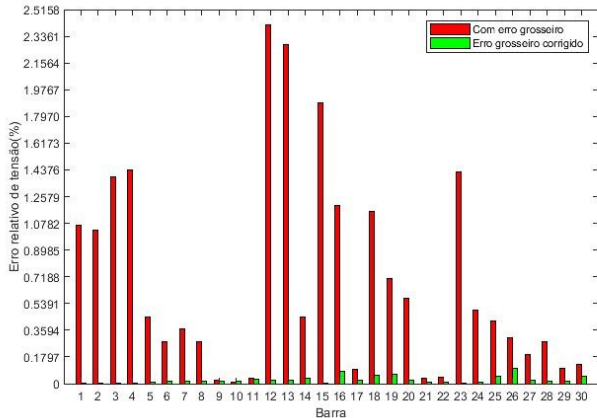


Figura 3. Erros relativos de tensão antes e após a correção para o caso 1.

4.2 Caso 2 - Erro grosseiro de 20% no módulo da tensão da barra 17 e também erro de 5 vezes os valores medidos dos fluxos de potência ativa entre as barras 17-16 e 17-10.

A presença dos erros grosseiros, resultou na estimação errônea das tensões de várias barras conforme ilustrado na Figura 4. Para essa estimação de estados, $J(\hat{x}) = 2922,23$.




Figura 4. Magnitude das tensões estimadas (Caso 2)

Após aplicar os procedimentos de detecção e identificação dos dados espúrios, esses foram tratados pela recalibração via otimização aritmética. Assim, a Tabela 3 ilustra os dados suspeitos levantados bem como as respectivas penalizações. A Figura 5 mostra a melhoria da estimação de estados após a correção. O valor final de $J(\hat{x})$ foi 3,8185.

Tabela 3. Fatores de calibração para o caso 1.

Dados suspeitos	Calibração (λ)
V_{17}	0,8391
P_{10-17}	1,0585
P_{12-16}	1,1171
P_{17-10}	0,1704
P_{17-16}	0,1322




Figura 5. Erros relativos de tensão antes e após a correção para o caso 2.

5. CONCLUSÃO

Neste artigo, foi proposto o uso do Algoritmo de Otimização Aritmética (AOA) para a correção de erros grosseiros no contexto da estimação de estados. Um problema de otimização foi modelado considerando o método dos mínimos quadrados ponderados, considerando cada medição associada a um fator de calibração cujo valor é obtido pelo uso da técnica AOA garantindo o sucesso da estimação de estados através da correção de dados espúrios presentes no plano de medição.

Foi visto que a convergência da otimização aritmética se dá sobre dois espaços de busca, trazendo atrativos na acurácia dos resultados, uma vez que há maior probabilidade de encontrar o ótimo global ou soluções subótimas de boa qualidade num tempo computacional aceitável. Também foi explicitado que a otimização aritmética dispõe de somente dois parâmetros (α e μ) para serem definidos no processo de convergência o que, tratando-se de meta-heurística, é um ponto positivo uma vez que outras técnicas apresentam muitos parâmetros a serem ajustados e estudados como: algoritmo genético, enxame de partículas, ecolocalização via algoritmo do morcego, etc. Ademais, esses parâmetros devem ser fixados inicialmente por ajuste fino uma vez que dependem de cada tipo de problema analisado.

Em relação aos casos estudados, foi possível concluir que ambos apresentaram resultados satisfatórios com a aplicação do AOA, ou seja, os erros grosseiros foram recalibrados com fatores ótimos que minimizaram a função objetivo explicitada em (12); as Figuras 3 e 5 concretizam a boa performance da meta-heurística na correção dos erros grosseiros uma vez que ilustram a diminuição dos erros relativos de tensão. No que tange ao tempo computacional, o caso 1 gastou 29,848019 segundos enquanto o caso 2 finalizou todo processo em 18,122614 segundos. Logo, a otimização aritmética também apresentou um tempo computacional convincente quando comparada a outros trabalhos de relevância da área a exemplo de (Mingorança et al., 2022) no qual os autores utilizam o Algoritmo Genético para correção de dados espúrios relatando um grande tempo computacional.

