

ALGORITMO EVOLUTIVO MULTI-OBJETIVO PARA REDUÇÃO DE CUSTOS NA ALOCAÇÃO DE MEDIDORES SCADA E PMU PARA EFEITO DE ESTIMAÇÃO DE ESTADO

Marcos P. Vigliassi, João B. A. London Jr., Alexandre C. B. Delbem, Julio A. D. Massignan

LACO, Dep. de Eng. Elétrica, Escola de Engenharia de São Carlos – Universidade de São Paulo

Av. Trabalhador São-carlense nº 400, CEP: 13560-250, fone: 55-16-33739321

E-mails: mvigliassi@usp.br, jbalj@sel.eesc.usp.br, acbd@icmc.usp.br, julio.massignan@usp.br

Abstract— Metering system planning for state estimation is a combinatorial problem and meta-heuristics have been employed to solve it. However, the majority of them require the formulation of puzzling objective functions and fine-tuning of parameters which are usually problem-dependent. This paper proposes a methodology that minimizes the investment cost, providing system observability and the absence of critical measurements, critical sets and critical remote terminal units. The proposed methodology is based on the Multi-objective Evolutionary Algorithm with subpopulation Tables, combined with the properties of the H_A matrix. This matrix is used to perform a local search minimizing the cost associated with each problem constraint. In a simple and direct way the methodology allows the adjustment of the operational constraints to the financial resources available in the companies. Simulations results with IEEE 14, 30, 57 and 118-bus test systems and a real Brazilian system illustrate the efficiency of the proposed methodology.

Keywords— Power Systems, State Estimation, Measurement Placement, Multi-objective Evolutionary Algorithm.

Resumo— O planejamento de sistemas de medição é um problema combinatorial e meta-heurísticas têm sido aplicadas para resolvê-lo. Contudo, a maioria delas necessita de funções objetivo específicas e ajustes de parâmetros dependentes do problema e do sistema a ser analisado. Este artigo propõe uma metodologia que minimiza o custo na alocação de medidores convencionais SCADA e fasoriais, garantindo a observabilidade do sistema e ausência de medidas críticas, conjuntos críticos de medidas e unidades terminais remotas críticas. A metodologia é baseada em um Algoritmo Evolutivo Multi-objetivo em Tabelas, combinado com a matriz H_A . Essa matriz é utilizada para realizar uma busca local, minimizando o custo relacionado a cada uma das restrições. A metodologia permite, de forma simples e rápida, adequar as restrições do problema aos recursos financeiros disponíveis nas empresas. Para ilustrar a eficiência da metodologia proposta, foram realizadas simulações com os sistemas de 14, 30, 57 e 118 barras do IEEE e com um sistema real Brasileiro.

Palavras-chave— Sistemas de Potência, Estimação de Estado, Alocação de medidas, Algoritmo Evolutivo Multi-objetivo.

1 Introdução

O crescimento no consumo de energia elétrica e a inclusão de novas tecnologias de controle aumentaram a complexidade dos Sistemas Elétricos de Potência (SEP). Para operar esses sistemas de forma segura e confiável o Estimador de Estado (EE) é uma ferramenta essencial, pois fornece, em tempo real, um modelo completo e confiável do SEP, a partir dos parâmetros da rede e da topologia atual do SEP, determinada anteriormente pelo configurador de redes (London et al. 2007; Coser et al. 2006), e do processamento de um conjunto redundante de medidas.

O correto funcionamento de um EE depende do sistema de medição disponível, ou seja, da distribuição dos medidores e Unidades Terminais Remotas (UTRs). De acordo com a literatura, um Sistema de Medição Confiável (SMC) para efeito de estimação de estado é aquele que além de garantir a observabilidade do sistema, é livre de Medidas Críticas (MC), Conjuntos Críticos de Medidas (CCM) e UTR críticas (Bozz et al. 2014; Vigliassi et al. 2009; Coser et al. 2006).

