

Robustez de Estimadores de Estados Baseados no Critério de Máxima Correntropia Face à Ocorrência de Pontos de Alavancamento

A.C.G. Carvalho* A.J.A. Simões Costa**

* *Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina, SC, (e-mail: anacarol.eng@hotmail.com).*

** *Departamento de Engenharia Elétrica, Universidade Federal de Santa Catarina, SC, (e-mail: simoes.costa@ufsc.br)*

Abstract: This paper analyzes the influence of measurements labeled as leverage points on the performance of state estimators based on the Maximum Correntropy Criterion (MCC). In addition to previously proposed approaches, a statistically robust method for identifying leverage points that has not been applied so far to Power System State Estimation is proposed. Corrective actions to prevent the degrading effects of bad leverage points on MCC-based estimates are also explored. The performance of the proposed methodologies is evaluated through tests conducted on the IEEE 14-bus test system.

Resumo: Este artigo analisa a influência de medidas caracterizadas como pontos de alavancamento no desempenho de estimadores de estados baseado no Critério de Máxima Correntropia (CMC). Além de algumas abordagens previamente exploradas na literatura, um método estatisticamente robusto para a identificação de pontos de alavancamento ainda não aplicado à Estimação de Estados em Sistemas de Potência é introduzido. Ações corretivas para reduzir os efeitos deletérios de pontos de alavancamento ruins sobre estimativas baseadas no CMC são também exploradas. O desempenho das metodologias propostas é avaliado por meio de testes conduzidos no sistema-teste IEEE de 14 barras.

Keywords: Power System State Estimation; Leverage Points; Bad Data Identification; Maximum Correntropy Criterion; Applied Robust Statistics.

Palavras-chaves: Estimação de Estados em Sistemas de Potência; Pontos de Alavancamento; Identificação de Erros Grosseiros; Critério de Máxima Correntropia; Estatística Robusta Aplicada.

1. INTRODUÇÃO

A monitoração em tempo real das principais variáveis de um Sistema Elétrico de Potência (SEP) é fundamental para assegurar a segurança operacional. Para isso, procedimentos conduzidos nos Centros de Operação do Sistema buscam determinar com precisão as variáveis de estado (magnitudes e ângulos de fase das tensões nas barras) reais da rede elétrica (Monticelli, 1999). A Estimação de Estados em Sistemas de Potência (EESP) é a função responsável por gerar esta base de dados em tempo real confiável a partir da aquisição de telemidas redundantes, tradicionalmente provenientes do sistema de Supervisão e Aquisição de Dados (SCADA - *Supervisory Control and Data Acquisition*), como fluxos de potência nas linhas, injeções de potência ativa e reativa e magnitudes de tensão nas barras (Monticelli, 1999), (Abur e Exposito, 2004).

Entretanto, essas telemidas analógicas coletadas do SEP e processadas pelo estimador estão sujeitas a erros grosseiros, ou seja, existe a possibilidade da presença de medidas mais imprecisas do que é suposto no modelo de medição. Estas medidas espúrias levam o processo de estimação de estados a valores incorretos ou até mesmo à não convergência. Por esse motivo, é imprescindível que os estimadores sejam dotados de funcionalidades para a detecção, identificação e eliminação de erros grosseiros (Abur e Exposito, 2004). Nos estimadores tradicionais baseados nos métodos

mínimos quadrados ponderados, esses procedimentos são realizados após a obtenção das estimativas. Desse modo, mesmo na presença de uma única medida errônea, a estimação deve ser refeita, para que se obtenha resultados finais livres da influência de tais erros. Na prática, o pós-processamento para supressão de erros grosseiros e a subsequente re-estimação implicam em um significativo esforço computacional adicional.

Outro problema associado a medidas errôneas que tende a degradar o desempenho de estimadores convencionais é a tendência de falha na presença de erros grosseiros em medidas classificadas como *pontos de alavancamento*. Trata-se de medidas que são posicionalmente divergentes em relação às demais medidas projetadas no *espaço fator* das matrizes jacobianas. Em sistemas de potência, pontos de alavancamento são associados às linhas curtas (de baixa impedância) ou injeções em nós com muitos ramos adjacentes (Mili et al., 1991).

