

Planejamento de Sistemas de Medição Utilizando Teoria da Informação

Diogo Lopes Bragança,

Universidade Federal Fluminense – Departamento de Engenharia Elétrica
Rua Passo da Pátria, 156
diogolopesbraganca@id.uff.br

Andre Abel Augusto, Julio Cesar Stacchini de Souza, Rainer Zanghi

Universidade Federal Fluminense – Departamento de Engenharia Elétrica
Rua Passo da Pátria, 156, Bloco D, Sala 509
aaaugusto@id.uff.br, julio@id.uff.br, rzanghi@id.uff.br

RESUMO

A estimação de estado desempenha papel importante na operação de sistemas elétricos em tempo real, sendo responsável por obter a melhor estimativa do estado de uma rede elétrica a partir de um conjunto de medições contendo incertezas e eventualmente Erros Grosseiros. A qualidade da observação realizada pelo estimador de estado depende do grau de redundância do sistema de medição, que por sua vez é limitada por questões financeiras. Consequentemente, o desenho do plano de medição deve estabelecer o melhor compromisso entre seu custo e sua capacidade de observação. Este trabalho apresenta uma metodologia de planejamento de sistemas de medição utilizando critérios baseados na Teoria da Informação. Medidas de Informação capazes de quantificar numericamente a capacidade de observação da rede foram investigadas. Um algoritmo genético é empregado para encontrar o plano de medição que tenha a maior quantidade de informação possível sujeito a uma quantidade específica de medições. Simulações com uma rede de 6 barras e o sistema IEEE 14 demonstram a eficácia do método proposto ao proporcionar planos de medição mais eficientes, com alta redundância e menor número de medições.

PALAVRAS CHAVE. Planejamento de Sistemas de Medição, Otimização, Teoria da Informação, Metaheurística, Estimação de Estado.

OC – Otimização Combinatória; MH – Metaheurísticas.

ABSTRACT

State estimation plays an important role in the operation of real-time electrical systems, being responsible for obtaining the best estimate of the state of an electrical network from a set of measurements containing uncertainties and, eventually, gross errors. The quality of observation performed by the state estimator depends on the degree of redundancy of the measurement system, which in turn is limited by financial issues. Consequently, the design of the measurement plan should establish the best compromise between its cost and its observation capability. This work presents a methodology for planning measurement systems using criteria based on Information Theory. Information measures capable of numerically quantifying the observation capability of the network were investigated. A genetic algorithm is employed to find the measurement plan that has the maximum amount of information possible subject to a specific quantity of measurements. Simulations with a 6-bus network and the IEEE 14 system demonstrate the effectiveness of the proposed method by providing more efficient measurement plans with high redundancy and fewer measurements.

KEYWORDS. Measurement Design, Optimization, Information Theory, Metaheuristics, State Estimation.

OC - Combinatorial Optimization; MH – Metaheuristics.

1. Introdução

Os Sistemas de Gerenciamento de Energia (SGE) e os Sistemas de Gerenciamento de Distribuição (SGD) modernos incluem funções para monitoramento, controle, análise de contingência e otimização por meio de aplicações computacionais avançadas. Entre essas funções, a função de Estimação de Estado (EE) tem a intenção de filtrar pequenos erros de medição ordinários e eliminar possíveis dados espúrios, também denominados erros grosseiros (EGs), introduzidos por falhas no sistema de aquisição de dados [Monticelli 1999] e [Abur e Gómez Expósito 2004]. A Estimação de Estado (EE) lida com fluxos de potência ativa e reativa, injeções e magnitudes das tensões nas barras e das correntes nos ramos. Essas medições são comumente fornecidas por unidades terminais remotas (UTRs) instaladas em locais específicos da rede elétrica. Mais recentemente, medições dos fasores de tensão nodal e de corrente dos ramos tem vem sendo disponibilizados por meio de unidades de medição fasoriais (UMFs).

A capacidade de observação da EE, isto é, a sua aptidão em adequadamente determinar o estado da rede e processar EGs, depende do nível de redundância do plano de medição, que pode ser compreendida como o excesso de dados além do mínimo necessário para a determinação do estado estimado [Monticelli 1999] e [Abur e Gómez Expósito 2004]. Os aspectos que caracterizam a redundância são a localização, tipo, qualidade (precisão) e quantidade de medições na rede elétrica [Abur e Gómez Expósito 2004]. A forma como as criticalidades – grupos mínimos de medidas cuja indisponibilidade simultânea torna a rede inobservável – ocorrem num sistema de medição está intimamente associada a redundância da rede. Nos sistemas de medição em que ela é baixa, k -tuplas críticas de baixa cardinalidade são frequentes. Um k -tupla crítica ou C_k é um grupo de k medidas tais que apenas na ausência de k delas a rede se torna não observável [Augusto et al. 2018]. As medidas críticas são exemplos de C_1 , enquanto os pares de medições em um conjunto crítico correspondem C_2 s [Augusto et al. 2018]. EGs múltiplos em $k-1$ medidas de uma C_k não são identificáveis pela análise residual. Logo, além do efeito na observabilidade, a presença de C_k s, especialmente as de baixa cardinalidade ($k < 4$) compromete o processamento de dados espúrios. Embora se deseje que o plano de medição tenha a redundância mais alta possível, na prática isso não ocorre por limitações de natureza econômica e operacional, como infraestrutura de comunicação, custo de medição e a capacidade de processamento de dados em tempo real. Soma-se a isto, a inerente falibilidade dos medidores e dos componentes da rede pode resultar em reduções temporárias da redundância. Nesse contexto, para que o processo de estimação de estado transcorra de forma mais transparente possível, deve-se planejar o sistema de medição de modo que haja o melhor compromisso entre custo, confiabilidade e capacidade de observação deste plano.