Em termos de medidas, adicionalmente às medidas convencionais SCADA, novos medidores têm sido incluídos no processo de estimação de estado em SEP, os chamados Medidores Fasoriais Sincronizados (MFS), obtidos pelas Unidades de Medição Fasoriais (UMF). Este dispositivo possibilita a medição do fasor de tensão da barra onde está localizada a UMF e dos fasores de corrente de linhas adjacentes conectadas àquela barra. As medições realizadas por

esses equipamentos são sincronizadas pelo tempo de referência fornecido pelo GPS (*Global Position System*) (Manousakis et al. 2012).

O planejamento de SMCs sem considerar o custo já é um problema de otimização combinatorial que exige a investigação de um grande número de possíveis soluções (London et al. 2003; Manousakis et al. 2012). Quando o custo para aquisição e instalação dos medidores é considerado, o problema torna-se mais complicado, devido às exigências conflitantes entre o custo e a confiabilidade do sistema de medição.

Devido ao exposto, heurísticas e meta-heurísticas têm sido utilizadas para resolver esse problema. Na maioria delas, o problema multi-objetivo é convertido em um único objetivo utilizando pesos (Souza et al. 2005; Saha Roy et al. 2012; Bozz et al. 2014; Coser et al. 2006; Vigliassi et al. 2009; Castro & Müller 2016). Um dos problemas dessa estratégia é a dependência da correta atribuição dos pesos da função objetivo (Deb 2001).

Este artigo propõe, inicialmente, uma formulação multi-objetivo para o tratamento do problema de planejamento de SMCs. Em seguida propõe uma nova metodologia, baseada em uma técnica de Algoritmo Evolutivo Multi-objetivo (AEMO), para o projeto de SMCs. A metodologia proposta explora o espaço de busca considerando objetivos conflitantes, através de um conjunto de tabelas de subpopulação que representam os objetivos do problema. Juntamente com o AEMO, a metodologia proposta faz uso das propriedades da matriz H_A (London et al. 2007), para realizar uma busca local, auxiliando assim o

processo evolutivo e minimizando o esforço computacional. A metodologia proposta difere dos trabalhos anteriormente publicados na literatura (Bozz et al. 2014; Souza et al. 2005; Coser et al. 2006; Vigliassi et al. 2009; Castro & Müller 2016), pelo fato de fazer uso de uma abordagem puramente multi-objetivo para o problema de alocação de medidores, considerando as restrições de um SMC e seu custo como objetivos a serem otimizados. Para comprovar a eficiência da metodologia proposta, simulações foram realizadas com sistemas testes do IEEE e um sistema real brasileiro.

2 Fundamentação Teórica

2.1 Análise da observabilidade para sistemas de medição SCADA

No contexto da estimação de estado em SEP, um sistema é dito observável se as medidas disponíveis são suficientes para permitir a estimação de todas as variáveis de estado do sistema (as tensões complexas nodais). O modelo de estimação de estado linearizado, ou modelo $P\theta$, geralmente é adotado na análise de observabilidade (Bozz et al. 2014; London et al. 2007; Souza et al. 2005). Daqui em diante, por uma questão de simplicidade, o modelo $P\theta$ será usado, assim como, a matriz Jacobiana do EE por mínimos quadrados ponderados será chamada de matriz H . Essa matriz relaciona as medidas de potência ativa (linhas) com os ângulos de fase de tensão (colunas), que são as variáveis de estado no modelo $P\theta$. Assim, um sistema de n -barras é dito ser algebricamente observável se (London et al. 2007):

$$\text{posto}(H) = (n - 1), \quad (1)$$

onde $(n-1)$ é a dimensão do vetor de estado no modelo $P\theta$ (uma barra é escolhida como referência).

2.2 Redundância em sistemas de medição SCADA

Como citado anteriormente, um SMC é um sistema observável livre de MCs, CCMs e UTRs críticas. Vale lembrar (London et al. 2007): **MC** é a medida que, se removida, torna o sistema não observável; **CCM** é um conjunto de medidas redundantes que, caso uma delas seja removida, as demais se tornam críticas; e uma **UTR crítica** é aquela que, caso seja removida torna o sistema não observável.

