ARQUITETURA HÍBRIDA E CRITÉRIO DE MÁXIMA CORRENTROPIA PARA INCLUSÃO DE MEDIDAS FASORIAIS NA ESTIMAÇÃO DE ESTADOS EM SISTEMAS DE POTÊNCIA

Victor Freitas*, Antonio Simões Costa*, Vladimiro Miranda†

*Grupo de Sistemas de Potência
Universidade Federal de Santa Catarina
Florianópolis, SC, Brasil

†INESC TEC e Faculdade de Engenharia da Universidade do Porto
Porto, Portugal

Emails: victor.silva@posgrad.ufsc.br, simoes.costa@ufsc.br, vmiranda@inesctec.pt

Abstract— This paper addresses the development of a hybrid and robust estimation architecture for effectively combining the availability of SCADA data with synchronized phasor measurements. The proposed approach considers two estimation stages: the first one is a conventional SCADA-based state estimator, whereas the second stage treats the resulting estimates as *a priori* state information in order to improve their quality by cumulatively processing available phasor measurements. Resilience to the occurrence of bad data is achieved through the use of a Maximum Correntropy-based state estimation algorithm in the second stage. It allows the automatic rejection of outliers possibly present in both PMU measurements and state *a priori* information produced by contaminated SCADA measurements. The performance of the proposed methodology is assessed through tests conducted on the IEEE 14-bus and 57-bus test systems.

Keywords— Power system state estimation, Hybrid state estimation, Maximum correntropy criterion, PMU measurements.

Resumo— Este trabalho propõe uma arquitetura de estimação robusta e híbrida, para combinar medidas SCADA com medidas fasoriais sincronizadas. Para tal, considera-se uma estimação em dois estágios: o primeiro utiliza um estimador convencional, baseado em medidas SCADA, enquanto o segundo estágio trata as estimativas resultantes como informações *a priori*, de modo a melhorar a saída do estimador através do processamento sequencial das medidas fasorais. A resiliência é obtida pelo uso de um estimador baseado na Máxima Correntropia no segundo estágio. Isto permite rejeitar automaticamente os erros grosseiros presentes em medidas PMU e/ou informações *a priori* de estado, produzidas por medidas SCADA contaminadas. O desempenho do método proposto é avaliado com base em simulações realizadas a partir dos sistemas-teste de 14 e 57 barras do IEEE.

Palavras-chave— Estimação de estados em sistemas de potência, Estimação de estados híbrida, Critério de máxima correntropia, Medidas PMU.

1 Introdução

A utilização de medidas fasoriais sincronizadas obtidas a partir de Unidades de Medição Fasorial (PMU) na Estimação de Estados em Sistemas de Potência (EESP) é um tópico de muito interesse tanto em círculos acadêmicos quanto na indústria. O processamento de tais medidas pode melhorar significativamente a qualidade dos resultados da estimação de estados mediante sua integração com medidas convencionais, obtidas através do sistema SCADA. Durante as últimas décadas, diversos métodos foram desenvolvidos para promover tal integração, como as propostas realizadas por (Zhou et al., 2006; Simões Costa and Albuquerque, 2011; Simões Costa et al., 2013). Estes trabalhos preservam os estimadores de estados convencionais, os quais processam somente medidas SCADA, e utilizam arquiteturas de estimação em que o processamento de medidas fasoriais são realizadas separadamente. Os resultados deste segundo módulo de estimação são combinados com as estimativas baseadas em medidas SCADA, obtidas por estimadores baseados no critério dos Mínimos Quadrados Ponderados (MQP). Métodos distintos de integração dos estimadores são reportados nos trabalhos acima. Embora todos confirmem as vantagens de integração entre as medidas SCADA e PMU, e a despeito de contribuições importantes relatadas na literatura (Do Coutto Filho et al., 2014), o processamento de erros grosseiros em conexão com arquiteturas híbridas ainda mantem-se como um problema que merece esforços adicionais de pesquisa.

Algoritmos resilientes que visam a eliminação de erros grosseiros ainda na fase de estimação de estados, e portanto sem a necessidade de estágios de pós-processamento, têm sido desenvolvidos com base na Teoria da Informação (Liu et al., 2006), e recaem na associação dos conceitos de Correntropia e janelas de Parzen (Miranda et al., 2009). O critério de máxima correntropia (MCC, da sigla em Inglês) permite obter estimativas que são mais aderentes às medidas observadas, sendo portanto uma alternativa atrativa em relação ao método MQP. Sob o MCC, o conjunto de medidas a serem processadas é restrito a uma região definida pelas janelas de Parzen, que são ajustadas iterativamente de tal forma a rejeitar automaticamente os erros grosseiros (Miranda et al., 2009). Na prática, a solução é obtida por uma equação cuja forma é similar à Equação Normal do método MQP, exceto pelo fato relevante de que os pesos das medidas variam ao longo das iterações (Wu et al., 2011; Freitas et al., 2017).

Este trabalho alia os algoritmos resilientes a erros grosseiros, baseados no conceito de máxima correntropia, à estimação híbrida utilizando medidas SCADA e PMU. O objetivo é dotar o estimador híbrido resultante da capacidade de rejeitar automaticamente os efeitos de erros grosseiros possivelmente presentes nas duas classes de medidas, de modo que os resultados finais da estimação não se apresentem contaminados por nenhum tipo de dado espúrio. A arquitetura de estimação utilizada para este fim trata as estimativas obtidas com medidas SCADA como informações *a priori* para o módulo de estimação que processa medidas fasoriais, e é referido como estimador APSI (Simões Costa and Albuquerque, 2011). Adicionalmente, a solução é obtida através da versão com três-multiplicadores das Rotações de Givens (Gentleman, 1973), que é capaz de processar informações *a priori* sem esforço computacional extra.