Para contornar o problema de múltiplas execuções do EE convencional presente na etapa de pós-processamento, este artigo faz uso de modelos não-quadráticos para a estimação de estados, devido às suas características robustas face à ocorrência de erros grosseiros, proporcionando maior confiabilidade ao processo de estimação de estados. O método de estimação baseado em conceitos do campo da Teoria da Informação, mais especificamente, relacionados ao Critério de Máxima Correntropia (CMC) em associação

com janelas de Parzen ajustáveis, mostra-se atraente para aplicação à EESP. Isto decorre de suas propriedades mais resilientes para expurgar automaticamente os efeitos das medidas espúrias com a vantagem adicional de não requerer um estágio de pós-processamento de erros grosseiros (Opara, 2014), (Ascari et al., 2019).

No que diz respeito a pontos de alavancamento, esse trabalho investiga a aplicação de metodologias robustas para identificação destes pontos baseadas em projeções estatísticas, sendo uma delas elaborada a partir do robustecimento da Distância de Mahalanobis e ainda não explorada na literatura, desenvolvida originalmente por (Donoho et al., 1992) e brevemente esboçada em (Mili et al., 1996). Além disso, este artigo propõe contribuições com o intuito analisar a robustez estatística dos estimadores CMC, ou seja, se estes têm a capacidade de processamento (detecção e identificação) de erros grosseiros em medidas classificadas como pontos de alavancamento. Adicionalmente, avalia-se a proposição de ações corretivas caso a estimação de estados não apresente desempenho confiável e robusto face à presença de pontos de alavancamento.

2. ESTIMADOR DE ESTADO BASEADO EM MQP

A EESP é a ferramenta responsável pela execução da Monitoração em tempo real que precede a Análise da Segurança da operação de sistemas de potência. Seu desempenho depende da disponibilidade de informações confiáveis a respeito das condições atuais de operação da rede elétrica e seus resultados permitem a atualização em tempo real do banco de dados do sistema (Abur e Exposito, 2004).

Considerando uma rede elétrica com N barras e monitorada por um conjunto de m medidas, é possível determinar os fluxos de potência em qualquer linha de transmissão e/ou a injeção de potência em qualquer barra a partir do conhecimento das tensões complexas nas barras do sistema. Estas últimas então se qualificam como as *variáveis de estado* do sistema elétrico. O modelo de medição é descrito por:

$$z = \tilde{h}(x) + \eta \quad (1)$$

onde z é o vetor ($m \times 1$) das quantidades medidas, x é o vetor ($n \times 1$) de variáveis de estado a ser estimado, $\tilde{h}(\cdot)$ é o vetor ($m \times 1$) formado pelas funções não-lineares que relacionam as quantidades medidas às variáveis do estado x e η é o vetor ($m \times 1$) de erros aleatórios de medição causados pelos transformadores de instrumentos, efeitos de conversão analógico-digital, etc. Supõe-se que o vetor de erros de medição tem distribuição normal, média zero e que os erros de medição são não-correlacionados, implicando em que a matriz de covariância R torna-se diagonal. Portanto:

$$\begin{aligned} E\{\eta\} &= 0 \\ E\{\eta\eta^T\} &= R \end{aligned} \quad (2)$$

onde $E(\cdot)$ é o operador expectância e R é a matriz de covariância ($m \times m$) dos erros de medição, suposta diagonal, cujos elementos são definidos por $R_{ii} = \sigma_{m,i}^2$.

O conjunto de medidas oriundo do plano de medição deve garantir a observabilidade do sistema, ou seja, que há informações suficientes e bem distribuídas para viabilizar a estimação de estados. Uma condição necessária para um sistema ser observável é que o índice de redundância do plano de medição ρ deve ser bem maior do que 1,0. Esse

índice é definido com base na relação da quantidade de medidas disponíveis ao estimador e o número de variáveis de estado, dado por:

$$\rho \triangleq \frac{m}{n} \quad (3)$$

onde $n = 2N - 1$ representa o número de estados estimados.

2.1 Critério dos Mínimos Quadrados Ponderados

A formulação utilizada com maior frequência para o problema de estimação de estados baseia-se no critério dos Mínimos Quadrados Ponderados. Classicamente, a solução do problema de otimização, que busca a minimização da soma ponderada dos quadrados dos resíduos, é obtida pelo método da Equação Normal de Gauss. Entretanto, métodos ortogonais de solução tem apresentado resultados com maior robustez numérica (Freitas et al., 2017).

O método dos Mínimos Quadrados Ponderados é formulado como um problema de otimização cujo objetivo é minimizar uma função custo com relação a \hat{x} baseada no modelo de medição dado em (1), como mostra a seguir:

$$\min_{\hat{x}} J_{MQP}(\hat{x}) = [z - h(\hat{x})]^T R^{-1} [z - h(\hat{x})] \quad (4)$$

A ponderação da função objetivo por R^{-1} implica em que medidas de menor variância recebem maior peso do que aquelas que apresentam maior incerteza, e, portanto, têm maior influência na solução da estimação de estados.