Como apresentado em (London et al. 2003), MCs, CCMs e UTRs críticas podem ser facilmente identificadas a partir da matriz H_A , originada da fatoração triangular da matriz H .

Considerando o modelo $P\theta$, a matriz H_A , associada a um sistema observável de n barras, contendo m medidores disponíveis, com $m > n$, possui a estrutura:

$$H_A = \begin{bmatrix} I_{(n-1)} & 0 \\ R & 0 \end{bmatrix}, \quad (2)$$

onde: $I_{(n-1)}$ é uma matriz identidade de dimensão $(n-1) \times (n-1)$; e R é uma submatriz de dimensão $[m-(n-1)] \times (n-1)$. A última coluna da matriz H_A é composta

somente de zeros, pois corresponde à barra de referência angular.

2.3 Projeto de SMC SCADA através da obtenção e análise da matriz H_A

Este trabalho é baseado no método de planejamento de sistemas medição SCADA proposto em (London et al. 2003), que será resumido a seguir.

Quando um sistema de medição já existente não é confiável para efeito de estimação de estado, o método proposto em (London et al. 2003) possibilita o fortalecimento desse sistema, ou aumento da confiabilidade, de duas maneiras: (i) por meio da seleção e instalação de novos medidores em subestações que já possuem UTRs instaladas; e (ii) por meio da seleção e instalação de UTRs candidatas, que consiste na instalação de medidores e UTRs em subestações onde não existem esses equipamentos. A primeira forma é mais vantajosa considerando o custo do sistema, pois não será necessária a instalação de uma nova UTR.

A obtenção de um SMC, através do método proposto em (London et al. 2003), faz uso do processo de obtenção e análise da matriz H_A . A seleção dos medidores e UTRs a serem instalados é feita diretamente através dos fatores triangulares obtidos durante o processo de fatoração da matriz H . A construção da matriz H é feita através de uma lista contendo todos os medidores candidatos a instalação e suas respectivas UTRs.

O método apresentado em (London et al. 2003) pode ser dividido em três fases:

1) Análise e restauração da observabilidade: a primeira etapa é verificar se o sistema de medição existente já é observável, caso contrário, o método vai determinar o local de instalação dos medidores e UTRs, a fim de torná-lo observável. Isso é realizado através da fatoração triangular da matriz H ;

2) Análise e restauração do nível de redundância: o objetivo desta fase é tornar o sistema de medição livre de MCs e CCMs, verificando os elementos não nulos da matriz H_A , obtida na fase anterior;

3) Identificando UTRs críticas e tornando-as redundantes: inicialmente verifica-se a existência de UTRs críticas no sistema de medição resultante da execução das fases 1 e 2. Caso não exista UTR crítica, esse sistema de medição é confiável e a análise se encerra. Caso contrário, o método permitirá determinar onde devem ser instalados medidores e/ou UTRs para tornar as UTRs críticas redundantes.

É importante destacar que o método proposto em (London et al. 2003) não minimiza os custos de investimento.

2.4 Matriz H_A com medidores SCADA e fasoriais

No processo do EE convencional, que não considera UMFs, uma das barras é escolhida como referência angular e seu ângulo de fase de tensão é definido como zero. Considerando que a monitoração

direta dos ângulos de tensão via sistema SCADA convencional não é usual, essa prática é apropriada, uma vez que é irrelevante, para o processo de estimação de estado, o valor absoluto do ângulo de tensão da barra de referência. Em sistemas híbridos, com medidores SCADA e UMFs instalados, essa prática não é adequada, isto porque as medidas de ângulo de tensão, fornecidas pelas UMFs, são obtidas a partir de outro referencial, que é determinado pelo instante de tempo fornecido pela recepção do sinal emitido pelo sistema GPS.