A proposta assume que as estimativas obtidas com base em medidas SCADA, processadas por um estimador existente baseado no método MQP, não necessariamente estão livres da contaminação por erros grosseiros. Em outras palavras, leva-se em conta a possibilidade de medidas errôneas não terem sido devidamente eliminadas no estágio de detecção/identificação. O estimador APSI é um segundo módulo de estimação que recebe as estimativas SCADA como informação de estado *a priori* e processa somente medidas PMU, com o objetivo de melhorar a qualidade das estimativas finais. Neste trabalho, propõe-se o uso do algoritmo MCC no segundo módulo de estimação, o que permite a rejeição de dados espúrios tanto entre as medidas fasoriais sincronizadas de tensão e de corrente quanto nas informações de estado *a priori* fornecidas pelo estimador SCADA existente. Adicionalmente, a metodologia proposta não impõe restrições de observabilidade da rede elétrica com relação às medidas fasoriais, o que é relevante do ponto de vista prático em razão do natureza incremental do processo de instalação de medidas PMU nas redes elétricas na maioria dos países do mundo, incluindo o Brasil.

Este artigo é organizado da seguinte forma. A Seção 2 apresenta alguns fundamentos de EESP baseados nos métodos MQP e MCC. As Seções 3 e 4 descrevem a inclusão de informações *a priori* no estimador MCC e a solução através do algoritmo de versão rápida das Rotações de Givens, respectivamente. A arquitetura híbrida de estimação e o processamento de erros grosseiros são apresentados na Seção 5. A Seção 6 apresenta resultados numéricos e a análises de desempenho com base em estudos de caso através dos sistema-teste do IEEE de 14 e 57 barras, e as conclusões finais são sumarizadas na Seção 7.

2 Abordagens para a Estimação de Estados: Mínimos Quadrados Ponderados e Máxima Correntropia

2.1 Estimador de Estados MQP e Método de Gauss-Newton

A EESP fornece estimativas para as variáveis de estado através do processamento de medidas remotas coletadas da rede elétrica. Considerando um conjunto de medidas de um sistema de energia com N barras, o modelo não-linear que relaciona as medidas com as variáveis de estado é dado por:

$$\mathbf{z} = \mathbf{h}(\mathbf{x}) + \boldsymbol{\eta} \tag{1}$$

onde $\mathbf{x}$ é o vetor $n \times 1$ de variáveis de estado e $\mathbf{z}$, $\boldsymbol{\eta}$ e $\mathbf{h}(\mathbf{x})$ são os vetores $m \times 1$ de medidas, erros de medição, e de funções não-lineares das medidas, respectivamente. Os erros de medição são assumidos não-correlacionados, com distribuição normal, média zero e a matriz de covariância diagonal $\mathbf{R}$, cujo i-ésimo elemento é a variância conhecida da medida i. O número de variáveis de estados é dado por $n = 2N - 1$.

O problema é tradicionalmente formulado pelo método MQP:

$$\min_{\hat{\mathbf{x}}} J_{MQP}(\hat{\mathbf{x}}) = \mathbf{r}^T \mathbf{R}^{-1} \mathbf{r} \tag{2}$$

onde $\mathbf{r} = \mathbf{z} - \mathbf{h}(\hat{\mathbf{x}})$ é o vetor de resíduos estimados.

O Problema (2) pode ser resolvido do método de Gauss-Newton, no qual o seguinte sistema linear deve ser resolvido a cada iteração (Monticelli, 1999):

$$\mathbf{G}\boldsymbol{\Delta}\mathbf{x} = \mathbf{H}^T \mathbf{R}^{-1} \boldsymbol{\Delta}\mathbf{z} \tag{3}$$

onde $\mathbf{G} = \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H}$ é a matriz ganho; $\mathbf{H}$ é o Jacobiano $m \times n$ de $\mathbf{h}(\mathbf{x})$ calculada no ponto $\mathbf{x}^k$, e $\boldsymbol{\Delta}\mathbf{z} = \mathbf{z} - \mathbf{h}(\mathbf{x}^k)$. Ao final de cada iteração, o vetor de estados estimados é atualizado de acordo com (4):

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \boldsymbol{\Delta}\mathbf{x} \tag{4}$$

Após a convergência, a matriz de covariância dos erros de estimação pode ser computada como (Monticelli, 1999):

$$\boldsymbol{\Sigma} = \mathbf{G}^{-1} = (\mathbf{H}^T \mathbf{R}^{-1} \mathbf{H})^{-1}. \tag{5}$$

Os elementos da diagonal de $\boldsymbol{\Sigma}$ podem ser interpretados como uma medida de precisão das estimativas dos estados (Swerling, 1971; Monticelli, 1999).

2.2 Estimador de Estados Baseado em Máxima Correntropia

A Correntropia $\hat{\mathcal{V}}$ considera o conjunto de medidas dado por m observações, e definido como:

$$\hat{\mathcal{V}}(\mathbf{r}) = \frac{1}{m} \sum_{i=1}^{m} G_\sigma(r_i, \sigma^2) \tag{6}$$

onde G_σ é um *kernel* Gaussiano com desvio-padrão σ e $r_i = z_i - h_i(\hat{\mathbf{x}})$ o resíduo para a i-ésima medida.

Considerando a equação em (6) como modelo de otimização para EESP, o Critério de Máxima Correntropia (MCC) visa a maximização sobre a soma de *kernels* Gaussianos, cuja forma explicita a função densidade de probabilidade (fdp) de cada resíduo. Desta forma, desconsiderando os termos constantes e introduzindo o inverso das variâncias como ponderação para levar em conta a importância relativa de cada medida, a equação (6) pode ser reescrita:

$$\max_{\hat{\mathbf{x}}} \mathcal{V} = \sum_{i=1}^{m} R_{ii}^{-1} e^{-\frac{(z_i - h_i(\hat{\mathbf{x}}))^2}{2\sigma_i^2}} \tag{7}$$

em que σ_i é o parâmetro que controla a largura do *kernel* Gaussiano da medida i. Este parâmetro pode variar durante o processo iterativo de maximização de $\mathcal{V}$ de forma a controlar a largura das janelas de Parzen (Liu et al., 2006). Este controle permite que o método MCC possa rejeitar automaticamente os efeitos provocados por possíveis erros grosseiros presentes no conjunto de medidas. Para tal, σ_i deve ser inicializado com um valor alto suficiente para englobar todos os resíduos no processo de estimação de estados. Nas iterações subsequentes, a largura dos *kernels* deve decrescer, e assim excluir os efeitos dos erros grosseiros nas iterações posteriores.