A solução clássica do problema (4) pode ser obtida pelo método iterativo de Gauss-Newton, que resolve a seguinte equação linear em cada iteração:

$$(H^T R^{-1} H) \Delta x = H^T R^{-1} \Delta z \quad (5)$$

onde H é a matriz jacobiana ($m \times m$) das funções não-lineares $\tilde{h}(\cdot)$ calculada em um determinado ponto x^k , e $\Delta z = z - \tilde{h}(x^k)$. No final de cada iteração as variáveis de estado são atualizadas como:

$$x^{k+1} = x^k + \Delta x \quad (6)$$

A solução acima é eficaz sob a suposição de análise sem a presença de erros grosseiros, já que o método MQP é extremamente sensível à influência de medidas espúrias. Consequentemente, é necessário um estágio de pós-processamento para lidar com dados incorretos. Os métodos convencionais para identificação de medidas errôneas dependem de resíduos normalizados, que são computados como:

$$r_i^N = \frac{|r_i|}{\sqrt{\Omega_{ii}}} \quad (7)$$

onde Ω é a matriz de covariância dos resíduos (Monticelli, 1999). O Método do Máximo Resíduo Normalizado é então aplicado repetidamente por meio de ciclos sucessivos de estimação - detecção - eliminação até que todas as medidas espúrias sejam removidas (Abur e Exposito, 2004). Essa dificuldade motiva a busca de novos algoritmos capazes de suprimir efeitos nocivos de dados errôneos ainda durante a etapa de estimação. Na seção a seguir, um método de estimação baseado no CMC, que cumpre esse objetivo,

é apresentado como uma alternativa ao estimador MQP convencional.

3. ESTIMADOR DE ESTADO BASEADO EM MÁXIMA CORRENTROPIA (CMC)

O conceito de Correntropia está associado à maximização da similaridade entre duas variáveis aleatórias em uma vizinhança pré-determinada do espaço amostral. A citada vizinhança é controlada pela largura de uma função *kernel* Gaussiana cuja variância determina a “janela de observação” onde a semelhança é avaliada (Liu et al., 2006). Ao aplicar esse princípio à EESP, o objetivo é maximizar a informação que pode ser extraída das medidas disponíveis.

Desse modo, a importância é avaliar a similaridade entre o vetor de m medidas disponíveis (z) e o vetor de medidas estimadas ($\hat{z} = \hat{h}(\hat{x})$). Logo, a função correntropia $\hat{\nu}$ entre os conjuntos de quantidades medidas e estimadas é definida como:

$$\hat{\nu}(z, \hat{z}) = \frac{1}{m} \sum_{i=1}^m G_{\sigma_i}(z_i - \hat{z}_i) \quad (8)$$

onde G_{σ_i} é o *kernel* Gaussiano com desvio padrão σ_i , parâmetro responsável por estabelecer a largura do *kernel*, controlando a janela de observação para a medição i (Parzen, 1962), computado como:

$$G_{\sigma_i}(z_i - \hat{z}_i) = \frac{1}{\sqrt{2\pi}\sigma_i} e^{-\frac{(z_i - \hat{z}_i)^2}{2\sigma_i^2}} \quad (9)$$

Matematicamente, o problema de EESP baseado no CMC é dado então por:

$$\max_{\hat{x}} J_{CMC}(\hat{x}) = \sum_{i=1}^m R_{ii}^{-1} e^{-\frac{(z_i - \hat{z}_i)^2}{2\sigma_i^2}} \quad (10)$$

A solução do problema (10) se baseia em uma equação cuja forma é semelhante à equação normal de Gauss (5):

$$H^T W H \Delta x = H^T W \Delta \tilde{z} \quad (11)$$

onde (Freitas et al., 2017),

$$W \triangleq D[I - R_p]; \quad R_W(i, i) = (z_i - \hat{z}_i)^2 / \sigma_i^2 \\ \Delta \tilde{z} \triangleq [I - R_p]^{-1} \Delta z; \quad D(i, i) = \frac{R_{ii}^{-1}}{\sigma_i^2} e^{-(z_i - \hat{z}_i)^2 / 2\sigma_i^2} \quad (12)$$

Neste artigo adota-se o método de solução alternativo a (11), o qual faz uso de um algoritmo ortogonal baseado nas Rotações de Givens. O objetivo é conferir robustez numérica à solução, tendo em vista o mau condicionamento numérico das soluções clássicas baseadas em equações normais similares a (11) (Simões Costa e Quintana, 1981).