A análise da matriz H_A pode ser estendida para sistemas de medição híbridos, sendo necessário incluir as MFSs na matriz H do modelo $P\theta$. Para isso, são propostas as seguintes aproximações: - as impedâncias de todos os ramos da rede são igualadas a 1. Assim, a parte real do fasor de corrente pode ser aproximada por $real(I_{ij}) = \theta_i - \theta_j$, onde θ_i e θ_j são os ângulos de fase de tensão das barras i e j , respectivamente (London et al. 2009); - cria-se uma barra fictícia, chamada de GPS, para representar a referência de tempo fornecida pelo GPS; e - cada medida de ângulo de fase de tensão é representada por uma medida de fluxo de potência ativa em um ramo fictício que liga a barra onde a medida está instalada e a barra fictícia de GPS. Considerando essas aproximações, as linhas da matriz Jacobiana correspondentes a uma UMF instalada na barra i podem ser escritas da seguinte forma:

$$H_{UMF_i} \begin{bmatrix} \vdots & \vdots & \vdots & \vdots & \vdots \\ \theta_i & \dots & \theta_i & \dots & \theta_j & GPS \\ \vdots & \dots & \vdots & 0 & 0 & -1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ I_{ij} & \left[\begin{array}{ccccc} \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & 0 & -1 & 0 & \end{array} \right] & \vdots \end{bmatrix} \quad (3)$$

A matriz H_A obtida através da fatoração da matriz H contendo medidas SCADA e UMFs terá estrutura semelhante à apresentada na equação (2) (Bozz et al. 2014), porém, ao invés de n colunas, a matriz terá $n+1$ colunas, ou seja, n colunas que representam os ângulos de tensão das n barras do sistema e mais uma (a última) representando a barra fictícia GPS. Dessa forma, a partir da obtenção e análise da matriz H de um sistema híbrido, é possível obter um SMC (Bozz et al. 2014).

2.5 Algoritmos Evolutivos Multi-objetivos

AEMOs são algoritmos de busca estocásticos que utilizam princípios da Teoria da Evolução e estratégias para otimização multi-objetivo (Deb 2001). Eles têm sido utilizados para resolver problemas complexos, com funções objetivo multimodais, não diferenciáveis, entre outras. Da mesma forma que os algoritmos evolutivos tradicionais, os AEMOs buscam soluções ótimas para o problema através da manipulação de um conjunto de soluções candidatas (indivíduos), chamada população. A população inicial é gerada aleatoriamente e deve representar adequadamente o espaço de busca das soluções do problema. A primeira população é avaliada de acordo com a função objetivo desejada e um subconjunto da

população é selecionado. Nesse subconjunto serão aplicados operadores para modificar os indivíduos produzindo uma nova população. O processo de produção de uma população, a partir de uma anterior, é chamado de geração.

A característica fundamental de um AEMO é a estratégia usada para selecionar o subconjunto de soluções ranqueado por mais de uma função objetivo. Uma das estratégias mais utilizadas é o ranking de dominância, utilizado pelo *Non Dominated Sorting Genetic Algorithm II* (NSGAI) (Deb et al. 2002). Ele consiste em dividir o conjunto de soluções em várias frentes de acordo com o grau de dominância de cada solução. No entanto, o NSGA II e outras abordagens baseadas no ranking de dominância podem falhar para problemas de otimização combinatória com três ou mais objetivos. Por outro lado, o AEMO proposto em (Sanches et al. 2014) apresenta desempenho satisfatório para problemas combinatórios com três ou mais objetivos. Esse método utiliza subpopulações distribuídas em tabelas para representar os objetivos do problema. Ao longo do processo evolutivo, cada tabela armazenará as melhores soluções para cada objetivo. Vale destacar que o AEMO proposto em (Sanches et al. 2014) trata do problema de restabelecimento de energia em sistemas de distribuição.

