

FUSÃO DE ESTIMATIVAS OBTIDAS A PARTIR DE MEDIDAS CONVENCIONAIS E FASORIAIS MEDIANTE CRITÉRIO DE MÁXIMA CORRENTROPIA

NASTASHA SALAME DA SILVA*, ANTONIO JOSÉ ALVES SIMÕES COSTA†, VLADIMIRO MIRANDA‡

**Universidade Tecnológica Federal do Paraná
Curitiba, Paraná, Brasil*

†*Universidade Federal de Santa Catarina
Florianópolis, Santa Catarina, Brasil*

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

Emails: nssilva@utfpr.edu.br, simoes.costa@ufsc.br,
vladimiro.miranda@inescbrasil.org.br

Abstract— This paper presents an extension to fusion methods applied to state estimation considering that the incoming measurements are obtained from SCADA and PMU measurements, whose sampling rates are significantly different. To combine the estimates individually produced by the two classes of measurements, fusion methods are applied, but in this paper the traditional WLS estimation paradigm is replaced by a Maximum Correntropy Criterion. The objective is to attain a more efficient power system state estimation process, based on both conventional and phasor measurements, whose main advantage is the resiliency with respect to the occurrence of single and multiple bad data.

Keywords— Power system state estimation, fusion methods, maximum correntropy criterion.

Resumo— Este artigo apresenta um aprofundamento e extensão de métodos de fusão à estimação de estados envolvendo medidas oriundas de equipamentos com diferentes taxas de amostragem e qualidade de medição. Adicionalmente, aplicam-se os métodos de fusão em um contexto diferente da formulação clássica dos mínimos quadrados, ou seja, utilizando o Critério da Máxima Correntropia (MCC). Como resultado, obtém-se um algoritmo robusto e eficaz para a estimação de estados para sistemas de potência, com plano de medição composto por medidas convencionais e fasoriais, cuja principal vantagem é a resiliência face à ocorrência de erros grosseiros.

Palavras-chave— Estimação de estados em sistemas de potência, métodos de fusão, critério da máxima correntropia.

1 Introdução

A Estimação de Estados em Sistemas de Potência (EESP) é a ferramenta fundamental utilizada nos Centros de Operação do Sistema (COS) para informações confiáveis em tempo real sobre a condição operativa corrente da rede elétrica. A EESP convencional constrói um modelo em tempo real para a rede a partir do processamento de informações analógicas coletadas por sistemas de aquisição de dados e controle supervisão (sistemas SCADA, da sigla em Inglês). Mais recentemente, medidas fasoriais sincronizadas de tensões nodais e correntes em ramos da rede, resultantes da instalação de unidades de medição fasorial (PMUs, da sigla em Inglês) em sistemas elétricos de potência (Phadke e Thorp, 2008) também tornaram-se disponíveis para processamento por parte de Estimadores de Estados (Zhou et al., 2006; Simões Costa et al., 2013).

Medidas analógicas coletadas pelo sistema SCADA e fornecidas ao estimador estão sujeitas a erros grosseiros, isto é, erros de medição cujo grau de inexatidão é muito maior do que o admitido pelo modelo de medição. O desempenho dos estimadores de estados baseados nos modelos tradicionais é severamente afetado por estas medidas

espúrias. Erros de topologia, resultantes de informações digitais incorretas sobre os *status* de chaves e disjuntores, constituem-se em outro tipo de anomalia cujo impacto sobre os resultados da estimação tendem a ser ainda mais graves (Clements e Simões Costa, 1998). Como os algoritmos de estimação convencionais não apresentam o nível de resiliência desejável para expurgar automaticamente os efeitos de anomalias, torna-se necessário dotar os estimadores de procedimentos adicionais, sob a forma de pós-processamento, para detectá-las, identificá-las e eliminá-las (Monticelli e Garcia, 1983; Monticelli et al., 1986; Wu, 1990). Uma desvantagem desta arquitetura convencional é que, na hipótese de ocorrência de anomalias, os resultados da estimação recém concluída estão comprometidos e todo o processo deve ser refeito após os erros terem sido expurgados. O fato de que tudo se passa em ambiente de tempo real, com limites estritos de tempo de execução para o cálculo de estimativas confiáveis, constitui-se em um fator agravante e que motiva a busca de soluções menos susceptíveis às anomalias descritas.