3.1 Janelas de Parzen

Como dito anteriormente, o desvio-padrão define a largura das janelas de Parzen e está diretamente relacionado à seletividade da função-objetivo do CMC, destinada a rejeitar os valores discrepantes contidos no conjunto de dados submetidos ao estimador. Para isso, a largura da janela de Parzen é ajustada como função dos resíduos

das medidas a cada iteração do procedimento de solução (Freitas et al., 2017). O procedimento de ajuste é descrito a seguir.

Inicializa-se o processo com um elevado valor de σ , ou seja, com uma ampla janela de observação. Nessa situação, as estimativas produzidas pelo estimador CMC são similares ao método convencional quadrático. Ao longo do processo, o valor da largura das janelas de Parzen, σ decresce, de acordo com uma regra estabelecida em função das magnitudes dos resíduos. O objetivo é reduzir a influência de possíveis dados discrepantes resultantes de erros grosseiros presentes nas medidas submetidas ao estimador.

Neste artigo o ajuste das janelas de Parzen é feito individualmente através do valor atual do resíduo normalizado máximo, ponderado pelo desvio-padrão do resíduo correspondente a cada medida, conforme (13):

$$\sigma_i^{k+1} = \sqrt{\Omega_{ii}} \cdot \max_j \left(\frac{|z_j - h_j(x)|}{\sqrt{\Omega_{jj}}} \right), i, j \in \{1, \dots, m\} \setminus S^k \quad (13)$$

em que S^k é o conjunto de medidas suspeitas, determinado na iteração atual, e o símbolo “\” significa a diferença entre conjuntos. O conjunto S é iniciado como $S^{(0)} = \emptyset$.

As medições cujo valor absoluto do respectivo resíduo excede a largura do *kernel* gaussiano tornam-se parte dos dados suspeitos em S . Para estas medidas, a atualização da janela de Parzen é diferente de (13), para reduzir a influência de um erro grosseiro sobre outros resíduos de outras medidas. Portanto, para as medidas em S , o parâmetro σ_i a ser usado na próxima iteração é:

$$\sigma_i^{k+1} = \lambda_s \sqrt{R_{ii}}, i \in S^k \quad (14)$$

onde λ_s é definido como o número de desvios-padrão da medida para os quais a medida i ainda pode ser considerada aceitável. Neste artigo, utiliza-se $\lambda_s = 3$, o que corresponde a um nível de significância de cerca de 0.3% (Liu et al., 2006).

4. PONTOS DE ALAVANCAMENTO EM SISTEMAS DE POTÊNCIA

Seja h_i , a i -ésima linha da matriz Jacobiana referente às funções não-lineares do modelo de medição em (1), o par (h_i, z_i) representa uma observação, e h_i pertence a um espaço n -dimensional chamado *espaço fator de regressão*. Os elementos h_i do espaço fator posicionalmente discrepantes dos demais elementos deste espaço são chamados *pontos de alavancamento* (Mili et al., 1991). Em estimação de estados em sistemas de potência, pontos de alavancamento geralmente estão associados a ramos cuja reatância é bem menor que a da maior parte dos ramos, seja através de medidas de fluxo no próprio ramo, seja via medidas de injeção em barras em que este incide. Outra possibilidade é em medidas de injeção em barras cujo grau é elevado.

A questão dos pontos de alavancamento no problema de EESP é que o resíduo de uma medição correspondente a um ponto de alavancamento tende a ser pequeno, mesmo quando a medida estiver contaminada por um grande erro (Abur e Exposito, 2004). Consequentemente, tal medida se comporta de forma quase similar a uma medida crítica (cujo resíduo é nulo), embora se diferencie desta pelo fato de não necessariamente acarretar na perda de observabilidade ao ser excluída do plano de medição. Desse modo, os

métodos tradicionais de detecção e identificação de erros grosseiros tendem a falhar na identificação dos pontos de avançamento contaminados, comprometendo o resultado de estimação (Zhao e Mili, 2018).

A seguir, são apresentados dois métodos para identificação de pontos de avançamento no problema de EESP. O primeiro deles, descrito na Seção 4.1, é de particular interesse pois, embora brevemente descrito em (Mili et al., 1996), não se tem notícia de sua operacionalização e aplicação à EESP, como será feito neste artigo.