2.6 Formulação do problema

O problema de alocação de medidores para planejamento de SMC tem como objetivos fundamentais: (1) minimizar o custo de aquisição e instalação de medidores SCADA e MFSs e, ao mesmo tempo; (2) instalar uma quantidade de medidas suficiente para tornar o sistema observável e isento de MCs, CCMs e UTRs críticas. Observe que os objetivos (1) e (2) são conflitantes, pois para diminuir o custo deve-se diminuir a quantidade de medidores, mas para alcançar o objetivo (2) deve-se aumentar o número de medidores instalados no sistema. Dessa forma, para aplicar algoritmos evolutivos o problema é usualmente formulado da seguinte forma (Bozz et al. 2014; Souza et al. 2005; Coser et al. 2006; Vigliassi et al. 2009):

$$\text{Min} (C_{met. SCADA} + C_{UTR} + C_{UMFbarra} + C_{UMF ramo}), \quad (4)$$

s.a. observabilidade do sistema, ausência de MCs, CCMs e UTRs críticas, onde $C_{met. SCADA}$ é o custo para adquirir e instalar medidores convencionais, C_{UTR} é o custo para adquirir e instalar UTRs, $C_{UMF barra}$ é o custo para adquirir e instalar UMF de barra, e $C_{UMF ramo}$ é o custo para adquirir e instalar UMF de ramo.

Neste artigo propõe-se uma formulação alternativa, em que os objetivos e as restrições (com exceção da observabilidade) são tratados como objetivos, da seguinte forma:

$$\text{Min} \text{Custo}, N^{MC}, N^{CCM}, N^{UTR_CR}, \quad (5)$$

s.a. observabilidade do sistema, onde $\text{Custo} = C_{met. SCADA} + C_{UTR} + C_{UMFbarra} + C_{UMF ramo}$, N^x é o número

de MCs (para $X=MC$), CCMs (para $X=CCM$) e UTRs críticas (para $X=UTR_CR$) do sistema de medição. Importa destacar que o tratamento de restrições como objetivos a serem minimizados possibilita uma exploração mais ampla do espaço de busca, sem as limitações impostas pelas restrições (Sanches et al. 2014).

3 Metodologia Proposta

A metodologia proposta para planejamento de SMC híbridos, chamada AEMOT+ H_A (Algoritmo Evolutivo Multi-objetivo em Tabelas com matriz H_A), é baseada em subpopulações divididas em tabelas e nas propriedades da matriz H_A para realizar buscas locais por melhores soluções. Esta seção apresenta as principais características do AEMOT+ H_A .

3.1 Codificação

Cada indivíduo (cromossomo) é representado por um vetor, onde cada elemento representa um medidor e sua localização no sistema elétrico. A dimensão do cromossomo corresponde ao máximo de medidores (SCADA e MFS) possíveis de serem instalados no sistema. Os elementos do cromossomo (genes) possuem valores binários, onde 1 são medidores selecionados para instalação e 0 não selecionados.

3.2 Subpopulação de tabelas

O conjunto de tabelas (T_n) do AEMOT+ H_A é o seguinte: T_1 – armazena soluções observáveis com baixo custo; T_2 – soluções observáveis e livres de MCs de baixo custo; T_3 – soluções observáveis, livres de MCs e de CCMs de baixo custo; T_4 – armazena SMC (sistemas observáveis e livres de MCs, CCM e UTRs críticas) de baixo custo; T_5 – soluções com baixo número de MCs e CCMs; T_6 – soluções observáveis e com UTRs instaladas em barras com grande quantidade de ramos adjacentes; T_7 – soluções observáveis e com medidores de injeção de potência instalados em barras com grande quantidade de ramos adjacentes; T_8 – soluções observáveis e com alto valor de $m_{inj} - m_{flu}$, sendo m_{inj} e m_{flu} a quantidade de medidores de injeção e de fluxo instalados no sistema respectivamente.

As tabelas T_{1-4} representam diretamente os objetivos do problema, de acordo com a equação (5), e as tabelas T_{5-8} fornecem soluções com características importantes na resolução do problema, como, por exemplo, a instalação de medidores em UTRs em barras com grande quantidade de ramos adjacentes.