O desenho de sistemas de medição vem sendo investigado por diversos autores. Os métodos propostos na literatura podem ser enquadrados em 3 categorias diferentes [Kogli 1975]: métodos de tentativa e erro, métodos de eliminação sistemática e métodos baseados em critério de observabilidade. A primeira classe de métodos simula a performance da EE para diferentes planos de medidas, sendo selecionado aquele de melhor qualidade, em termos de precisão do estado [Schweppe e Wildes 1970] e [Ariatti et al. 1975]. Métodos de eliminação sistemática [Kogli 1975] e [Aam et al. 1983] partem de uma configuração inicial, adicionando ou removendo medidas, e observando o impacto dessas modificações no processo de estimação. Métodos que projetam o sistema de medição segundo critérios de observabilidade e redundância se enquadram na terceira classe de métodos [Fetzer e Anderson 1975] e [Phua e Dillion 1978]. Diversos trabalhos na literatura propõem o planejamento de sistemas de medição sob a ótica da otimização. A principal vantagem dessa abordagem é a obtenção de planos ótimos segundo a métrica de otimização e restrições adotadas. Os problemas de desenho ótimo de sistema de medição podem ser solucionados utilizando-se técnicas de otimização exata [Baran et al. 1995] e [Castillo et al. 2008] ou de inteligência computacional [Ricciari e Falcão 1999] e [Rocha et al. 2017]. Os primeiros produzem soluções garantidamente ótimas, mas tem limitações quanto à modelagem do problema. Os métodos da outra categoria por outro lado não apresentam tais restrições e produzem soluções de elevada qualidade, cuja proximidade da solução ótima é desconhecida.

A Otimização por Colônia de Formigas é empregada no trabalho [Rocha et al. 2017], para determinar um plano de medição que possua o melhor compromisso entre custo, observabilidade, confiabilidade (capacidade de detecção e identificação de EGs simples – ausência de C1s e C2s) e robustez (preservação da confiabilidade e da observabilidade na ocorrência de variações topológicas e do plano de medição). O método permite determinar as medidas a serem coletadas por cada UTR e definir áreas de prioridade. Em [Baran et al. 1995] a alocação ótima de UTRs é realizada através de busca exaustiva. São considerados como requisitos para o plano ótimo a robustez, observabilidade e a confiabilidade. Os trabalhos [Abur e Magnago 1999] e [Castillo et al. 2008] empregam programação linear inteira para desenhar o sistema de medição, utilizando os critérios de observabilidade e robustez. O planejamento de sistemas de medição fasorial tem sido investigada nos últimos anos. Os critérios frequentemente adotados são a observabilidade [Baldwin 1993] e [Gou 2008], confiabilidade [Chen e Abur 2005] e [Chen e Abur 2008], robustez [Chakrabarti e Kyriakides 2008] e [Emami e Abur 2010] e custo do sistema de medição [Abbasy e Ismail 2009]. Alguns trabalhos vêm propondo a alocação conjunta de UMFs e UTRs [Chen e Abur 2008] e [Emami e Abur 2010].

A literatura sobre planejamento de sistemas de medição é vasta. Entretanto, poucos trabalhos se debruçam no uso da Teoria de Informação como critério de planejamento. Em 1978 Phua e Dillion [Phua e Dillion 1978] apresentam um método de planejamento de sistemas de medição guiado por um critério de entropia. O método considera aspectos técnicos e financeiros do problema. O trabalho de Qiao Li [Li et al. 2013] propõe a Informação Mútua de Shannon entre as medidas fasoriais e o estado da rede elétrica como critério de planejamento. Em [Krstulovic e Miranda 2014] constrói-se um índice de observabilidade baseado na Informação Mútua de Reyni, que é utilizada para selecionar medidas relevantes para estimação da configuração. Em [Augusto et al. 2014] é apresentada uma metodologia para identificar, num sistema de medição, as medidas a serem aquisitadas ou não em tempo real. Como critério de relevância propôs-se no trabalho uma métrica baseada na divergência de Kullback-Leibler. Os critérios de informação são capazes de agregar numa única medida a observabilidade, a confiabilidade, a qualidade e a robustez de um plano de medição. No que tange a observabilidade, também são capazes de expressar a observabilidade de forma gradativa abrangendo diversos níveis de redundância entre a observabilidade e a inobservabilidade, diferentemente da resposta binária provida pela análise de observabilidade clássica.