4.1 Distância de Mahalanobis Robusta

Para identificar medidas que são discrepantes das demais no *espaço fator*, é necessário medir a distância de cada ponto (no caso, um componente do espaço fator de H) em relação ao centro de massa dos pontos amostrais. Intuitivamente, quanto mais próximo estiver o ponto em questão deste centro de massa, mais provável é que pertença ao conjunto. Essa distância é calculada convencionalmente pela Distância de Mahalanobis, que utiliza a média da amostra, correspondente a esse centro, e o desvio-padrão. Como se sabe, valores médios (quando usados como estimadores de posição) e desvios-padrão (como estimadores de dispersão) são fortemente afetados pela presença de *outliers* entre as amostras (Leys et al., 2013). Consequentemente, essa metodologia clássica não é robusta, pois sua dependência do conceito de valores médios pode comprometer a detecção de observações divergentes ou até classificar como discrepantes dados válidos (Rousseeuw e Hubert, 2011). Para evitar esses efeitos, o objetivo de estatísticas robustas é encontrar resultados próximos aos que seriam obtidos sem a influência de valores largamente diferentes.

O método referido como *Distância de Mahalanobis Robusta* (DMR) foi inicialmente proposto por (Donoho et al., 1992) e posteriormente citado em (Mili et al., 1996), mas ainda não explorado na literatura relacionada à EESP. Na DMR, utilizam-se como estimadores robustos de posição e escala a mediana amostral e o desvio absoluto da mediana (MAD, da sigla em inglês *Median Absolute Deviation*), respectivamente. A DMR para a i -ésima linha da matriz H é calculada da seguinte maneira:

$$DMR_i = \max_i \frac{|h_i \cdot h_j^T - \text{median}(h_1 \cdot h_j^T, \dots, h_m \cdot h_j^T)|}{MAD(h_1 \cdot h_j^T, \dots, h_m \cdot h_j^T)} \quad (15)$$

em que

$$MAD = 1,4826 \text{med}_i \left| h_i \cdot h_j^T - \text{med}_j(h_j \cdot h_i^T) \right| \quad (16)$$

Os pontos de avançamento são então identificados quando a Distância de Mahalanobis Robusta (DMR_i) excede um valor limiar (b_{MAD}), sugerido por (Majumdar e Pal (2016)) e calculado da seguinte maneira:

$$b_{MAD} = \text{Mediana}(DMR_i) + 3MAD(DMR_i) \quad (17)$$

4.2 Índice de Estatística de Projeção

O índice de estatística de projeção de cada medida, Ep_i , pode ser definido como sendo a maior distância resultante da projeção do segmento de reta que une o i -ésimo ponto

do espaço fator à mediana do conjunto de pontos disponíveis, sobre todos os segmentos de reta igualmente obtidos para os demais pontos (Croux e Rousseeuw, 1992). Em outras palavras, o índice Ep_i determina o quão distante cada linha da matriz Jacobiana está em relação ao conjunto formado por todas as demais linhas dessa matriz. Dessa forma, com base em (Mili et al., 1996), é recomendado que o cálculo dos índices de estatística de projeção sejam realizados a partir da seguinte equação:

$$Ep_i = \max_k \frac{|h_i \cdot h_k^T|}{Es_k}, \text{ para } i, k = 1, \dots, m \quad (18)$$

onde h é um vetor linha da matriz Jacobiana e Es_k é o estimador de escala correspondente ao k -ésimo ponto do espaço fator. Este estimador de escala tem a função de padronizar as projeções e é calculado como (Mili et al., 1996):

$$Es_k = c_k \cdot 1,1926 \text{lomed}_{i \neq j} |h_i \cdot h_k^T + h_j \cdot h_k^T| \quad (19)$$

em que c_k é um fator de correção definido como (Croux e Rousseeuw, 1992):

Tabela 1. Fator de correção

m	2	3	4	5	6	7	8	9
c_k	0,74	1,85	0,95	1,35	0,99	1,19	1,01	1,13

para $m \leq 9$, e para $m > 9$ é dado por:

$$c_k = \frac{m}{m - 0,9} \text{ para } m \text{ ímpar} \quad (20)$$

$$c_k = 1 \text{ para } m \text{ par.}$$

Em (19), “*lomed*” significa a *mediana baixa*, ou seja, é o elemento que ocupa a $\lfloor (m+1)/2 \rfloor$ -ésima posição do conjunto de m dados disponíveis em ordem crescente (Croux e Rousseeuw, 1992).