O propósito deste artigo é o desenvolvimento de uma nova classe de algoritmos de estimação de estados dotados de propriedades de resiliência superiores aos dos estimadores existentes. No

contexto deste artigo, o termo *resiliência* como propriedade de um algoritmo refere-se à capacidade de *rejeição automática de dados espúrios*. Um algoritmo de estimação de estados resiliente é portanto capaz de fornecer estimativas confiáveis mesmo na presença de medidas portadoras de erros grosseiros. Desta forma, não necessita obrigatoriamente ser secundado por um aparato de processamento de erros grosseiros, pois a eliminação das medidas espúrias passa a ocorrer como parte do próprio processo de estimação.

Para sintetizar esta nova classe de estimadores, torna-se necessário rever o paradigma tradicional da EESP, calcado no método dos mínimos quadrados ponderados (Monticelli, 1999; Abur e Exposito, 2004). Os estimadores resilientes baseiam-se em critérios de otimização não-quadráticos, tendo por base sólidos princípios da Teoria da Informação e de Processamento de Sinais (Principe e Xu, 1999; Liu et al., 2006).

A utilização, por si só, de critérios não-quadráticos na EESP não é uma novidade. Já na década de 70, Merrill e Schweppe (1971) e Handshin et al. (1975) buscavam contornar a necessidade de pós-processamento mediante métodos heurísticos de análise de resíduos a cada iteração. A ausência de uma base teórica sólida prejudicou a aceitação ampla desta metodologia.

A abordagem proposta em (Mili et al., 1996; Pires et al., 1999) utiliza fundamentos de robustez estatística para a detecção e identificação de erros grosseiros, os quais implicam na adoção de critérios não-quadráticos. Os estimadores resultantes apresentam baixo custo computacional relativo (Pires et al., 1999; Zhuang e Balasubramanian, 1985; Simões Costa et al., 1991), mas podem convergir para mínimos locais, dependendo da distância das condições iniciais com respeito à solução.

Mais recentemente, surgiram outras formulações embasadas em princípios da Teoria da Informação cuja solução leva igualmente ao emprego de critérios não-quadráticos, porém são dotadas de mecanismos para contornar o problema de extremos locais. Tais métodos empregam os conceitos da *Correntropia* (Liu et al., 2006; Miranda et al., 2009) e de *janelas de Parzen* (Parzen, 1962). O conceito de Correntropia está diretamente relacionado à similaridade entre variáveis aleatórias em uma vizinhança do espaço conjunto, definida por uma função Gaussiana cuja variância estabelece uma “janela de observação” dentro da qual a similaridade é avaliada (Miranda et al., 2009; Wu et al., 2011). Sendo ajustável, esta janela fornece um instrumento para atenuação ou eliminação dos efeitos de dados discrepantes (ou *outliers*). A principal vantagem de estimadores centrados no chamado *Critério de Máxima Correntropia* (MCC, da sigla em Inglês) é a sua resiliência, traduzida pela rejeição automática dos efeitos

das medidas espúrias. A possível ocorrência de extremos locais é também mitigada mediante a aplicação das janelas de Parzen (Principe e Xu, 1999; Wu et al., 2011).

A aplicação do conceito de máxima correntropia à EESP é recente (Krstulovic et al., 2013; Miranda et al., 2009; Wu et al., 2011). Até o momento, o interesse tem se concentrado no desenvolvimento de algoritmos de estimação e à rejeição de erros grosseiros em medidas analógicas.

O objetivo deste artigo é explorar a resiliência dos estimadores MCC, buscando sua inserção em arquiteturas de estimação que contemplam tanto o processamento de medidas SCADA quando de medidas fasoriais sincronizadas. Em particular, explora-se a arquitetura de *fusão de estimativas* (Simões Costa et al., 2013), porém aplicada em um contexto distinto do originalmente utilizado: os estimadores individuais que processam cada uma das duas classes de medida, passam a ser ambos baseados no princípio do MCC, ao invés da clássica estratégia dos Mínimos Quadrados Ponderados (Monticelli, 1999; Abur e Exposito, 2004). A vantagem almejada é a depuração automática de erros grosseiros eventualmente presentes entre as medidas SCADA e fasoriais, sem a necessidade de pós-processamento para sua eliminação.

Na Seção 2 são apresentados os princípios básicos do MCC. Alguns conceitos de fusão de estimativas e a solução proposta neste artigo são descritos na Seção 3. A Seção 4 apresenta a arquitetura de estimação proposta, cujos resultados para o sistema IEEE 14 barras são relatados e discutidos na Seção 5. As conclusões e considerações finais são apresentadas na Seção 6.