Este artigo propõe um método para projetar sistemas de medição para EE. A metodologia visa selecionar a melhor combinação de medições em tempo real e pseudomedidas que minimiza a perda de desempenho do processo de EE. Uma medida de desempenho para a estimação de estado, baseada na teoria da informação, também é investigada. Testes com o sistema de teste IEEE-6 e IEEE-14 Barras são apresentados e seus resultados discutidos. Na Seção 2, o background técnico necessário para a metodologia proposta será apresentado. A Seção 3 apresenta uma metodologia para o fornecimento de medições relevantes para a estimação de estado do sistema de energia. Na Seção 4, resultados de simulações usando os sistemas de teste IEEE-6 e IEEE-14 são apresentados. A Seção 5 apresenta as conclusões deste trabalho de pesquisa.

2. Fundamentação de Estimação de Estado

O processo clássico de Estimação do Estado (EE) estrutura-se em 4 etapas: a de configuração de rede, na qual o modelo de rede é obtido a partir dos estados dos disjuntores e chaves; a de análise de observabilidade, que determina se o estado do sistema pode ser estimado a partir das medidas disponíveis; a de filtragem da EE, em que as estimativas de estado e medições são obtidas; e a etapa de processamento de dados espúrios, onde as inconsistências nos dados são identificadas e corrigidas, desde que haja redundância suficiente nas medições. Os principais aspectos do problema de Estimação do Estado do sistema de energia podem ser encontrados em [Monticelli 1999] e [Abur e Gómez Expósito 2004].

2.1. Estimação de Estado Linear

O estimador de estado linear é útil para analisar questões relacionadas à observabilidade e planejamento de sistemas de medição [Monticelli 1999]. O modelo de EE linear assume que a magnitude de todas as tensões da rede iguais a 1.0 pu e que os elementos shunt e a resistência série são desprezíveis, o que permite que a relação entre as medidas e o estado da rede possa ser descrita matematicamente pela equação (1):

$$\mathbf{z} = \mathbf{H}\mathbf{x} + \boldsymbol{\varepsilon} \quad (1)$$

onde $\mathbf{z}$ ($m \times 1$) é o vetor de medidas; $\mathbf{H}$ ($m \times n$) é a matriz Jacobiano; $\mathbf{x}$ ($n \times 1$) é o vetor de estado e $\boldsymbol{\varepsilon}$ é o vetor de erro das medidas.

O vetor de medidas é composto pela parcela ativa da potência injetada e dos fluxos de potência, pelos ângulos de tensão das barras e pela parte real dos fasores de corrente dos ramos. O vetor $\mathbf{x}$ é constituído pelos ângulos das tensões nodais, sendo n igual ao número de barras da rede. A matriz $\mathbf{H}$ mapeia o estado nas medidas observadas. O erro de medição é assumido ser independente e normalmente distribuído com valor esperado $\mathbf{0}$ e matriz de covariância $\mathbf{R} = \text{diag}(u_1^2, \dots, u_m^2)$ onde u_i é a incerteza da medida z_i e $\text{diag}(\cdot)$ é a matriz diagonal correspondente a $u_1^2, \dots, u_m^2$. O estado mais provável $\hat{\mathbf{x}}$, segundo o critério dos mínimos quadrados ponderados [Abur e Gómez Expósito 2004] é a solução do problema de otimização (2).

$$\min_{\mathbf{x}} [\mathbf{z} - \mathbf{H}\mathbf{x}]^T \mathbf{R}^{-1} [\mathbf{z} - \mathbf{H}\mathbf{x}] \quad (2)$$

que pode ser determinada resolvendo-se as equações normais (3):

$$\mathbf{G}\mathbf{x} = \mathbf{H}^T \mathbf{R}^{-1} \mathbf{z} \quad (3)$$

onde $\mathbf{G} = \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H}$ é a matriz de ganho.

O sistema linear (3) tem solução única quando $\mathbf{G}$ é não singular. Assim sendo, uma rede é considerada observável somente se $\mathbf{G}$ tiver posto completo [Monticelli 1999], sendo, estado estimado dado por $\hat{\mathbf{x}} = \mathbf{G}^{-1} \mathbf{H}^T \mathbf{R}^{-1} \mathbf{z}$. Visto que as medidas de injeção e fluxo vem em pares ativo/reactivo, se ao menos uma medida de magnitude de tensão estiver presente na rede elétrica, os resultados de observabilidade obtidos para o caso linear podem ser aplicados o não linear [Abur e Gómez Expósito 2004]. A função densidade de probabilidade (fdp) condicional do estado estimado, parametrizada por $\mathbf{z}$, é dada por:

$$\varphi(\hat{\mathbf{x}}; \mathbf{z}) = \mathcal{N}(\mathbf{x}^*, \mathbf{G}^{-1}) = \frac{1}{\sqrt{(2\pi)^m |\mathbf{G}^{-1}|}} \exp \left(-\frac{1}{2} (\hat{\mathbf{x}} - \mathbf{x}^*)^T \mathbf{G} (\hat{\mathbf{x}} - \mathbf{x}^*) \right) \quad (4)$$

onde $\mathbf{x}^*$ é o estado verdadeiro.