A identificação das medidas caracterizadas como pontos de avançamento baseia-se na comparação individual dos índices de estatística de projeção (Ep_i) com um valor limiar correspondente (b_i). Como as estatísticas de projeção se comportam aproximadamente como uma distribuição normal multivariada, pode-se definir o limiar b_i como uma função da distribuição do Qui-quadrado ($X_{v,97,5\%}^2$) com percentil de 97,5% e número de graus de liberdade em função do número de elementos não-nulos da i -ésima linha da matriz Jacobiana (Mili et al., 1996). Portanto, a i -ésima medida é considerada ponto de avançamento quando satisfaz a seguinte condição:

$$Ep_i > b_i = X_{v,97,5\%}^2 \quad (21)$$

4.3 Estratégia de Correção

A forma pela qual as medidas caracterizadas como pontos de avançamento são incorporadas ao problema de EESP de modo a corrigir o distanciamento em relação à mediana, baseia-se na atribuição de pesos adicionais a tais medidas. O objetivo é subponderá-las durante a execução do algoritmo de solução do estimador deve ser capaz de subponderá-las. O cálculo dos fatores de pesos adicionais é feito da seguinte forma (Mili et al., 1996):

No último caso, a medida portadora do erro grosseiro é aleatoriamente escolhida entre as medidas regulares.

Para cada um dos cinco casos, são considerados dois cenários: (a) sem a implementação do mecanismo de subponderação individual w_i dado por (22) para os pontos de alavancamento previamente identificados; e (b) com subponderação. Além disso, para cada cenário, é realizada uma bateria de 100 simulações que se distinguem uma das outras por *realizações distintas dos ruídos de medição* η referidos no modelo dado em (1). O valor da magnitude do erro grosseiro considerado em todos os casos é de 15 desvios-padrão.

Os resultados relativos à eficiência de identificação de medidas errôneas são expressos como a porcentagem das simulações computacionais que obtiveram sucesso, ou seja, quando o estimador exclui apropriadamente a medida simulada com erro grosseiro. Quando são utilizados estimadores não equipados com ações corretivas, é esperado que medidas portadoras de erro grosseiro classificadas como ponto de alavancamento não sejam reconhecidas como errônea e portanto não sejam removidas do processo de estimação, uma vez que seus efeitos são camuflados pelo fato de apresentarem resíduos pequenos. Já ao se considerar a estratégia corretiva via matriz diagonal de subponderação, espera-se que os efeitos do ponto de alavancamento sejam amenizados.

Tabela 2. Eficiência do algoritmo face aos pontos de alavancamento ruins

Casos	Medidas Errôneas	Sem Subponderação	Com Subponderação
I	P_5^*	1%	78%
II	Q_5^*	6%	100%
III	T_{1-2}^*	57%	100%
IV	P_7^*	1%	98%
V	U_{4-3}	100%	100%

Os resultados dos cinco casos são apresentados na Tabela 2. As medidas classificadas como pontos de alavancamento são indicadas com um asterisco. No cenário (a) descrito acima, o algoritmo apresenta baixa eficiência para os quatro primeiros casos em que as medidas contaminadas por erro grosseiro são também pontos de alavancamento. Isto significa que o estimador CMC não apresenta bom desempenho face à presença de pontos de alavancamento ruins. Diante disso, procura-se aprimorar a performance do estimador mediante a redução dos pesos atribuídos aos pontos de alavancamento, conforme a Subseção 4.3. Desse modo, os casos foram submetidos ao cenário (b) em que há tratamento dos pontos de alavancamento previamente detectados. Novas simulações foram feitas considerando a subponderação das medidas identificadas como pontos de alavancamento. Como resultado, o algoritmo consegue alcançar alta eficiência, produzindo expressiva melhoria no desempenho do estimador CMC. Por fim, o último caso da Tabela 2 é referente à medida espúria U_{1-2} . O objetivo é apresentar a diferença de funcionamento do estimador em casos em que o erro grosseiro ocorre em medida não identificada como ponto de alavancamento. Como pode ser concluído da tabela, alcança-se bom desempenho independentemente do cenário.