2 Critério da Máxima Correntropia

O MCC tem por finalidade extrair o máximo de informação sobre os estados contida nas medidas disponíveis. Para tal, o MCC maximiza a similaridade entre o vetor de medidas disponíveis e o vetor de medidas estimadas. Para tal, a seguinte função objetivo deve ser maximizada (Principe, 2010; Opara, 2013):

$$J_{MCC}(\mathbf{x}) = \sum_{i=1}^m \exp^{-\frac{(z_i - h_i(\mathbf{x}))^2}{2\sigma^2}} \quad (1)$$

onde z_i representa a medida i do vetor $\mathbf{z}$ de dimensão $m \times 1$, $h_i(\mathbf{x})$ representa a equação que relaciona a medida i às variáveis de estado e $\mathbf{x}$ é o vetor de estados a ser estimado, de dimensão $n \times 1$.

A solução do problema MCC baseia-se no método de Newton, por apresentar qualidades que aproveitam ao máximo as propriedades da função de MCC (sempre diferenciável para qualquer ordem), sendo esse método rápido, eficiente e de implementação relativamente simples (Opara, 2013). De forma a maximizar o critério de correntropia

Eq. (1), deve-se satisfazer as condições de otimalidade de primeira ordem, ou seja:

$$\nabla J_{MCC}(\mathbf{x}) = \mathbf{g}_{MCC}(\mathbf{x}) = 0$$

$$\frac{1}{\sigma^2} \sum_{i=1}^m \exp^{-\frac{(z_i - h_i(\mathbf{x}))^2}{2\sigma^2}} (z_i - h_i(\mathbf{x})) \underbrace{\frac{\partial h_i(\mathbf{x})}{\partial \mathbf{x}}}_{\mathbf{H}(\mathbf{x})} = 0 \quad (2)$$

onde $\mathbf{D}_{ii}^{MCC}(\mathbf{x}) = \frac{1}{\sigma^2} \exp^{-\frac{(z_i - h_i(\mathbf{x}))^2}{2\sigma^2}}$ é definido como o elemento (i, i) da matriz diagonal $m \times m$ $\mathbf{D}^{MCC}(\mathbf{x})$ e $\mathbf{H}(\mathbf{x})$ é a matriz Jacobiana. Ponderando-se a matriz $\mathbf{D}^{MCC}$ pela matriz de covariância dos erros de medição $\mathbf{R}$, obtêm-se uma nova matriz de ponderação diagonal $\mathbf{D} = \mathbf{R}^{-1} \mathbf{D}^{MCC}$.

Expandindo-se o termo do lado esquerdo da Eq. (2) em série de Taylor em torno de um dado vetor de estados $\mathbf{x}^k$ e negligenciando-se as derivadas de ordem superior, resulta o esquema iterativo do método de Newton que fornece uma correção do vetor de estados a cada iteração k , conforme segue:

$$\nabla \mathbf{g}_{MCC}(\mathbf{x}^k) \Delta \mathbf{x}^k = -\mathbf{g}_{MCC}(\mathbf{x}^k) \quad (3)$$

$$\mathbf{x}^{k+1} = \mathbf{x}^k + \Delta \mathbf{x}^k \quad (4)$$

Calculando-se a matriz $\mathbf{G}_W(\mathbf{x}) = \nabla \mathbf{g}_{MCC}(\mathbf{x}) = \nabla^2 J_{MCC}(\mathbf{x})$, após terem sido desprezadas as derivadas de segunda ordem cujos efeitos locais não são significativos, obtêm-se:

$$\mathbf{G}_W(\mathbf{x}) = \mathbf{H}^T \mathbf{W}(\mathbf{x}) \mathbf{H}(\mathbf{x}) \quad (5)$$

onde $\mathbf{W}(\mathbf{x}) \triangleq \mathbf{D}(\mathbf{x}) (\mathbf{I} - \mathbf{R}_P)$ e $\mathbf{R}_P$ é uma matriz diagonal, cujos elementos são calculados como $\mathbf{R}_{P,ii} = \left(\frac{(z_i - h_i(\mathbf{x}))^2}{\sigma^2} \right)$.