Ao analisar os resultados referentes aos fatores de calibração das medidas suspeitas, pode-se observar que as penalizações foram maiores nas medições que realmente apresentaram os erros grosseiros enquanto que nas medições sem erros, mas identificadas como suspeitas, as calibrações tenderam a apresentar correção próximo do valor unitário. Vale lembrar que as penalizações nunca foram unitárias pelo fato de neste trabalho ter sido considerado a presença de um ruído com distribuição gaussiana para ilustrar os erros aleatórios.

Finalmente, a otimização aritmética aplicada no problema de correção de erros grosseiros na estimação de estados apresentou resultados bastantes significativos frente à qualidade da solução e ao tempo computacional, oferecendo uma boa estimativa do estado operativo real da rede mesmo na presença de dados contaminados.

REFERÊNCIAS

Abualigah, L., Diabat, A., Mirjalili, S., Abd Elaziz, M., and Gandomi, A.H. (2021). The Arithmetic Optimiza-

- tion Algorithm. *Computer Methods in Applied Mechanics and Engineering*, 376, 113609.
- Abur, A. (2004). *Power System State Estimation: Theory and Implementation*. Marcel Dekker.
- Al-Roomi, A. (2015). Power Flow Test Systems Repository. <https://al-roomi.org/power-flow>.
- Ascari, L.B. (2022). *Fusão de Estimativas Resiliente a Erros Grosseiros baseada no Critério de Máxima Correntropia com Aplicação na Estimação de Estados Híbrida em Sistemas Elétricos de Potência*. D. sc., Universidade Federal de Santa Catarina (UFSC). Florianópolis.
- Augusto, A., De Souza, J.S., and Do Coutto Filho, M. (2010). Correção de erros em parâmetros de redes elétricas utilizando a técnica do recozimento simulado. *XVIII Congresso Brasileiro de Automática, Bonito*, 53–58.
- Bragança, D.L., Augusto, A.A., de Souza, J.C., Do Coutto Filho, M.B., et al. (2021). Identificação inteligente de dados críticos para a estimação de estado em sistemas de potência. In *Simpósio Brasileiro de Automação Inteligente-SBAI*, volume 1.
- Cruz, M.A.d.R.S. (2016). *Otimização da Alocação de PMUs em Redes Elétricas com Infraestrutura de Comunicações*. M. sc., Universidade Federal do Espírito Santo.
- Da Cunha, H.O., Henriques, F.d.R., and De Barros, A.L.F. (2022). Detecção e descarte de erros grosseiros obtidos na estimação de estado em linhas de transmissão. *REVISTA DE ENGENHARIA E TECNOLOGIA*, 14(3).
- Kundur, P. (1994). *Power System Stability and Control*. McGraw-Hill.
- Massignan, J.A., de Melo, V.H., and London Jr, J.B.A. (2020). Efeitos não-lineares na redundância e observabilidade em estimadores de estado para sistemas elétricos de potência. In *Congresso Brasileiro de Automática-CBA*, volume 2.
- Melo, I.D. and Antunes, M.P. (2022). Bad Data Correction in Harmonic State Estimation for Power Distribution Systems: An Approach Based on Generalised Pattern Search Algorithm. *Electric Power Systems Research*, 204, 107684.
- Melo, I.D. (2022). *Estimação de Estados: Uma Abordagem Sistêmica sobre a Qualidade de Energia*. Blucher.
- Mingorança, J.S., de Melo, I.D., Antunes, M.P., de Oliveira, B.C., and de Souza, M.A. (2022). Uma nova abordagem para correção de erros grosseiros em estimação de estados utilizando algoritmo genético. *Simpósio Brasileiro de Sistemas Elétricos-SBSE*, 2(1).
- Monticelli, A. and Garcia, A. (1983). Reliable bad data processing for real-time state estimation. *IEEE transactions on power apparatus and systems*, 1126–1139.
- Monticelli, A.J. (1983). *Fluxo de Carga em Redes de Energia Elétrica*. Edgard Blucher LTDA.
- Raposo, A.A.M., Rodrigues, A.B., and Da Silva, M.D.G. (2019). Alocação ótima de medidores para a estimação de estado considerando a reconfiguração da rede de distribuição. In *Congresso Brasileiro de Automática-CBA*, volume 1.
- Shaheen, A.M., Spea, S.R., Farrag, S.M., and Abido, M.A. (2018). A review of meta-heuristic algorithms for reactive power planning problem. *Ain Shams Engineering Journal*, 9(2), 215–231.