Também é verificado o desempenho das estratégias propostas mediante o cálculo dos erros absolutos dos estados estimados (com relação aos resultados do fluxo de potência) pelo método CMC. Para tal, comparam-se resultados em que os pontos de alavancamento são ou não tratados. Os erros são calculados tanto para as magnitudes quanto para os ângulos de fase das tensões nodais, como mostram as Figuras 4 e 5, respectivamente. As figuras representam

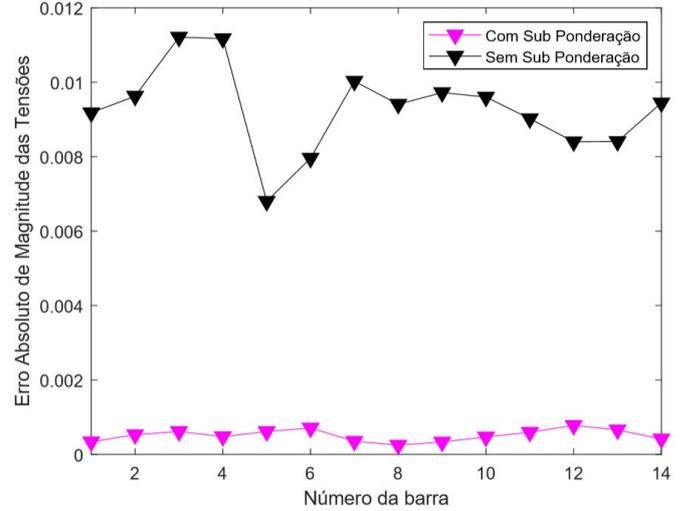


Figura 4. Erros de Magnitude da Tensão.

estes erros para o caso em que há a presença de erro grosseiro na medida de injeção Q_5 , caso que é considerado típico dentre todos os simulados.

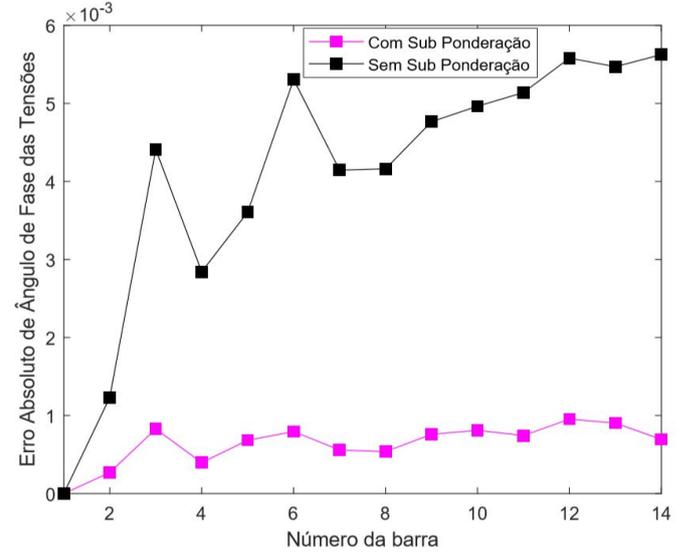


Figura 5. Erros de Ângulo de Fase das Tensões.

Por fim, para ter um índice global que compare o desempenho nos dois cenários, é utilizada uma métrica de tensão nodal proposta anteriormente em (KEMA, 2006), dada por:

$$M_V = \left(\frac{1}{n} \sum_{i=1}^n |\vec{V}_i^{est} - \vec{V}_i^{verd}|^2 \right)^{(1/2)} \quad (23)$$

onde \vec{V}_i^{est} e \vec{V}_i^{verd} são os fasores estimados e reais das tensões das barras, respectivamente. Os valores das métricas apresentados na Tabela 3 são obtidos aplicando o índice de desempenho definido em (23) aos resultados apresentados nas Figuras 4 e 5.

6. CONCLUSÃO

O objetivo deste artigo é analisar a influência de erros grosseiros em medidas classificadas como pontos de alavan-

Tabela 3. Valores da métrica das tensões nas barras com e sem subponderação

Casos	Sem	Com
	Subponderação	Subponderação
I	$3,80 \times 10^{-2}$	$8,15 \times 10^{-4}$
II	$1,04 \times 10^{-2}$	$8,9 \times 10^{-4}$
III	$4,20 \times 10^{-2}$	$9,66 \times 10^{-4}$
IV	$7,6 \times 10^{-2}$	$1,2 \times 10^{-2}$
V	$3,5 \times 10^{-2}$	$3,3 \times 10^{-2}$