A partir o estado estimado, pode-se realizar o processamento de EGs por meio da análise residual. Segundo o teste dos resíduos normalizados, a medida i é suspeita de estar contaminada por EG se não atender à condição (5):

$$r_i^N = \frac{|r_i|}{v_i} = \frac{|z_i - \hat{z}_i|}{\sqrt{\mathbf{E}(i, i)}} \leq \ell \quad (5)$$

onde $\hat{z}_i$, r_i e r_i^N são respectivamente o valor estimado, o resíduo e o resíduo normalizado da medida i , $v_i = \sqrt{\mathbf{E}(i, i)}$ o desvio padrão da medida i , $\mathbf{E} = \mathbf{R} - \mathbf{H}\mathbf{G}^{-1}\mathbf{H}^T$ a matriz de covariância ($m \times m$) dos resíduos das medidas, e ℓ o limiar de detecção de EGs.

A medida crítica (C_{meas}) é uma criticalidade do tipo C1 cujo erro não pode ser filtrado pela EE. Logo, seu resíduo e variância são nulos. Medidas que constituem C2 entre si formam um conjunto crítico (C_{conj}). Os resíduos normalizados das medidas pertencentes a um C_{conj} são idênticos, o que torna os EGs nessas medidas detectáveis, mas não identificáveis. Métodos eficientes de listagem de C_{meas} e C_{conjs} podem ser encontrados em [Augusto 2019].

2.3. Divergência de Kullback-Leibler

A Teoria da Informação (TI) é um ramo da matemática aplicada que envolve a quantificação da informação. Suas bases foram desenvolvidas por [Shannon 1948] para o projeto de sistemas de comunicação eficientes e confiáveis. A TI foi posteriormente aplicada a uma variedade de campos, desde inferência estatística até neurobiologia e inteligência artificial. A aplicação de conceitos de Aprendizado da Teoria da Informação à Estimção do Estado foi sugerida pela primeira vez em [Miranda et al. 2009]. Um quantificador de informação importante é a divergência de Kullback-Leibler (D_{KL}) ou entropia relativa, que quantifica a similaridade entre duas densidades de probabilidade. Para variável aleatória contínua ξ , a D_{KL} é definida por (6).

$$D_{KL}(f \parallel \hat{f}) = \int_{-\infty}^{+\infty} f(\xi) \log \left(\frac{f(\xi)}{\hat{f}(\xi)} \right) d\xi = \int_{-\infty}^{+\infty} f(\xi) \log f(\xi) d\xi - \int_{-\infty}^{+\infty} f(\xi) \log \hat{f}(\xi) d\xi \quad (6)$$

onde f e $\hat{f}$ são respectivamente as funções densidade de probabilidade (fdp) verdadeira e assumida para a variável aleatória ξ .

Importante destacar que esta definição se estende para vetores aleatórios. Neste caso, as distribuições de probabilidade são conjuntas. Além disso, caso a variável (ou vetor) aleatória seja discreta, a integral em (6) deve ser substituída por um somatório. A divergência de Kullback-Leibler é não negativa, tendo seu valor nulo somente quando $f = \hat{f}$. O cálculo de D_{KL} é uma tarefa matemática e computacionalmente difícil. Entretanto, expressões simplificadas podem ser obtidas em determinados casos. Considere o caso em que f e $\hat{f}$ pertencem à família das distribuições normais. Se $f = \mathcal{N}(\mu_0, \Sigma_0)$ e $\hat{f} = \mathcal{N}(\mu_1, \Sigma_1)$ e o vetor aleatório ξ tem dimensão $d \times 1$, então $D_{KL}(f \parallel \hat{f})$ é dada por (7):

$$D_{KL}(f \parallel \hat{f}) = \frac{1}{2} \left[\text{tr}(\Sigma_1^{-1} \Sigma_0) + (\mu_1 - \mu_0)^T \Sigma_1^{-1} (\mu_1 - \mu_0) + \ln \frac{|\Sigma_1|}{|\Sigma_0|} - d \right] \quad (7)$$

onde $\text{tr}(\cdot)$ é o traço de uma matriz.

Além da interpretação D_{KL} como o grau de similaridade entre distribuições, ela pode ser compreendida como a perda de informação resultante da adoção da distribuição alternativa $\hat{f}$ em lugar da verdadeira f .

3. Metodologia Proposta

3.1. Formulação Geral do Problema de Alocação de Medidores

O problema de planejamento de medidores explorado neste trabalho consiste na determinação dos tipos e localizações dos medidores constituintes do plano de medição, de modo a se maximizar a capacidade de observação, respeitando-se limites de investimento, observabilidade e confiabilidade. Seja Ω o conjunto de todos os possíveis planos de medição e $\omega \in \Omega$ um plano de medição. A formulação geral do problema é dada por:

$$\max o(\omega) \quad (8)$$

$$s. a \quad \omega \in \Omega \quad (9)$$

$$c(\omega) \leq c_{lim} \quad (10)$$

$$1_{ob}(\omega) \leq 0 \quad (11)$$

$$1_{c1}(\omega) \leq 0 \quad (12)$$

$$1_{c2}(\omega) \leq 0 \quad (13)$$

onde $o(\cdot)$ é a função que quantifica a capacidade de observação de plano de medição, $c(\cdot)$ é a função de custo do plano, $1_{ob}(\cdot)$, $1_{c1}(\cdot)$ e $1_{c2}(\cdot)$ são respectivamente as funções indicadoras da observabilidade, presença de medidas críticas e presença de pares críticos.