Por fim, a magnitude do passo a ser dado, $\Delta \mathbf{x}^{k+1}$, no processo iterativo para obtenção das estimativas, $\mathbf{x}^{k+1} = \mathbf{x}^k + \Delta \mathbf{x}^{k+1}$, é calculado conforme abaixo:

$$\Delta \mathbf{x}^{k+1} = -[\mathbf{G}_W(\mathbf{x})^k]^{-1} \mathbf{g}_{MCC} \quad (6)$$

Logo, o vetor de estados estimados pelo Método da Máxima Correntropia é dado por:

$$\hat{\mathbf{x}} = (\mathbf{H}^T \mathbf{W} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{D} \mathbf{z} \quad (7)$$

Nota-se que a equação (7) não está exatamente na forma da Equação Normal convencional, o que seria desejável. Para contornar esta dificuldade, definimos:

$$\bar{\mathbf{z}} \triangleq (\mathbf{I} - \mathbf{R}_p)^{-1} \mathbf{z} \quad (8)$$

e portanto, utilizando a definição de $\mathbf{W}$ podemos re-escrever (7) como:

$$\hat{\mathbf{x}} = (\mathbf{H}^T \mathbf{W} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{W} \bar{\mathbf{z}} \quad (9)$$

ou equivalentemente:

$$\mathbf{G}_W \hat{\mathbf{x}} = \mathbf{H}^T \mathbf{W} \bar{\mathbf{z}} \quad (10)$$

3 Fusão de estimativas considerando estimadores baseados no critério da máxima correntropia

Para realizar a fusão de estimativas obtidas a partir de dados gerados por N classes distintas de sensores, primeiramente deve-se considerar a matriz de covariância dos erros de estimação $\mathbf{P}$, que pode ser escrita como (Mitchell, 2007):

$$\mathbf{P} = \begin{bmatrix} \mathbf{P}_{11} & \dots & \mathbf{P}_{1N_S} \\ \vdots & \ddots & \vdots \\ \mathbf{P}_{N_S 1} & \dots & \mathbf{P}_{N_S N_S} \end{bmatrix} \quad (11)$$

onde N_S representa o número de sensores. No caso particular da fusão de estimativas oriundas de sistemas não correlacionados, como é o caso abordado neste artigo, a matriz $\mathbf{P}$ é bloco diagonal, ou seja, apenas as submatrizes $\mathbf{P}_{ii}$, onde i representa o tipo de sensor, são não nulas. Neste trabalho há apenas duas classes de sensores: SCADA e PMU, ou seja, $N_S = 2$. Desta forma, temos que:

$$\mathbf{P}_{ii} = \text{cov}\{\tilde{\mathbf{x}}_i, \tilde{\mathbf{x}}_i\}$$

$$= E[(\tilde{\mathbf{x}}_i - \mathbf{x})(\tilde{\mathbf{x}}_i - \mathbf{x})^T], i = 1, 2 \quad (12)$$

A fusão das estimativas $\hat{\mathbf{x}}_1$ e $\hat{\mathbf{x}}_2$ pode ser formulada como uma combinação linear cujos coeficientes são matrizes de ponderação a serem determinadas (Zhu, 2003). Se $\hat{\mathbf{x}}^*$ é o vetor ótimo de estados estimados resultante desta combinação, tem-se (Zhu, 2003; Albuquerque, 2012):

$$\hat{\mathbf{x}}^* = \Psi^T \hat{\mathbf{x}} \quad (13)$$

onde $\hat{\mathbf{x}} = [\hat{\mathbf{x}}_1^T, \hat{\mathbf{x}}_2^T]^T$ e $\Psi^T = [\Psi_1^T, \Psi_2^T]$. As matrizes de ponderação Ψ_i , de dimensão $n \times n$, são obtidas como solução do seguinte problema de otimização com restrição matricial de igualdade (Zhu, 2003; Albuquerque, 2012):

$$\min_{\Psi} E[(\Psi^T \hat{\mathbf{x}} - \mathbf{x})(\Psi^T \hat{\mathbf{x}} - \mathbf{x})^T]$$

$$s.a \quad \Gamma^T \Psi = \mathbf{I} \quad (14)$$

onde $\Gamma = [\mathbf{I} \quad \mathbf{I}]^T$ tem dimensão $2n \times n$ e $\mathbf{I}$ é a matriz identidade $n \times n$. O critério utilizado no problema de otimização acima busca minimizar a covariância do erro $(\hat{\mathbf{x}}^* - \mathbf{x})$. Pode ser mostrado que o problema (14) possui uma única solução em Ψ , sendo que as submatrizes Ψ_i são obtidas da equação (Zhu, 2003; Albuquerque, 2012):

$$\Psi_i = \left(\sum_{k=1}^2 \mathbf{P}_{ik}^{-1} \right) \left(\sum_{j,k=1}^2 \mathbf{P}_{jk}^{-1} \right)^{-1} \quad (15)$$