camento sobre o desempenho de estimadores de estados baseados no Critério de Máxima Correntropia (CMC). Estes estimadores são conhecidos pelas suas propriedades superiores de supressão automática dos efeitos de medidas errôneas sobre as estimativas. Entretanto, a literatura ainda não apresenta estudos de sua sensibilidade à ocorrência de erros grosseiros em pontos de alavancamento. As análises preliminares relatadas neste artigo confirmam que tal sensibilidade de fato existe, embora estratégias corretivas similares às adotadas para estimadores de mínimos quadrados mostrem-se também eficazes para estimadores CMC. O artigo também explora um novo método para a identificação de pontos de alavancamento baseado no robustecimento estatístico da Distância de Mahalanobis previamente proposto na literatura de Estatística Robusta, mas ainda não aplicado no âmbito da Estimação de Estados em Sistemas de Potência. O método mostrou-se ser tão eficiente quanto o tradicional procedimento mais conhecido, fundamentado no conceito de estatística de projeção. Propõe-se para pesquisas futuras uma metodologia de correção embasada na DMR. O algoritmo de estimação de estados resultante, baseado no Critério de Máxima Correntropia, porém dotado das estratégias corretivas acima mencionadas, mostra-se capaz de suprimir erros grosseiros, independentemente destes ocorrerem ou não em medidas classificadas como pontos de alavancamento.

AGRADECIMENTOS

Os autores agradecem o suporte da CAPES via Programa de Pós-Graduação em Engenharia Elétrica da UFSC. A. Simões Costa também reconhece o apoio financeiro do CNPq, mediante Processo No. 313468/2018-4.

REFERÊNCIAS

- Abur, A. e Exposito, A.G. (2004). *Power system state estimation: theory and implementation*. CRC press.
- Ascari, L.B., Simões Costa, A., e Miranda, V. (2019). Correntropy-based fusion strategy for incorporating pmu measurements into power system state estimation. In *2019 IEEE Milan PowerTech*, 1–6. IEEE.
- Croux, C. e Rousseeuw, P.J. (1992). Time-efficient algorithms for two highly robust estimators of scale. In *Computational statistics*, 411–428. Springer.
- Donoho, D.L., Gasko, M., et al. (1992). Breakdown properties of location estimates based on halfspace depth and projected outlyingness. *The Annals of Statistics*, 20(4), 1803–1827.
- Freitas, V., Simões Costa, A., e Miranda, V. (2017). Robust state estimation based on orthogonal methods and maximum correntropy criterion. In *2017 IEEE Manchester PowerTech*, 1–6. IEEE.
- KEMA (2006). Metrics for determining the impact of phasor measurements on power system state estimation. *DRAFT*.
- Leys, C., Ley, C., et al. (2013). Detecting outliers: Do not use standard deviation around the mean, use absolute deviation around the median. *Journal of Experimental Social Psychology*, 49(4), 764–766.

- Liu, W., Pokharel, P.P., e Principe, J.C. (2006). Correntropy: A localized similarity measure. In *The 2006 IEEE international joint conference on neural network proceedings*, 4919–4924. IEEE.
- Majumdar, A. e Pal, B.C. (2016). Bad data detection in the context of leverage point attacks in modern power networks. *IEEE Transactions on Smart Grid*, 9(3), 2042–2054.
- Mili, L., Phaniraj, V., e Rousseeuw, P.J. (1991). Least median of squares estimation in power systems. *IEEE Transactions on Power Sysucms*, 6(2).
- Mili, L., Cheniae, M., et al. (1996). Robust state estimation based on projection statistics [of power systems]. *IEEE Transactions on Power Systems*, 11(2), 1118–1127.
- Monticelli, A. (1999). *State estimation in electric power systems: a generalized approach*. Springer Science & Business Media.
- Opara, J.K. (2014). *Information theoretic state estimation in power systems*. Ph.D. thesis, Universidade do Porto (Portugal).
- Parzen, E. (1962). On estimation of a probability density function and mode. *The annals of mathematical statistics*, 33(3), 1065–1076.
- Rousseeuw, P.J. e Hubert, M. (2011). Robust statistics for outlier detection. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1(1), 73–79.
- Simões Costa, A., Piazza, T.S., e Mandel, A. (1990). Qualitative methods to solve qualitative problems in power system state estimation. *IEEE transactions on power systems*, 5(3), 941–949.
- Simões Costa, A. e Quintana, V. (1981). An orthogonal row processing algorithm for power system sequential state estimation. *IEEE Transactions on Power Apparatus and Systems*, 3791–3800.
- Washington University (1999). Power systems test case archive. <http://www.ee.washington.edu/research/pstca/>. Accessed: 2019-11-03.
- Zhao, J. e Mili, L. (2018). Vulnerability of the largest normalized residual statistical test to leverage points. *IEEE Transactions on Power Systems*, 33(4), 4643–4646.