3 Inclusão de Informação de Estado *A Priori* no Estimador MCC

Informações de estado *a priori* (APSI) podem ser facilmente incorporadas à EESP (Do Coutto Filho and Stacchini de Souza, 2009; Simões Costa et al., 2005). Consistem em geral de informações previamente existentes sobre as variáveis de estado, usualmente denotadas por $\bar{\mathbf{x}}$, e podem contribuir para melhorar a observabilidade do sistema em estudo.

Esta seção estende o estimador de estados baseado no método MCC, para permitir o processamento de informações *a priori*. O estimador resultante, designado como estimador APSI, é o núcleo da arquitetura híbrida de estimação proposta.

Para levar em consideração o critério de máxima correntropia, a mesma abordagem aplicada ao conjunto de medidas pode ser estendida às informações de estado *a priori*. Portanto, para maximizar a semelhança entre $\hat{\mathbf{x}}$ e $\bar{\mathbf{x}}$, procura-se maximizar a correntropria entre estes vetores. Para traduzir o nível de confiança das informações em $\bar{\mathbf{x}}$ utilizam-se os elementos diagonais da matriz de covariância $\mathbf{\Sigma}_0$, computada de acordo com (5). A partir destas considerações, o estimador de máxima correntropia em (7) pode ser estendido para incluir informações *a priori* aumentando-se a função-objetivo da seguinte forma:

$$\max_{\hat{\mathbf{x}}} J_{MCC} = \sum_{i=1}^{m} R_{ii}^{-1} \exp[-(z_i - h_i(\hat{\mathbf{x}}))^2/2\sigma_i^2] + \sum_{j=1}^{n} \Sigma_{jj}^{-1} \exp[-(\bar{x}_j - \hat{x}_j)^2/2\sigma_{apsi,j}^2] \tag{8}$$

onde $\sigma_{apsi,j}$ é a largura da janela de Parzen relacionada com o estado *a priori* $\bar{x}_j$.

De acordo com os critérios de otimalidade, o Problema (8) é solucionado através da resolução da seguinte equação linear em cada iteração (Freitas et al., 2017):

$$\left[\mathbf{H}^T\mathbf{W}\mathbf{H} + \mathbf{V}\right] \cdot \mathbf{\Delta x} = \mathbf{H}^T\mathbf{W}\mathbf{\Delta\tilde{z}} + \mathbf{V}\mathbf{\Delta\tilde{\bar{x}}} \tag{9}$$

em que

$$\begin{aligned}
\mathbf{W} &= \mathbf{D}[\mathbf{I} - \mathbf{R_P}] \; ; \; \mathbf{\Delta\tilde{z}} = [\mathbf{I} - \mathbf{R_P}]^{-1}\mathbf{\Delta z}; \\
\mathbf{V} &= \mathbf{L}[\mathbf{I} - \mathbf{M_P}] \; ; \; \mathbf{\Delta\tilde{\bar{x}}} = [\mathbf{I} - \mathbf{M_P}]^{-1}\mathbf{\Delta\bar{x}}; \\
R_{P,ii} &= (z_i - h_i(\hat{\mathbf{x}}))^2/\sigma_i^2; \\
D_{ii} &= \tfrac{R_{ii}^{-1}}{\sigma_i^2} \exp[-(z_i - h_i(\hat{\mathbf{x}}))^2/2\sigma_i^2]; \\
M_{P,jj} &= (\bar{x}_j - \hat{x}_j)^2/\sigma_{apsi,j}^2; \\
L_{jj} &= \tfrac{\Sigma_{jj}^{-1}}{\sigma_{apsi,j}^2} \exp[-(\bar{x}_j - \hat{x}_j)^2/2\sigma_{apsi,j}^2].
\end{aligned} \tag{10}$$

Nas equações acima, $\mathbf{\Delta\bar{x}} = (\bar{\mathbf{x}} - \mathbf{x}^k)$ e $\mathbf{I}$ é a matriz identidade de dimensões apropriadas.

Denota-se o problema definido em (9) como estimador MCC com capacidade de processar informações *a priori*„ ou simplesmente Estimador de Estados MCC/APSI. Assume-se correlação nula entre os elementos de $\mathbf{\Delta\bar{x}}$, e portanto, $\mathbf{\Sigma}_0$ reduz-se a uma matriz diagonal (Zhou et al., 2006), em que o j-ésimo elemento $\bar{\sigma}_j$ é a variância da informação *a priori* $\bar{x}_j$.

A inclusão de APSI no modelo de estimação MCC permite que as mesmas propriedades de resiliência que se aplicam às medidas sejam impostas às informações *a priori*. Portanto, dados compatíveis com a operação atual são processadas de forma a melhorar a qualidade das estimativas, enquanto *outliers* são automaticamente rejeitados, não importando se são dados de medidas ou informações *a priori*.

Um aspecto peculiar de (9) é que os fatores de ponderação são atualizados de forma dinâmica durante o processo iterativo, o que pode potencialmente gerar problemas de mal-condicionamento numérico. Para preveni-los, e também para facilitar o processamento dos pesos dinâmicos, aplicam-se técnicas ortogonais de decomposição para resolver o problema de estimação MCC/APSI, como descrito na próxima seção.

4 Solução via Rotações Rápidas de Givens

A utilização da versão rápida das Rotações de Givens garante robustez numérica e efetividade de processamento para resolver o problema de EESP com base no método MQP (Simões Costa and Quintana, 1981; Vempati et al., 1991). Este artigo propõe a resolução do estimador MCC/APSI através do algoritmo das Rotações de Givens com três-multiplicadores (G3M) (Gentleman, 1973), com capacidade de processar informação de estado *a priori* , ao invés de resolver (9). A técnica de resolução é baseada em sucessivas transformações ortogonais aplicadas a matriz $\mathbf{H}$ (aumentada pelo vetor de incrementos $\mathbf{\Delta\tilde{z}}$), ponderada pelos pesos do método MCC os quais compõem a matriz diagonal $\mathbf{W}$ (equações em (10)), com a finalidade de se obter um sistema linear triangular superior de equações. Considerando a matriz ortogonal $\mathbf{Q}$ que armazena cumulativamente as rotações individuais, tem-se que:

$$\mathbf{Q}\left(\mathbf{W}^{\frac{1}{2}}\ [\mathbf{H} \mid \boldsymbol{\Delta}\tilde{\mathbf{z}}]\right) = \begin{bmatrix} \mathbf{U} & \mathbf{c} \\ \mathbf{0} & \tilde{e} \end{bmatrix} \tag{11}$$

onde $\mathbf{U}$ é uma matriz $n \times n$ triangular superior, $\mathbf{c}$ é um vetor $n \times 1$ e $\tilde{e}$ um escalar. A versão rápida G3M é baseada na fatoração da matriz $\mathbf{U}$, como (Gentleman, 1973):

$$\mathbf{U} = \mathbf{T}^{\frac{1}{2}}\bar{\mathbf{U}} \tag{12}$$

em que $\mathbf{T}$ é uma matriz diagonal e $\bar{\mathbf{U}}$ uma matriz triangular superior unitária. Considerando a equação (11), o vetor $\boldsymbol{\Delta}\tilde{\mathbf{z}}$ é uma coluna extra da matriz $\mathbf{H}$, e portanto o vetor $\mathbf{c}$ é também escalonado por $\mathbf{T}^{\frac{1}{2}}$, sendo então denotado por $\bar{\mathbf{c}}$. Este procedimento é atrativo pelo fato de eliminar o cálculo das raízes quadradas existentes em (11) (Simões Costa and Quintana, 1981; Gentleman, 1973).

Após o processamento de todas as medidas, o vetor de incrementos é obtido através da resolução da simples equação triangular superior:

$$\bar{\mathbf{U}}\boldsymbol{\Delta}\mathbf{x} = \bar{\mathbf{c}} \tag{13}$$

A técnica G3M, aplicada para a solução do método MCC facilita a inclusão dos fatores de escala para as variáveis de estado antes de qualquer medida seja processada. Isto é, as informações *a priori* de estado podem ser levadas em consideração da seguinte forma. Cada elemento t_{jj} da diagonal de $\mathbf{T}$ em (12) é um peso para j-ésima linha de $\bar{\mathbf{U}}$, a qual é inicializada como matriz identidade, e então, os elementos t_{jj} são pesos para os valores iniciais das variáveis de estado x_j, o que neste caso são as informações *a priori* de estado. Outros detalhes da inclusão de APSI através da técnica são abordadas em (Simões Costa and Albuquerque, 2011; Simões Costa et al., 2005).

Considerando o estimador MCC/APSI e as Rotações de Givens G3M, os elementos de $\mathbf{T}$ são inicializados de acordo com os valores da matriz $\mathbf{V}$ em (10), cujos elementos diagonais dependem da largura das janelas de Parzen, e assim fornecem os pesos para os valores dos estados *a priori*. Logo:

$$t_{jj}^{(0)} = V_{jj}. \tag{14}$$

Adicionalmente, os valores das informações *a priori* são inicializados em $\bar{\mathbf{c}}$, sob as propriedades do método MCC da forma:

$$\bar{\mathbf{c}} = \boldsymbol{\Delta}\bar{\tilde{\mathbf{x}}}. \tag{15}$$

O procedimento descrito acima permite incluir informações *a priori* sem qualquer custo computacional extra (Simões Costa et al., 2005).

5 Arquitetura Híbrida de Estimação MCC/APSI

5.1 Estratégia para Estimação MCC/ASPI

A estrutura do estimador de estados MCC/APSI é representado na Fig. 1. O primeiro módulo

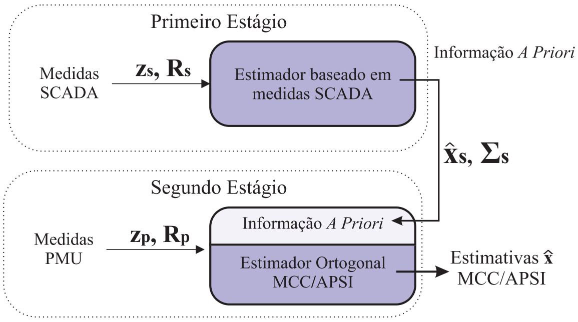

Figura 1: Arquitetura do estimador MCC/APSI

de estimação é composto pelo tradicional método MQP que processa somente medidas do sistema SCADA. A saída deste módulo consiste em um vetor de estados $\hat{\mathbf{x}}_S$ baseado nas medidas SCADA, e sua correspondente matriz de covariância dos erros de estimação $\boldsymbol{\Sigma}_S$, computada como em (5). O vetor $\hat{\mathbf{x}}_S$ e os elementos da diagonal de $\boldsymbol{\Sigma}_S$ são tratados como informação *a priori* e seus correspondentes pesos pelo segundo módulo de estimação, que processa somente medidas fasorais. A principal característica desta estratégia é que mantem o estimador de estados convencional baseado no método MQP que processa apenas medidas SCADA (Simões Costa and Albuquerque, 2011; Simões Costa et al., 2013).

O segundo estágio de estimação é composto pelo estimador ortogonal MCC/APSI, como retratado na Fig. 1 e descrito nas Seções 3 e 4. Neste segundo módulo somente medidas PMU são processadas, entretanto as estimativas do estimador SCADA são tratadas como informações *a priori* pelo estimador MCC/APSI. Para rejeitar possíveis *outliers*, os ajustes as janelas de Parzen seguem o procedimento a ser descrito na subseção a seguir.

5.2 Ajuste das Janelas de Parzen

A correntropia apresenta propriedades de rejeição de *outliers* resultantes do ajuste das janelas de Parzen, cuja largura é determinada iterativamente no método MCC/APSI. Portanto, a similaridade entre medidas/informações *a priori* e seus correspondentes valores estimados é avaliada dentro de uma "janela de observação". Erros situados fora das respectivas janelas são virtualmente excluídos do processo de estimação. No que diz respeito às medidas fasoriais, aplica-se neste trabalho um procedimento de ajuste para as janelas de Parzen baseado no máximo resíduo normalizado (Monticelli, 1999), ponderado pelo desvio-padrão do correspondente resíduo da medida (Freitas et al., 2017; Opara, 2014). Logo, para a i-ésima medida tem-se que a largura da janela de Parzen na iteração k é :

$$\sigma_i^k = \sqrt{\Omega_{ii}} \cdot \max_j \left(|r_j|/\sqrt{\Omega_{jj}}\right), \quad i,j \in \{1,\ldots,m\}\backslash\mathcal{S}^{k-1} \tag{16}$$

onde $\boldsymbol{\Omega}$ é a matriz de covariância dos resíduos e $\mathcal{S}^{k-1}$ é um conjunto de *outliers* determinado na iteração anterior. Este conjunto é inicializado como $\mathcal{S}^{(0)} = \phi$.