Para o caso de apenas duas classes de sensores a Equação (13) torna-se:

$$\hat{\mathbf{x}}^* = \Psi_1^T \hat{\mathbf{x}}_1 + \Psi_2^T \hat{\mathbf{x}}_2 \quad (16)$$

sendo que as matrizes Ψ_1 e Ψ_2 são obtidas a partir de (15), resultando na seguinte equação:

$$\hat{\mathbf{x}}^* = (\mathbf{P}_{22} - \mathbf{P}_{21})(\mathbf{P}_{11} + \mathbf{P}_{22} - \mathbf{P}_{12} - \mathbf{P}_{21})^{-1}\hat{\mathbf{x}}_1 + (\mathbf{P}_{11} - \mathbf{P}_{12})(\mathbf{P}_{11} + \mathbf{P}_{22} - \mathbf{P}_{12} - \mathbf{P}_{21})^{-1}\hat{\mathbf{x}}_2 \quad (17)$$

A Eq. (17) é conhecida como fórmula de fusão de Bar-Shalom-Campo para a fusão de dados no caso particular de dois sensores (Zhu, 2003; Albuquerque, 2012). No caso de interesse, em que as estimativas $\hat{\mathbf{x}}_1$ e $\hat{\mathbf{x}}_2$ são não correlacionadas, ou seja, $\mathbf{P}_{ij} = \mathbf{P}_{ji} = \mathbf{0}$, e realizando algumas manipulações matemáticas, a fórmula de fusão (17) torna-se:

$$\hat{\mathbf{x}}^* = (\mathbf{P}_{11}^{-1} + \mathbf{P}_{22}^{-1})^{-1}(\mathbf{P}_{11}^{-1}\hat{\mathbf{x}}_1 + \mathbf{P}_{22}^{-1}\hat{\mathbf{x}}_2) \quad (18)$$

onde, considerando-se que as estimativas individuais são obtidas pelo Critério da Máxima Correntropia, tem-se $\hat{\mathbf{x}}$ dado pela equação (10).

Conforme preconizado pela Eq. (18), o método de fusão de estimativas faz uso das matrizes de covariância dos erros de estimação correspondentes a cada classe de sensores envolvida no processo de estimação. Portanto, para se estender a aplicação do método de fusão descrito em (Simões Costa et al., 2013) a estimadores de máxima correntropia, torna-se necessário determinar as matrizes de covariância dos erros de estimação produzidos por estes estimadores. O vetor dos erros de estimação $\hat{\mathbf{x}} - \mathbf{x}$ quando $\hat{\mathbf{x}}$ é obtido mediante um estimador de máxima correntropia é dado por:

$$\begin{aligned} \hat{\mathbf{x}} - \mathbf{x} &= \mathbf{G}_w^{-1} \mathbf{H}^T \mathbf{W} \bar{\mathbf{z}} - \mathbf{x} \\ &= \mathbf{G}_W^{-1} (\mathbf{H}^T \mathbf{W} \bar{\mathbf{z}} - \mathbf{G}_W \mathbf{x}) \\ &= \mathbf{G}_W^{-1} \mathbf{H}^T \mathbf{W} (\bar{\mathbf{z}} - \mathbf{H} \mathbf{x}) \end{aligned} \quad (19)$$

A partir de (19), é possível mostrar que a matriz de covariância dos erros de estimação para a classe de sensores i é dada simplesmente por:

$$\begin{aligned} \mathbf{P}_{ii} &= cov\{\tilde{\mathbf{x}}_i, \tilde{\mathbf{x}}_i\} = E[(\tilde{\mathbf{x}}_i - \mathbf{x}_i)(\tilde{\mathbf{x}}_i - \mathbf{x}_i)^T] \\ &= \mathbf{G}_{W,i}^{-1} \end{aligned} \quad (20)$$

Finalmente, este resultado permite reescrever (18) como:

$$(\mathbf{G}_{W,1} + \mathbf{G}_{W,2})\hat{\mathbf{x}}_{MCC}^* = \mathbf{G}_{W,1}\hat{\mathbf{x}}_1 + \mathbf{G}_{W,2}\hat{\mathbf{x}}_2 \quad (21)$$

onde os índices 1 e 2 em (21) representam os sensores SCADA e PMU, respectivamente.