A restrição (10) obriga que o custo de investimento no plano de medição seja igual ou inferior ao montante reservado para esse fim. Neste trabalho, o custo será modelado como o número de medidores do plano isto é $c(\omega) = \text{card}(\omega)$. A função indicadora $1_{ob}(\omega)$ é igual a 0 caso o plano seja observável e 1 caso contrário. Logo, a restrição (11) obriga que o plano de medição ótimo seja observável, implementando o requisito de observabilidade. As funções indicadoras $1_{c1}(\omega)$ e $1_{c2}(\omega)$ são nulas quando o plano de medição não apresenta medidas e pares críticos respectivamente, assumindo o valor 1 quando isso ocorre. As restrições (12) e (13) representam o requisito de confiabilidade. A função o mede a aptidão da EE em determinar o estado e processar EGs, podendo ser uma medida da precisão do estado, do grau de observabilidade ou ainda do nível de criticidade. Quando os dois últimos são quantificados por meio de $o(\cdot)$, as restrições (11) – (13) podem ser suprimidas.

O problema estabelecido em (8) – (13) é de natureza combinatória. Portanto, métodos baseados em meta-heurísticas são adequados para resolver essa classe de problemas. Neste trabalho, um Algoritmo Genético (AG) será empregado na solução de (8) – (13). Uma descrição completa do AG e sua aplicação a problemas de otimização combinatória pode ser encontrada em [Goldberg 1989].

3.1. Medidas de Capacidade de Observação

Para especificar o problema de otimização (8) – (13) é necessário definir a função $o(\cdot)$. Propõe-se neste trabalho a expressão da capacidade de observação através da D_{KL} apresentada na seção 2.2 baseada na densidade de probabilidade $\phi(\hat{\mathbf{x}}; \mathbf{z})$, a probabilidade de ocorrência do estado estimado $\hat{\mathbf{x}}$ dado a medição observada $\mathbf{z}$. Considere os planos de medição $\omega_0, \omega \in \Omega$. Suponha o sistema de medição de referência ω_0 com a máxima redundância possível. De acordo com (4), as densidades de probabilidade do estado estimado segundo os planos de medição ω e ω_0 são respectivamente $f(\hat{\mathbf{x}}; \mathbf{z}) = \mathcal{N}(\mathbf{x}^*, \mathbf{G}_0^{-1})$ e $\hat{f}(\hat{\mathbf{x}}; \mathbf{z}) = \mathcal{N}(\mathbf{x}^*, \mathbf{G}_1^{-1})$, onde $\mathbf{G}(\omega_0) = \mathbf{G}_0$ e $\mathbf{G}(\omega) = \mathbf{G}_1$. Substituindo-se f e $\hat{f}$ em (11) obtêm-se a entropia relativa:

$$C_{ER}(\omega) = D_{KL}(f||\hat{f}) = \frac{1}{2} \left[\text{tr}(\mathbf{G}_1 \mathbf{G}_0^{-1}) + \ln \frac{|\mathbf{G}_0|}{|\mathbf{G}_1|} - n \right] \quad (14)$$

A expressão (14) é uma medida exata e direta da divergência de Kullback-Leibler. Não negativa, atinge seu valor mínimo 0 quando $\omega_0 = \omega$ e $\mathbf{G}_0 = \mathbf{G}_1$. Quando a rede é não observável $C_{ER}(\omega) = +\infty$. Mesmo que o plano ω_0 não seja de máxima redundância, $C_{ER}(\omega)$ pode ainda ser empregada para selecionar as medidas mais relevantes do plano de medição, isto é, as medidas que cuja indisponibilidade traz sérios prejuízos à capacidade de observação. Caso se deseje avaliar o reforço de um plano de medição existente, pode-se aplicar a expressão (14), considerando como o plano de referência ω_0 o plano reforçado e como ω o plano original. Tendo em vista que o problema de otimização (9) – (13) é de maximização. Neste trabalho será estabelecida como medida alternativa de capacidade de observação a função $o(\omega) = -C_{ER}(\omega)$.

3.2. Codificação da Solução

A codificação usada para descrever as soluções propostas deve ser de fácil manipulação pelo AG e capaz de representar adequadamente o espaço de soluções. Considere $\omega_0 \in \Omega$ o plano de com a maior redundância possível e $m_0 = \text{card}(\omega_0)$ o número de medidas nesse plano. Propõe-se como representação de ω o vetor binário $\mathbf{b}(\omega) = [b_1 \ \cdots \ b_i \ \cdots \ b_m]$ onde $b_i = 1$ se a medida i pertence à ω e $b_i = 0$ caso contrário. A Figura 1 ilustra o vetor de medidas.