Por outro lado, a estratégia de ajuste dos *kernels* Gaussianos para as informações *a priori* é baseada no valor do máximo erro absoluto computado para cada classe de variável de estado. Isto faz com que distintas janelas de Parzen sejam aplicadas aos ângulos e magnitudes de tensão, da forma:

$$\begin{aligned} \sigma^k_{apsi,\theta} &= \max_i |\bar{\theta}_i - \hat{\theta}_i|, \ i \in \{1,\ldots,N\}\backslash\mathcal{S}^{k-1}_\theta \\ \sigma^k_{apsi,V} &= \max_i |\bar{V}_i - \hat{V}_i|, \ i \in \{1,\ldots,N\}\backslash\mathcal{S}^{k-1}_V \end{aligned} \quad (17)$$

onde $\mathcal{S}_\theta$ e $\mathcal{S}_V$ são subconjuntos de *outliers* para ângulos e magnitudes de tensão, respectivamente, determinados na iteração anterior. Ambos os conjuntos são inicializados como conjuntos vazios.

5.3 Observações Adicionais

As seguintes observações se aplicam à arquitetura de estimação em dois estágios:

- A hipótese de que as medidas SCADA garantem a observabilidade ao sistema elétrico permite relaxar os requisitos de observabilidade com respeito as medidas PMU, o que é realístico, já que o número de dispositivos de medição fasorial instalados ainda é limitado;
- A presença de medidas PMU em parte do sistema elétrico tende a melhorar a qualidade dos resultados locais da estimação de estados, devida à exatidão superior das medidas fasoriais com respeito às medidas SCADA;
- As regiões da rede elétrica nas quais estão disponíveis medidas fasoriais alcançam maior nível de redundância, o que facilita as propriedades de resiliência do estimador MCC;
- Como as medidas PMU possuem taxas de amostragem superiores ao sistema SCADA, considera-se que o alinhamento temporal entre as medidas é realizado por uma metodologia especializada (Glavic and Cutsem, 2013), possibilitando que a estimação ocorra com base em um conjunto de medidas que descrevam da melhor forma a operação corrente do sistema elétrico;
- Possíveis perdas de informação de dados de medidas PMU não afetam o desempenho do estimador no esquema multi-estágio proposto. O pior cenário garante que a solução seja o resultado da estimação de estados baseado nas medidas convencionais.

6 Resultados de Simulações

Para ilustrar a aplicação do estimador MCC/APSI, são realizadas simulações a partir dos sistemas-teste de 14 e 57 barras do IEEE (Washington University, 2007). Modelos não-lineares são utilizados para ambas as redes elétricas. O sistema SCADA monitora as magnitudes de tensão nas barras, injeções e fluxos de potência ativa e reativa, enquanto medidas fasoriais monitoram os fasores de tensão barras onde medidas PMU estão instaladas bem como a corrente nos ramos incidentes nestas barras. As variâncias das medidas dependem das exatidões atribuídas aos medidores, sendo $5 \cdot 10^{-3}$ *pu* e $3 \cdot 10^{-2}$ *pu* os valores utilizados para as magnitudes de tensão e medidas de potência do sistema SCADA, respectivamente. Para medidas PMU, considera-se $2 \cdot 10^{-3}$ *pu* tanto para fasores de tensão como de corrente.

A avaliação do desempenho do estimador é feita através da aplicação da métrica Euclidiana (KEMA, 2006) sobre os erros vetoriais entre as tensões nodais estimadas e reais (obtidas a partir de um estudo de fluxo de potência convergido da rede elétrica). Da mesma forma, o valor médio e desvios-padrão dos erros são utilizados para avaliação do desempenho do estimador MCC/APSI.

Em ambos os sistemas-teste, são realizados três estudos de caso: caso base (*CB*), em que ambos os sistemas de medição estão livres de erros grosseiros; *EG-SCADA*, onde medidas convencionais possuem erros grosseiros, e consequentemente as respectivas informações *a priori* repassadas ao estimador MCC/APSI são igualmente contaminadas; e *EG-SCADAePMU*, em que ambos os subconjuntos de medição estão contaminados com erros grosseiros.

6.1 Sistema-Teste IEEE 14 Barras

O sistema-teste de 14 barras do IEEE, bem como o plano de medição composto por medidas SCADA e PMU é mostrado na Fig. 2. O referido sistema não é totalmente observável com respeito às mexdidas fasoriais instaladas. Por outro lado, as medidas convencionais garantem a total observabilidade da rede elétrica.

Os resultados para o caso base são apresentados na Fig. 3, que mostra os desvios de estimação