Os parâmetros do AEMOT+ H_A são: $G_{inicial}$ – tamanho da população inicial; S_{Ti} – quantidade de indivíduos armazenados em cada tabela T_i , com $i=1, \dots, 8$; e G_{max} – número máximo de indivíduos gerados pelo AEMOT+ H_A (critério de parada do algoritmo).

Inicialmente, são geradas aleatoriamente $G_{inicial}$ soluções candidatas e o processo de avaliação de

cada solução é realizado em dois passos: (i) através das propriedades da matriz H_A (London et al. 2007) verifica-se a observabilidade e os objetivos do problema (ausência de MC, CCM e UTR crítica); e (ii) se a solução é observável, calcula-se o custo, de acordo com a equação (5) e os valores da Tabela 1, onde N_d é o número de ramos adjacentes à barra com UMF.

Tabela 1. Custo de equipamentos (unidades monetárias – UMs)

SCADA		UMF	
Medidor	UTR	De ramo	De barra
4,5	100	135	$130 + 5 \times N_d$

Para uma nova solução gerada G_n ser armazenada nas tabelas T_{1-8} , as seguintes condições devem ser atendidas: (i) se a tabela T_{1-8} não estiver cheia, G_n deve atender ao critério de seleção da tabela (ser observável e não possuir MC alguma, para a tabela T_2 , por exemplo); (ii) se a tabela T_{1-4} estiver cheia, além de atender ao critério de seleção dessa tabela, G_n deve apresentar custo menor que a solução mais cara já armazenada nessa tabela, substituindo-a; e (iii) se a tabela T_{5-8} estiver cheia, além de atender ao critério de seleção dessa tabela, G_n deve ser melhor que a pior solução já armazenada na tabela, de acordo com o critério de seleção dessa tabela.

O processo de geração de novas soluções candidatas ocorre selecionando, aleatoriamente, uma tabela e um indivíduo dessa tabela, e aplicando a ele o operador de mutação de acordo com uma determinada taxa. A mutação é realizada alterando o valor dos genes (de 0 para 1 e vice-versa). A cada geração, somente um indivíduo é gerado, podendo ingressar em várias tabelas, conforme estabelecido no parágrafo anterior.

3.3 Busca local usando a matriz H_A

O AEMOT+ H_A utiliza a matriz H_A para: (i) avaliar as soluções candidatas, verificando a observabilidade e a quantidade de MCs, CCMs e UTRs críticas de cada sistema (London et al. 2003); e (ii) selecionar medidores e/ou UTRs para obtenção de um SMC. Como será demonstrada na seção de testes, a busca local acelera e torna o processo evolutivo mais eficiente.

3.4 Flexibilidade na escolha dos objetivos

Após a execução do AEMOT+ H_A , analisando isoladamente as melhores soluções armazenadas nas tabelas T_{1-4} , tornam-se disponíveis os seguintes tipos de sistemas de medição: (1) Observáveis de menor custo; (2) Observáveis e livres de MCs de menor custo; (3) Observáveis e livres de MCs e CCMs de menor custo; e (4) Observáveis e livres de MCs, CCMs e UTRs críticas (SMCs) de menor custo. Essa característica é muito importante para empresas com restrições de orçamento, visto que podem realizar o planejamento de seus sistemas instalando somente os medidores necessários para o cumprimento de suas restrições e obtenção de um sistema de medição do

tipo (1)-(4). Fazendo uso desse tipo de análise, ou seja, uma análise isolada de cada uma das tabelas, a metodologia possibilita a seleção da melhor solução obtida para um determinado objetivo do problema. Entretanto, fazendo uso das soluções armazenadas em todas as tabelas de subpopulação é possível a obtenção de soluções não dominadas, ou seja, o conjunto de Pareto-ótimo. Neste artigo essa possibilidade de análise das soluções obtidas não será explorada. Vale destacar também que o AEMOT+ H_A pode ser utilizado para projetar um novo SMC ou para aprimorar um sistema de medição já existente.