Medida 1	Medida 2	...	Medida i	...	Medida m
1	0	...	0	...	1

Figura 1 - Representação da solução proposta.

Caso se deseje realizar a alocação de UMs, propõe-se utilizar o vetor binário estendido $\mathbf{b}(\omega) = [b_1 \ \dots \ b_i \ \dots \ b_m | b_{m+1} \ \dots \ b_{m+i} \ \dots \ b_{m+nb}]$ onde $b_{m+i} = 1$ se a unidade de medição i pertence à ω e $b_{m+i} = 0$ caso contrário. Importante destacar que se a medida i pertence à unidade de medição medida j , ela integrará o plano de medição ω somente se $b_i = 1$ e $b_{m+j} = 1$.

3.3. Função de Aptidão

A função de aptidão é responsável por guiar o processo de otimização do AG. Portanto, uma formulação adequada - que cubra todos os objetivos/restrições e estabeleça um compromisso entre eles - deve ser escolhida. Neste trabalho, a função de aptidão investigadas para o planejamento do sistema de medição é:

$$FA1 = o(\omega) - M|c_{lim} - c(\omega)| \quad (15)$$

onde c_{lim} é o número de medidores desejado para o plano de medição, $c(\omega) = \text{card}(\omega)$ o número de medidores do plano ω e M o fator de penalidade tal que $M \gg |o(\omega)|$.

3.4. Algoritmo Proposto

O Quadro 1 apresenta os passos para obter a alocação ótima de medidores proposta. Caso não se deseje saber somente a quantidade, tipo e localização dos medidores, pode-se adotar a matriz de covariância das medidas unitária. Repare que as restrições (11) – (13) não foram incluídas no processo de otimização. Como será demonstrado adiante, os indicadores $o_1(\omega)$ e $o_2(\omega)$ indiretamente quantificam a presença de C1 e C2 no plano de medição. Vale ressaltar que as restrições podem ser incorporadas em (15) de forma análoga a inclusão da restrição (12). Sendo o AG é um método de otimização estocástica, não há garantia sobre quão próxima a solução obtida está da solução ótima global. Portanto, diversas execuções do algoritmo devem ser realizadas, para que se tenha a melhor e mais consistente solução.

Algoritmo: Otimização de plano de medição via AG
Passo 1 – Construir plano de referência ω_0 ; Passo 2 – Construir, para ω_0 , as matrizes $\mathbf{H}$ e $\mathbf{G}_0 = \mathbf{H}_0^T \mathbf{R}_0^{-1} \mathbf{H}_0$; Passo 3 – Definir o número de medidas desejado c_{lim} ; Passo 4 – Construir a codificação da solução $\mathbf{b}(\cdot)$; Passo 5 – Definir os parâmetros do AG; Passo 6 – Construir a população inicial de soluções; Passo 7 – Obter o plano de medição ótimo ω_{opt} via AG, adotando FA1 ou FA2 como aptidão; Passo 8 – Retornar a solução ótima ω_{opt} .

Quadro 1 – Representação da solução proposta.

4. Testes e Resultados

A metodologia proposta foi implementada na linguagem Python e a otimização foi realizada usando a biblioteca PyGAD. Os parâmetros do AG utilizados na simulação estão apresentados na Tabela 1. Foi utilizada uma máquina com processador i5 de 8ª geração e 8GB de memória RAM.

Tabela 1 - Parâmetros da Otimização.

Parâmetros	Valor
Tamanho da População	100
Tipo de Seleção	Torneio
Tipo de Crossover	Crossover de dois pontos
Taxa de Crossover	100%
Tipo de Mutação	Inversão
Taxa de Mutação	95%
Número de Gerações	100

4.1. Exemplo ilustrativo com o Sistema IEEE 6 Barras

A rede teste IEEE 6 de Barras é apresentada na Figura 2a, juntamente com o plano de medição de referência ω_0 . Adotou-se como convenção a representação visual das medidas de injeção de potência pelo símbolo ▲, sendo as medidas de fluxo de potência indicadas pelo símbolo ■ e as de ângulo por ☀. O sistema de medição de referência é composto por 12 pares de medidas de fluxo de potência e 6 pares de injeção de potência e 1 pseudomedida de ângulo na barra 1, totalizando 19 medições. Considerando o modelo linear de EE, a proporção de medidas para medidores é de 6 para 1 aproximadamente, tendo uma redundância extremamente alta.