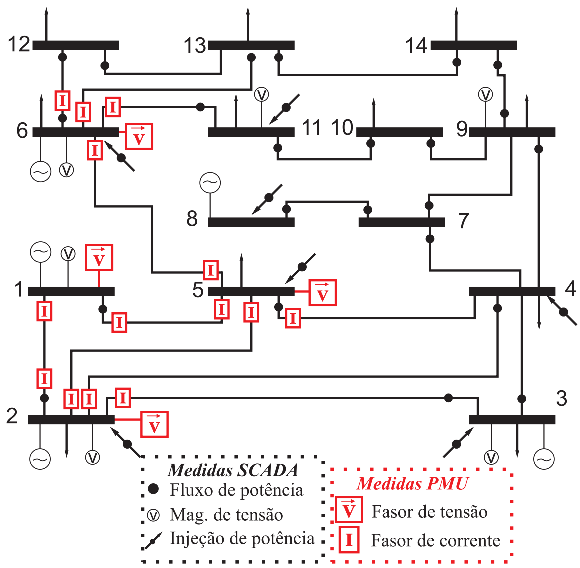

Figura 2: Sistema-teste de 14 barras do IEEE

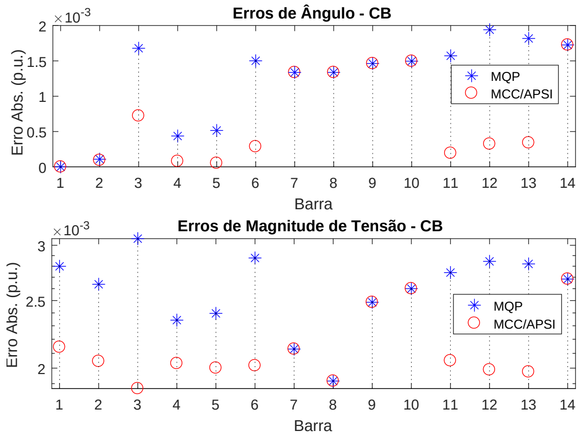

Figura 3: Erros das estimativas para os métodos MQP e MCC/APSI na ausência de erros grosseiros.

para ângulos e magnitudes de tensão com relação aos valores obtidos pelo fluxo de potência. Pode-se verificar que, na ausência de monitoração por medidas fasoriais locais, as estimativas dos estados fornecidas pela metodologia proposta coincidem com os valores obtidos pelo estimador SCADA. Tal fato ocorre nas barras 7 a 10 e na barra 14, as quais não são atingidas por nenhuma medida PMU, seja por seu monitoramento direto ou via ramos incidentes cujos fasores de corrente são monitorados por medidas PMU (*ver fig.* 2). A coincidência dos erros de estimativas para a barra 1 é justificada pelo fato de que esta barra é a referência angular para ambos os sistemas de medição. É possível também verificar na Fig. 3 que nas barras que possuem medição fasorial ou sejam adjacentes a uma medida PMU, os resultados de suas estimativas são melhorados, já que os erros são reduzidos quando comparados com aquelas produzidas pelo estimador SCADA. Estes resultados confirmam o fato esperado de que a adição de medidas fasoriais sincronizadas melhoram o desempenho da estimação de estados.

O caso *EG-SCADA* considera a situação em que uma medida com erro grosseiro é processada pelo estimador SCADA, entretanto não é detectada ao final do primeiro estágio (ver Fig. 1). A magnitude de tensão na barra 1 é escolhida como medida errônea, cuja magnitude do erro grosseiro é de 5 desvios-padrão. Como apresentado na Fig. 4, a presença do erro afeta o resultado do estimador MQP, já que principalmente a estimação de algumas magnitudes de tensão mas também de alguns ângulos, apresenta desempenho pior em comparação com o caso base, na Fig. 3. Quando as informações *a priori* são processadas pelo estimador MCC/APSI no segundo estágio, uma consequência direta é que estimativas resultantes do primeiro módulo e inconsistentes com as medidas PMU (estas isentas de erros grosseiros) são automaticamente rejeitadas. A Tabela 1 mostra os pesos para as medidas PMU e informações *a priori* relacionadas às larguras das janelas de Parzen, computados na convergência do estimador MCC/APSI, após duas iterações. Para uma melhor análise, todos os pesos da tabela são normalizados com respeito ao peso de $\tilde{\theta}_2$. Os pesos destacados em negrito estão associados às estimativas SCADA inconsistentes, sendo todos negativos pelo fato de que os correspondentes erros são maiores que suas próprias larguras das janelas de Parzen. Como resultado, as informações *a priori* errôneas são rejeitadas pelo estimador MCC. A tabela também mostra os pesos das medidas fasoriais de corrente, os quais possuem maior impacto no processo de estimação com relação às informações *a priori*. Observa-se também que, nas barras que não são observáveis por medidas fasoriais, as estimativas *a priori* não são filtradas, e consequentemente tais valores continuam contaminados pelos efeitos do erro grosseiro. Finalmente, as grandes diferenças entre os resultados dos dois módulos de estimação podem ser utilizadas como alerta de que o processo de estimação do primeiro estágio deve ser refeito (na pressuposição de que o estimador MCC depurou adequadamente o conjunto de medidas fasoriais).

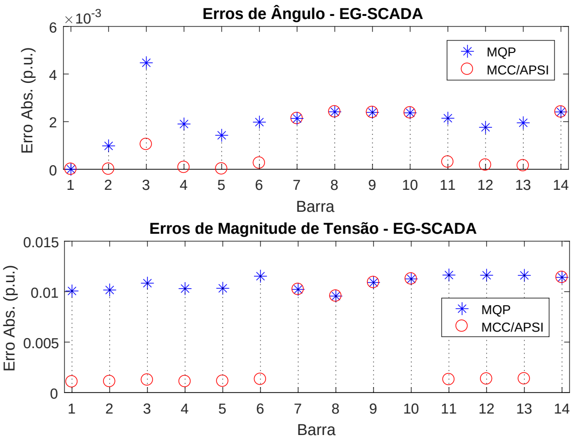

Figura 4: Erros das estimativas para o caso *EG-SCADA*- erro grosseiro somente no sistema SCADA

Tabela 1: Pesos normalizados para medidas e informações *a priori* - caso *EG-SCADA*