4 Testes e Análise dos Resultados

O AEMOT+ H_A foi implementado utilizando a linguagem de programação C++ e os resultados foram obtidos utilizando um computador com processador Core i5 2.67 GHz, 6 GB de memória RAM e sistema operacional Linux Ubuntu 14.04. Após uma análise detalhada, os melhores parâmetros encontrados foram: $G_{inicial} = 10.000$; $T_i = 20$, com $i=1,...,8$; $G_{max} = 50.000$; e taxa de mutação: 10%.

As figuras a seguir utilizam a seguinte simbologia: ▼ medidor de injeção de potência; ● medidor de fluxo de potência; ▼ medidor de ângulo de tensão; ● medidor de magnitude de corrente em ramo; e --- UTR.

4.1 Planejamento de um SMC SCADA

As Figuras 1 e 2 apresentam, respectivamente, os SMCs obtidos para o sistema de 30 barras do IEEE e um sistema brasileiro de 61 barras. Nas figuras nota-se claramente o agrupamento de medidores em algumas barras do sistema a fim de diminuir o custo de instalação de UTRs.




Figura 1. SMC obtido para o sistema de 30 barras do IEEE

A Tabela 2 apresenta as melhores soluções (SMCs de menores custos) encontradas pelo AEMOT+ H_A para os sistemas IEEE 14, 30, 57 e 118 barras, utilizando apenas medidores SCADA. A Tabela 3 compara as melhores soluções encontradas pelo AEMOT+ H_A com outras três metodologias, para o sistema de 30 barras do IEEE. De acordo com essa tabela, o AEMOT+ H_A chegou ao melhor resultado.

Os resultados apresentados nas Tabelas 2 e 3 não consideram a presença de barras de injeção nula.




Figura 2. SMC obtido para um sistema de 61 barras real brasileiro

Tabela 2. Resultados para os sistemas do IEEE

Sistemas IEEE				
Sistema	Medidas		UTRs	Custo (UM)
	Injeção	Fluxo		
14	8	8	9	972,00
30	19	16	21	2.257,50
57	33	33	33	3.597,00
118	67	356	68	7.452,50

Tabela 3. Comparação entre metodologias para o sistema de 30 barras do IEEE

Metodologias	Custo (UM)
Proposto em (Souza et al. 2005)	2.980,00
Proposto em (Vigliassi et al. 2009)	2.338,50
Proposto em (Bozz et al. 2014)	2.262,00
AEMOT+ H_A	2.257,50

A fim de destacar a importância do processo de busca local usando a matriz H_A , a Figura 3 mostra o custo do melhor indivíduo durante a convergência do algoritmo, com e sem a busca local. Esse teste foi realizado com o sistema de 57 barras do IEEE, considerando apenas medidores SCADA. A busca local contribui significativamente para convergência.




Figura 3. Diferenças no processo evolutivo com a busca local

4.1 Planejamento de SMC híbridos

Neste teste, o AEMOT+ H_A foi aplicado para fortalecer o sistema de medição de 14 barras do IEEE, não observável, que já possui as seguintes MFS: ângulos de tensão nas barras 2, 3 e 8, e magnitude de corrente da barra 3 para barra 4. Para demonstrar a flexibilidade do AEMOT+ H_A , ele foi restrito a instalar apenas medidas SCADA e a solução obtida é apresentada na Figura 4. O custo total para aquisição e instalação dos medidores SCADA foi de 758,50MUs.




Figura 4. SMC híbrido obtido para o sistema de 14 barras do IEEE.