Foram realizados 3 testes, fixando-se o número de medidas em exatamente 6, 8 e 9 medidores, sendo uma desses a pseudomedida do ângulo da barra 1. A primeira execução é caracterizada pelo limite mínimo que garante a observabilidade do sistema e, a cada nova execução, acrescentou-se duas medidas até que a variação da divergência (14) fosse pequena. A Figura 3 apresenta os resultados. O índice D_{KL} , responsável por indicar a distância entre plano encontrado e o sistema totalmente redundante, reduz conforme o número de medidas do sistema de medição aumenta. A Tabela 2 apresenta o valor da divergência e a quantidade de criticalidades C1 e C2, para cada plano obtido. Refletindo os altos valores atingidos no D_{KL} , o conjunto de 8 medidas apresenta apenas os conjuntos C2 e, por fim, o plano com 9 medidas não apresenta nenhuma medida crítica ou conjunto crítico. Observando o resultado do plano com 9 medidas apresentado na Figura 2b, fica evidente a preferência do método para as medidas do tipo de injeção, uma vez que ela está presente em maior quantidade no plano. Outro ponto a ser ressaltado é a distribuição uniforme das medidas no sistema, uma vez que o plano reduzido não apresentou nenhuma medida redundante.




Figura 2 - Sistema IEEE-6 Barras. Plano de medição de referência (a). Plano de medição otimizado de 9 medidas (b).

Tabela 2 - Resultados da Otimização: Caso 01

Nº de Medidas	6	8	9
D_{KL}	0,70	0,35	0,13
C1	5	0	0
C2	0	10	0




Figura 3 - Resultado do algoritmo para o sistema IEEE-6 Barras.

4.2. Teste com o Sistema IEEE 14 Barras

No caso 2, é apresentado um sistema de 14 Barras contendo 14 medidas de injeção de potência, 50 medidas de fluxo de potência, 1 uma pseudomedida de ângulo na barra 1 (Figura 4a). Similarmente ao teste anterior, aumentou-se o número de medidas do plano, até que a variação de D_{KL} fosse pequena. A Figura 5 apresenta o comportamento de D_{KL} em relação ao número de medidas dos planos de medição ótimos. A D_{KL} apresenta inicialmente grande redução, não apresentando mudanças significativas quando o número de medidas excede 18. Conforme mostra a Tabela 3, com 22 medidas não há mais medidas e conjuntos críticos presentes no plano de medição. Convém destacar que ainda pode haver tuplas críticas de medida de cardinalidade mais elevada no plano de medição.




Figura 4 - Sistema IEEE-14 barras. Plano de medição de referência (a). Plano de medição otimizado de 22 medidas (b).

Tabela 3 - Resultados do Otimizador: Caso 02.

Nº de Medidas	14	16	18	20	22
D_{KL}	6,49	5,20	2,72	2,08	1,51
C1	13	0	2	1	0
C2	0	13	2	1	0




Figura 5 - Resultado do algoritmo para o sistema IEEE-14 Barras.

A partir da distribuição das medições para o plano de 22 medidas apresentada na Figura 4b, novamente têm-se o prevaletimento da medida de injeção de potência em relação às de fluxo, uma vez que apenas a barra 1 não possui essa medida. Porém, a ausência de injeção nesse ponto do sistema é compensada com outras 3 medidas de fluxo que estão nas proximidades dessa barra.

5. Conclusões

Este artigo introduziu uma nova metodologia, baseada em conceitos de Teoria da Informação, para projetar a distribuição topológica de sistemas de medição para monitoramento em tempo real de sistemas de energia elétrica, com o objetivo de servir a um processo de Estimação de Estado (EE). Um objetivo específico é determinar o melhor conjunto de medidas que minimize a degradação do desempenho do EE em tempo real. A adoção de um critério de qualidade para avaliar o desempenho do EE, baseado na Teoria da Informação, é uma inovação significativa: proporciona uma base teórica para avaliar a qualidade do EE, em vez de recorrer a critérios heurísticos inspirados na engenharia. Além disso, o modelo apresenta semelhanças e constrói pontes para outras medidas sugeridas, facilitando sua compreensão e interpretação.

O sucesso do método foi alcançado por meio de um desenvolvimento matemático cuidadoso, aliado a uma técnica algorítmica baseada em Algoritmos Genéticos com uma codificação de cromossomos adequada. O problema tem uma natureza combinatória, o que justifica a escolha de uma meta-heurística como solucionador. A função de aptidão mostrou-se flexível, direta e ajustável aos objetivos de otimização do projetista. A solução do problema é estabelecida como um compromisso entre custo e qualidade do EE e, portanto, embora não discutido neste artigo, uma fronteira de Ótimo de Pareto pode ser explorada manipulando o trade-off entre os dois objetivos – ou seja, a nova abordagem permite uma base teórica para um conceito de trade-off entre a variação no custo de um sistema de medição e seu impacto no desempenho da EE. Os resultados dos testes foram obtidos com o sistema IEEE 6 e IEEE 14 Barras. Esses resultados ilustram o caráter geral do novo modelo. Em particular, provou-se útil para sistemas de potências uma vez que foi possível obter grande qualidade na EE a partir de uma métrica eficiente de escolha e posicionamento das medidas do sistema.

6. Agradecimentos

Os autores agradecem o apoio financeiro concedido pelo CAPES, CNPq e FAPERJ. Tendo este último apoiado este trabalho através do processo nº E-26/211.233/2019.