4 Arquitetura de Estimação Proposta

Tendo em vista o que foi apresentado nas seções anteriores, pode-se propor a arquitetura de estimação descrita abaixo, tendo como fundamento estimadores de estados baseados no critério da máxima correntropia. Em um primeiro estágio, dois estimadores MCC são implementados. O estimador que processa medidas provenientes do sistema SCADA é não linear e utiliza medidas de

tensão, injeção e fluxo de potência ativa e reativa de forma convencional. Já o estimador MCC para medidas oriundas de PMUs faz uso de medidas do fasor tensão e corrente, representadas em coordenadas retangulares para permitir o uso de um modelo de medição linear (Zhou et al., 2006). Quando a estimação de estados é finalizada nos dois estimadores, os elementos necessários para fusão são enviadas para o segundo estágio, de onde obtêm-se as estimativas finais dos estados. Tal procedimento é sumarizado na Figura 1.




Figura 1: Algoritmo proposto.

5 Resultados

O algoritmo proposto foi aplicado a diferentes sistemas-teste, porém, por limitações de espaço, apenas os resultados obtidos para o sistema-teste IEEE 14 barras (fig. 2) serão aqui apresentados. O plano de medição apresentado nesta figura corresponde a medidas de injeção (fluxo) de potência tanto ativa quanto reativa e medidas de tensão presentes apenas nas barras com geração. Nas barras onde se tem a presença de PMUs, há medição tanto do fasor tensão naquela barra quanto das correntes em todas as linhas conectadas a ela. O plano de medição tanto para medidas SCADA como para medidas PMU é redundante o suficiente para permitir a análise de erros grosseiros. A precisão adotada para os medidores é de 1% para medidas SCADA e 0,1% para medidas fasoriais.

Os resultados apresentados nesta seção representam a média obtida após a realização de 50 simulações consecutivas.

Primeiramente, leva-se em consideração que o conjunto de medidas é completamente isento de erros grosseiros. Com isso, obtêm-se os resultados apresentados nas Figs. 3 e 4.




Figura 2: Sistema-teste IEEE 14 barras.




Figura 3: Erro relativo do módulo da tensão para as três etapas de estimação em relação aos valores obtidos pelo fluxo de potência.




Figura 4: Erro relativo de ângulo para as três etapas de estimação em relação aos valores obtidos pelo fluxo de potência.

Apesar das diferenças de precisão e processamento dos dados entre os sistema SCADA e PMU, percebe-se que os resultados obtidos pela fusão acompanham o comportamento dos estimadores individuais, apresentando erros de estimação que

tendem a assumir valores intermediários em relação aos obtidos por aqueles, sendo considerados satisfatórios.

Como mencionado na introdução, a maior vantagem da proposta deste artigo está na rejeição a erros grosseiros, bem como não ser necessário um novo processo de estimação de estados após a identificação e remoção desses erros. Ao adotarmos estimadores baseados no MCC, o efeito das medidas espúrias é eliminado mediante a atribuição de ponderação reduzida a essas medidas. Sendo assim, diversas simulações foram realizadas utilizando diversos tipos de erros grosseiros para o conjunto de medidas disponível, com ordem de grandeza entre 10 e 15 desvios-padrão. Devido às limitações de espaço, apenas uma combinação será aqui apresentada.

Considera-se que há um erro grosseiro no conjunto de medidas SCADA no fluxo de potência ativa entre as barras 10 e 11. Além disso, o plano de medição fasorial também apresenta uma medida espúria, sendo ela presente na medida de corrente entre a barra 2 e 4. Com isso, os resultados obtidos para a média das 50 simulações podem ser vistos nas Figs. 5 e 6.




Figura 5: Erro relativo do módulo da tensão para as três etapas de estimação em relação aos valores obtidos pelo fluxo de potência.




Figura 6: Erro relativo de ângulo para as três etapas de estimação em relação aos valores obtidos pelo fluxo de potência.