	Pesos de meds. PMU		Pesos de APSI		Pesos de meds. fasor de corrente		
Barra	Ângulo	Mag. de Tensão	Ângulo	Mag. de Tensão	De-Para	Real	Imag.
1	-	1,19e-3	-	**-2,60e-6**	$\dot{I}_{1-2}$	3,90e-4	1,54
2	33,797	1,26e-3	1,0*	**-1,82e-6**	$\dot{I}_{1-5}$	6,68e-3	72,25
3	-	-	**-0,041**	**-1,90e-7**	$\dot{I}_{2-3}$	0,97	3,74e3
4	-	-	0,041	**-1,19e-6**	$\dot{I}_{2-4}$	2,39e-2	57,26
5	3,325	1,42e-3	0,170	**-1,02e-6**	$\dot{I}_{2-5}$	9,62e-2	43,21
6	0,433	1,60e-3	0,120	**-8,70e-9**	$\dot{I}_{2-1}$	3,76e-4	9,58
7	-	-	0,129	0,107	$\dot{I}_{5-6}$	6,35e-2	1,68
8	-	-	0,117	0,109	$\dot{I}_{5-1}$	7,26e-3	9,26
9	-	-	0,119	0,102	$\dot{I}_{5-2}$	0,10	10,258
10	-	-	0,115	0,099	$\dot{I}_{5-4}$	0,13	1,19e4
11	-	-	0,105	**-6,34e-9**	$\dot{I}_{6-11}$	9,76e3	7,25e4
12	-	-	0,076	**-4,44e-9**	$\dot{I}_{6-12}$	1,21e4	3,77e4
13	-	-	0,086	**-4,90e-9**	$\dot{I}_{6-13}$	8,69e2	7,67e3
14	-	-	0,099	0,090	$\dot{I}_{6-5}$	0,11	1,66

*Peso tomado como base para normalização.

Os resultados para o caso *EG-SCADAePMU* são obtidos a partir do estimador MCC/APSI sob

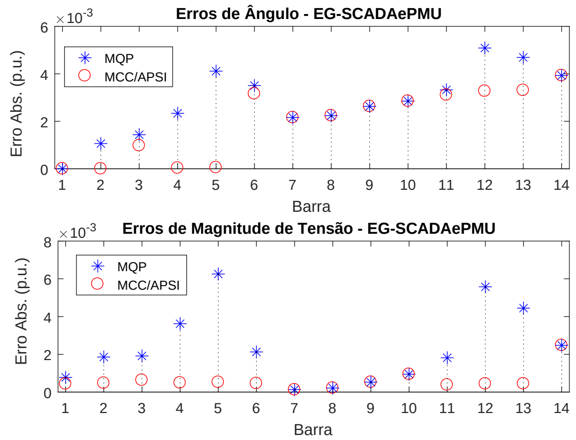

Figura 5: Erros das estimativas para o caso *EG-SCADAePMU*- erros grosseiros nos sistemas SCADA e PMU

a presença de erros grosseiros em ambos os subconjuntos de medidas SCADA e PMU (*ver fig.* 2). As medidas convencionais errôneas são as injeções de potência ativa e reativa na barra 5, a qual é também monitorada por uma medida PMU. As magnitudes dos erros grosseiros são iguais a 15 desvios-padrão. Adicionalmente, supõe-se que houve falha na transmissão da medida PMU de magnitude de tensão na barra 1 de modo que seu valor que chega para processamento é zero. A Fig. 5 apresenta os erros de estimação do primeiro e segundo estágio do estimador de estados híbrido. Verifica-se que a arquitetura de dois estágios (MCC/APSI) produz estimativas com menores erros absolutos com relação aquelas obtidas pelo estimador SCADA, além de que a medida PMU de tensão errônea e as informações *a priori* inconsistentes não afetam o resultado do estimador híbrido. Desta forma, o método MCC/APSI é capaz de fornecer estimativas confiáveis e precisas, mesmo sob condições severas onde erros grosseiros ocorrem em ambos sistemas de medição.

A análise de desempenho do estimador MCC/APSI é sumarizada na Tabela 2, onde são apresentados os valores das métricas dos erros de tensão nodal, média e desvios-padrão dos erros de estimação. Nota-se que a performance baseada na estimação em dois estágios é consistentemente melhor da que a apresentada pelo estimador convencional MPQ, para os três estudos de caso relatados, ou seja, ocorre a diminuição dos valores de métricas, o que inclui as métricas de tensão, em que no pior caso obtém-se uma redução de 57% com relação ao resultado do estimador MQP.

6.2 Sistema-Teste IEEE 57 Barras

Nesta subseção, são apresentados resultados obtidos através da aplicação do estimador MCC/APSI a estudos de caso utilizando o sistema-teste de 57 barras do IEEE. O plano de medição empregado é apresentado na Tabela 3. O número de medidas PMU disponíveis é insuficiente para garantir a total observabilidade da rede elétrica por este tipo de sensor. São aplicados os mesmos estudos de caso abordados na subseção 6.1: *CB*, onde todas as medidas estão isentas de erros grosseiros; *EG-SCADA*, onde uma medida de injeção de potência ativa é assumida errônea, cuja magnitude do erro é de 10 desvios-padrão; e *EG-SCADAePMU*, que envolve múltiplos erros grosseiros. Tais erros são: medidas SCADA de fluxos ativo e reativo em um ramo, e uma medida PMU de tensão nodal (ambos magnitude de tensão e ângulo).

Tabela 2: Índices de desempenho para o Sistema IEEE 14-barras

Estudo de caso	Métrica de tensão M_{MQP}	Métrica de tensão M_{MCC}	Valor de erro médio/(Desv. Padrão do erro) MQP $\|V\|$	MQP θ	MCC $\|V\|$	MCC θ
CB	0,0077	0,0061	-2,85e-3 (9,58e-4)	-1,10e-3 (3,02e-4)	-7,37e-4 (6,35e-4)	-8,51e-4 (2,48e-4)
EG-SCADA	0,0292	0,0125	-1,09e-2 (7,86e-4)	-4,09e-3 (5,61e-4)	-4,10e-3 (7,38e-4)	-1,41e-3 (4,26e-3)
EG-SCADA ePMU	0,0101	0,0058	1,09e-3 (2,72e-3)	-6,41e-5 (2,99e-3)	9,48e-4 (1,41e-3)	4,75e-5 (5,47e-4)

Tabela 3: Número de medidas SCADA e PMU para a rede de 57 barras do IEEE.

Medida	P	Q	$\|V\|$	p_{ij}	q_{ij}	$\dot{V}$	$\dot{I}$
SCADA	34	34	29	83	83	-	-
PMU	-	-	-	-	-	18	65

Os resultados de desempenho são sumarizados na Tabela 4. Como indicado pela métrica de tensão para caso *CB*, a alta penetração de medidas PMU melhora o desempenho de estimador, reduzindo em cerca de 40% o valor da métrica quando tais medidas são incluídas. Por outro lado, mesmo quando *outliers* estão presentes em um ou ambos os subconjuntos de medidas, os índices obtidos pelo estimador MCC/APSI comprovam o bom desempenho da metodologia híbrida.