5 Conclusões

Este artigo apresenta uma formulação multi-objetivo para o problema de planejamento de sistemas de medição confiáveis, para efeito de estimação de estado. Em seguida, combina um AEMO, com subpopulações em tabelas, e as propriedades da matriz H_A , para desenvolver uma metodologia para tratamento daquele problema. A metodologia proposta, chamada de AEMOT+ H_A , explora o espaço de busca das soluções através de subpopulações divididas em tabelas, com características distintas, e usa a matriz H_A para realizar uma busca local, melhorando o processo evolutivo. O AEMOT+ H_A possibilita a obtenção de SMCs possuindo apenas medidas SCADA, apenas MFSs ou ambos os tipos de medidas. O AEMOT+ H_A difere dos demais trabalhos publicados anteriormente na literatura (Bozz et al. 2014; Souza et al. 2005; Coser et al. 2006; Vigliassi et al. 2009; Saha Roy et al. 2012; Castro & Müller 2016), pelo fato de ser baseada em subpopulações divididas em tabelas e nas propriedades da matriz H_A . Resultados de diversas simulações considerando os sistemas de 14, 30, 57 e 118 barras do IEEE, bem como um sistema brasileiro de 62 barras, comprovam a eficiência do AEMOT+ H_A . Resultados obtidos pelo AEMOT+ H_A , alguns apresentados neste trabalho, foram melhores que os obtidos por outras três metodologias já existentes.

Referências Bibliográficas

Bozz, A.A.C., Vigliassi, M.P. & London, J.B.A., 2014. Metering system planning for state estimation via evolutionary algorithm and H_A matrix considering SCADA and PMU

measurements. In *2014 IEEE PES General Meeting | Conference & Exposition*. IEEE, pp. 1–5.

Castro, C.A. & Müller, H.H., 2016. Genetic algorithm-based phasor measurement unit placement method considering observability and security criteria. *IET Generation, Transmission & Distribution*, 10(1), pp.270–280. Available at: <http://digital-library.theiet.org/content/journals/10.1049/iet-gtd.2015.1005>.

Coser, J., Costa, A.S. & Rolim, J.G., 2006. Metering Scheme Optimization With Emphasis on Ensuring Bad-Data Processing Capability. *IEEE Transactions on Power Systems*, 21(4), pp.1903–1911.

Deb, K. et al., 2002. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2), pp.182–197.

Deb, K., 2001. *Multi Objective Optimization Using Evolutionary Algorithms* 1st ed., New York: Wiley.

London, J.B.A. et al., 2009. Redundancy and observability analysis of conventional and PMU measurements. *IEEE Transactions on Power Systems*, 24(3), pp.1629–1630.

London, J.B.A., Alberto, L.F.C. & Bretas, N.G., 2007. Analysis of measurement-set qualitative characteristics for state-estimation purposes. *IET Generation, Transmission & Distribution*, 1(1), p.39.

London, J.B.A., Brito, G.L.R. & Bretas, N.G., 2003. Method for meter and RTU placement for state estimation purposes. *2003 IEEE Bologna PowerTech - Conference Proceedings*, 1, pp.146–153.

Manousakis, N.M., Korres, G.N. & Georgilakis, P.S., 2012. Taxonomy of PMU placement methodologies. *IEEE Transactions on Power Systems*, 27(2), pp.1070–1077.

Saha Roy, B.K., Sinha, A.K. & Pradhan, A.K., 2012. An optimal PMU placement technique for power system observability. *International Journal of Electrical Power and Energy Systems*, 42(1), pp.71–77.

Sanches, D.S., London Junior, J.B.A. & Delbem, A.C.B., 2014. Multi-Objective Evolutionary Algorithm for single and multiple fault service restoration in large-scale distribution systems. *Electric Power Systems Research*, 110, pp.144–153.

Souza, J.C.S. et al., 2005. Optimal Metering Systems for Monitoring Power Networks Under Multiple Topological Scenarios. *IEEE Transactions on Power Systems*, 20(4), pp.1700–1708.

Vigliassi, M.P. et al., 2009. Metering system planning for state estimation via evolutionary algorithm and H matrix. *2009 IEEE Bucharest PowerTech*, pp.1–5.