Comparando-se as figuras 5 e 6 com as figuras 3 e 4, podemos perceber que a presença de er-

ros grosseiros n o afeta sensivelmente a qualidade das estimativas, j  que os resultados s o bastante similares aos obtidos na sua aus ncia. Estes resultados s o indicadores da aplicabilidade da arquitetura proposta, que portanto se mostra uma metodologia de estima  o de estados promissora e resiliente face   ocorr ncia de medidas esp rias.

6 Conclus es

Este artigo tem por objetivo expandir as estrat gias de fus o de estimativas de estados mediante   ado  o de crit rios de m xima correntropia para estimadores individuais que processam medidas provenientes de sensores SCADA e PMU. Tais crit rios, quando aplicado   EESP, mostram-se resilientes   ocorr ncia de erros grosseiros, estejam eles presentes em medidas SCADA ou fasoriais. Al m disso, o algoritmo proposto confirma os bons resultados da abordagem via fus o de estimativas anteriormente apresentado na literatura que aborda a inclus o de medidas fasoriais na estima  o de estados em sistemas de pot ncia.

Agradecimentos

Os autores agradecem o apoio financeiro do CNPq mediante os projetos 400799/2014-6 e 312037/2013-9 (A. Sim es Costa).

Refer ncias

Abur, A. e Exposito, A. G. (2004). *Power System State Estimation: Theory and Implementation*, Marcel Dekker.

Albuquerque, A. (2012). *Estrat gias em dois est gios para incorporar medidas fasoriais sincronizadas na estima  o de estados em sistemas de pot ncia*, Master's thesis, UFSC.

Clements, K. A. e Sim es Costa, A. (1998). "Topology Error Identification using Normalized Lagrange Multipliers", *IEEE Transactions on Power Systems* **13**(2): 347–353.

Krstulovic, J., Miranda, V., Sim es Costa, A. J. A. e Pereira, J. (2013). Towards an auto-associative topology state estimator, *Power Systems, IEEE Transactions on* **28**(3): 3311–3318.

Liu, W., Pokharel, P. e Principe, J. (2006). Correntropy: A localized similarity measure, *Neural Networks, 2006. IJCNN '06. International Joint Conference on*, pp. 4919–4924.

Mili, L., Cheniae, M., Vichare, N. e Rousseeuw, P. (1996). Robust state estimation based on projection statistics [of power systems], *Power Systems, IEEE Transactions on* **11**(2): 1118–1127.

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

Mitchell, H. B. (2007). *Multi-sensor data fusion: an introduction*, Springer.

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

Monticelli, A. e Garcia, A. (1983). Reliable bad data processing for real-time state estimation, *IEEE Transactions on Power Systems* **PAS-102**(5): 1126–1139.

Monticelli, A., Wu, F. F. e Yen, M. S. (1986). Multiple bad data identification for state estimation by combinatorial optimization, *IEEE Transactions on Power Delivery* **1**(3): 361–369.

Opara, J. K. (2013). *Information Theoretic State Estimation in Power Systems*, PhD thesis, Faculdade de Engenharia da Universidade do Porto.

Parzen, E. (1962). On estimation of a probability density function and mode, *Annals of Mathematical Statistics* **3**(3): 1065–1076.

Phadke, A. e Thorp, J. (2008). *Synchronized phasor measurements and their applications*, Springer Verlag.

Pires, R., Costa, A. e Mili, L. (1999). Iteratively reweighted least-squares state estimation through Givens rotations, *Power Systems, IEEE Transactions on* **14**(4): 1499–1507.

Principe, J. C. (2010). *Information theoretic learning: Renyi's Entropy and Kernel Perspectives*, Vol. 1, 1st edn, Springer.

Principe, J. e Xu, D. (1999). An introduction to information theoretic learning, *Neural Networks, 1999. IJCNN '99. International Joint Conference on*, Vol. 3, pp. 1783–1787 vol.3.

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

Sim es Costa, A., Rolim, J. G. e Aitchison, P. W. (1991). Iterative bad-data suppression applied to state estimators based on the augmented matrix method, *Electric Power Systems Research* **20**: 205 – 213.

Wu, F. F. (1990). Power system state estimation: a survey, *Electrical Power & Energy Systems* **12**(2): 80–87.

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

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

Zhu, Y. (2003). *Multisensor decision and estimation fusion*, Kluwer Academic Publishers.

Zhuang, F. e Balasubramanian, R. (1985). Bad data suppression in power system state estimation with a variable quadratic-constant criterion, *Power Apparatus and Systems, IEEE Transactions on* **PAS-104**(4): 857 – 863.