Tabela 4: Índices de desempenho para o Sistema IEEE 57-barras

Estudo de caso	Métrica de tensão M_{MQP}	Métrica de tensão M_{MCC}	Valor de erro médio/(Desv. Padrão do erro) MQP $\|V\|$	MQP θ	MCC $\|V\|$	MCC θ
CB	0,0097	0,0059	-4,63e-4 (1,36e-3)	-1,23e-3 (4,69e-4)	3,71e-4 (1,10e-3)	-6,36e-4 (5,33e-4)
EG-SCADA	0,0136	0,0062	-7,21e-4 (1,45e-3)	2,03e-3 (8,44e-4)	1,03e-4 (1,21e-3)	9,25e-4 (1,19e-3)
EG-SCADA ePMU	0,0397	0,0151	2,12e-3 (9,60e-3)	-3,40e-3 (8,08e-3)	5,46e-4 (3,15e-3)	-1,52e-3 (6,39e-3)

7 Conclusões

Este trabalho faz uso de um estimador de estados híbrido, com arquitetura de dois estágios, capaz de processar medidas convencionais e fasorais sincronizadas. A arquitetura mantém o estimador clássico MQP no primeiro estágio, enquanto possibilita processar medidas PMU no segundo módulo, que trata como informações de estado *a pri-*

ori os resultados provenientes do primeiro estágio. A principal contribuição do artigo é a utilização do método MCC no segundo estágio, o que permite explorar as propriedades superiores de rejeição de informações espúrias deste algoritmo de estimação e assim obter estimativas confiáveis mesmo se erros grosseiros estiverem presentes em medidas SCADA, em medidas PMU ou em ambas. Estudos de caso utilizando os sistemas-teste de 14 e 57 barras do IEEE confirmam as propriedades de resiliência do estimador MCC/APSI.

Agradecimentos

Os autores agradecem o suporte financeiro do CNPq, mediante os projetos 312037/2013-9 (A. Simões Costa) e 400799/2014-6. Os autores V. Freitas e V. Miranda reconhecem igualmente o apoio do FEDER - Fundo Europeu de Desenvolvimento Regional, através do seu Programa Operacional para a Competitividade e Internacionalização COMPETE 2020, bem como da FCT - Fundação para a Ciência e Tecnologia (refª POCI-01-0145-FEDER-016731-INFUSE).

Referências

Do Coutto Filho, M. B. and Stacchini de Souza, J. C. (2009). Forecasting-aided state estimation -part i: Panorama, *Power Systems, IEEE Trans. on* **24**(4): 1667–1677.

Do Coutto Filho, M. B., Stacchini de Souza, J. C. and Guimarãens, M. A. R. (2014). Enhanced bad data processing by phasor-aided state estimation, *IEEE Trans. on Power Systems* **29**(5): 2200–2209.

Freitas, V., Simões Costa, A. and Miranda, V. (2017). Robust state estimation based on orthogonal methods and maximum correntropy criterion, *2017 IEEE Manchester PowerTech*, pp. 1–6.

Gentleman, W. M. (1973). Least squares computations by Givens transformations without square roots, *J. of the Inst. of Math. Applications* **12**: 329–336.

Glavic, M. and Cutsem, T. V. (2013). Reconstructing and tracking network state from a limited number of synchrophasor measurements, *IEEE Trans. on Power Systems* **28**(2): 1921–1929.

KEMA (2006). *Metrics for Determining the Impact of Phasor Measurements on Power System State Estimation*, DRAFT. Eastern Interconnection Phasor Project.

Liu, W., Pokharel, P. P. and Principe, J. C. (2006). Correntropy: A localized similarity measure, *in* IEEE (ed.), *Inter. Joint Conf. on Neural Networks*, IEEE, Vancouver, BC, Canada, pp. 4919–4924.

Miranda, V., Santos, A. and Pereira, J. (2009). State estimation based on correntropy: a proof of concept, *Power Systems, IEEE Trans. on* **24**(4): 1888 – 1889.

Monticelli, A. (1999). *State Estimation in Electric Power Systems: A Generalized Approach*, Kluwer's Power Eletrocnics and Power Systems Series, New York.

Opara, J. K. (2014). *Information Theoretic State Estimation in Power Systems*, PhD thesis, Faculty of Engineering, University of Porto.

Simões Costa, A. and Albuquerque, A. (2011). A two-stage orthogonal estimator to incorporate phasor measurements into power system real-time modeling, *17th PSCC*, Stockholm, Sweden, pp. 1–7.

Simões Costa, A., Albuquerque, A. and Bez, D. (2013). An estimation fusion method for including phasor measurements into power system real-time modeling, *IEEE Trans. on Power Systems* **28**(2): 1910–1920.

Simões Costa, A., Lourenço, M. E. and Vieira, F. (2005). Topology error identification for orthogonal estimators considering *a priori* state information, *15th PSCC*, Liège, pp. 1–7.

Simões Costa, A. and Quintana, V. H. (1981). An orthogonal row processing algorithm for power system sequential state estimation, *IEEE Trans. on Power Apparatus and Systems* **PAS-100**(8): 3791–3800.

Swerling, P. (1971). Modern state estimation methods from the viewpoint of the method of least squares, *IEEE Trans. on Aut. Control* **16**(6): 707–719.

Vempati, N., Slutsker, I. W. and Tinney, W. F. (1991). Enhancements to Givens rotations for power system state estimation, *IEEE Trans. on Power Systems* **6**(2): 842–849.

Washington University (2007). Power Systems Test Case Archive, University of Washington, Electrical Engineering, [Online]. Available: `http://www.ee.washington.edu/research/pstca/`.

Wu, W., Guo, Y., Zhang, B., Bose, A. and Hongbin, S. (2011). Robust state estimation method based on maximum exponential square, *IET Generation, Transmission and Distribution* **5**(11): 1165–1172.

Zhou, M., Centeno, V. A., Thorp, J. S. and Phadke, A. G. (2006). An alternative for including phasor measurements in state estimators, *IEEE Trans. on Power Systems* **21**(4): 1930–1937.