Referências

- Monticelli, A. (1999). State Estimation in Electric Power Systems: A Generalized Approach. Springer US, New York.
- Abur, A., e Gómez Expósito, A. (2004). Power System State Estimation: Theory and Implementation. Marcel Dekker, New York.
- Augusto, A. A., et. al. (2019). "Branch-and-Bound Guided Search for Critical Elements in State Estimation", IEEE Trans. Power Syst., vol. 34, no. 3, pp. 2292 – 2301.
- Augusto, A. A et al. (2014). "Most Relevant Measurements For State Estimation According to Information Theoretic Criteria", International Conference on Probabilistic Methods Applied to Power Systems (PMAPS), pp. 1-6, Durham, Reino Unido.
- Shannon, C.E. (1948), "A mathematical theory of communication", Bell System Technical Journal vol.27 no.3, pp. 379–423.
- Miranda, V., Santos, A. e Pereira, J. (2009), " State Estimation Based on Correntropy: A proof of concept", IEEE Transactions on Power Systems, vol.24, no.4, pp.1888-1889.
- Goldberg, D. E. (1989), Genetic Algorithms in Search, Optimization and Machine Learning. Reading. Addison-Wesley, Massachusetts.
- Augusto, A. A. et al. (2019). "Branch-and-Bound Guided Search for Critical Elements in State Estimation", IEEE Trans. Power Syst., vol. 34, no. 3, pp. 2292 – 2301.
- Li, Q. et al. (2013). "An Information-Theoretic Approach to PMU Placement in Electric Power Systems," in IEEE Transactions on Smart Grid, vol.4, no.1, pp.446-456.
- Krstulovic, J. e Miranda, V. (2014). "Selection of measurements in topology estimation with mutual information", Proceedings of 2014 IEEE International Energy Conference (ENERGYCON), vol. 1, no. 1, pp.589-596.
- Koglin, H. (1975). "Optimal measuring system for state estimation", in Proc. PSCC.
- Rocha, H. R. d. O. et al. (2017). "Fast and flexible design of optimal metering systems for power systems monitoring", J. Control Autom. Electr. Syst., vol. 29, no. 2, pp. 209–218.
- Phua, K. e Dillion, T. (1978). "Optimal choice of measurements for state estimation," IEEE Transactions on Power Apparatus and Systems", vol. 97, no. 2, pp. 321–321.
- Baran, M. E. et al. (1995). "A meter placement method for state estimation", IEEE Transactions on Power systems", vol. 10, no. 3, pp. 1704–1710, 1995.
- Schweppe, F. C. e Wildes, J. (1970). "Power System Static-State Estimation, Part I: Exact model," IEEE Transactions on Power Apparatus and systems, no. 1, pp. 120–125.
- Castillo, E. et al. (2008). "m – k robust observability in state estimation," IEEE Transactions on Power Systems, vol. 23, no. 2, pp. 296–305.

Emami, R. e Abur, A. (2010). “Robust measurement design by placing synchronized phasor measurements on network branches,” IEEE Transactions on power systems, vol. 25, no. 1, pp. 38–43.

Abbasy, N. H. e Ismail, H. M. (2009). “A unified approach for the optimal pmu location for power system state estimation”, IEEE Transactions on power systems, vol. 24, no. 2, pp. 806–813.

Gou, B. (2008). “Optimal Placement of PMUs by Integer Linear Programming”, IEEE Transactions on power systems, vol. 23, no. 3, pp. 1525–1526.

Chen, J. e Abur, A (2008). “Enhanced Topology Error Processing Via Optimal Measurement Design”, IEEE Transactions on power systems, vol. 23, no. 3, pp. 845–852.

Ariatti, F et al. (1975). “Designing State Estimation in View of Reliability”, in Proc. 5th PSCC, pp. 2–3.

Aam, S. et al. (1983). “Design of the Measurement System for State Estimation in the Norwegian High-Voltage Transmission Network”, IEEE transactions on power apparatus and systems, no. 12, pp. 3769–3777.

Fetzer, E. E. e Anderson, P. (1975). “Observability in the State Estimation of Power Systems”, IEEE transactions on power Apparatus and Systems, vol. 94, no. 6, pp. 1981–1988.

Ricceri, O. e Falcão, D. (1999). “A Meter Placement Method for State Estimation Using Genetic Algorithms”, Intelligent System Application to Power Systems (ISAP), pp. 360–364.

Abur, A. e Magnago, F. H. (1999). “Optimal Meter Placement for Maintaining Observability During Single Branch Outages”, IEEE Transactions on Power Systems, vol. 14, no. 4, pp. 1273–1278.

Baldwin, T. L. et al. (1993). “Power System Observability with Minimal Phasor Measurement Placement”, IEEE Trans. Power Syst., vol. 8, no. 2, pp. 707–715.

Chen, J. e Abur, A. (2005). “Improved Bad Data Processing Via Strategic Placement of PMUs”, IEEE Power Engineering Society General Meeting, IEEE.

Chakrabarti, S. e Kyriakides, E. (2008). “Optimal Placement of Phasor Measurement Units for Power System Observability”, IEEE Transactions on power systems, vol. 23, no. 3, pp. 1433–1440.