

Abstract— This paper presents a multi-objective evolutionary approach for solving the problem of allocation of conventional (SCADA) and synchronized phasor measurements for power system state estimation. Solutions to the problem involve the conflicting objectives of investment cost and performance requirements. The approach combines a Multi-objective Evolutionary Algorithm, based on subpopulation tables, with the properties of the so-called H_A matrix, obtained from the triangular factorization of the Jacobian matrix to find compromise solutions that minimize investment costs and maximize performance requirements of measurement systems for state estimation. The proposed approach enables the design of four types of measurement systems in only one execution and can be applied for allocation of only SCADA measurements, only synchronized phasor measurements or both types of measurements. To validate the efficiency of the proposed approach, the computational simulations were conducted in the IEEE systems of 14, 30, 57, 118-bus and 300-bus and a real Brazilian system. Results were compared with those presented in the literature.

Keywords— Power system state estimation, measurement placement, synchronized phasor measurements, combinatorial optimization, multi-objective evolutionary algorithm.

Resumo— Este artigo apresenta uma abordagem evolutiva multiobjetivo para tratamento do problema de alocação de medidas convencionais (SCADA) e fasoriais sincronizadas para efeito de estimação de estado em sistemas elétricos de potência. A abordagem proposta fundamenta-se no Algoritmo Evolutivo Multiobjetivo baseado em tabelas de subpopulações, juntamente com as propriedades da matriz H_A , obtida a partir da fatoração triangular da matriz Jacobiana, para encontrar soluções de compromisso que minimizam os custos de investimentos e maximizam os requisitos de performance de sistemas de medição. A abordagem permite a geração de quatro tipos de sistemas de medição em apenas uma execução. Pode ser aplicada para alocação exclusiva de medidas convencionais, de medidas fasoriais ou dos dois tipos de medidas. Para validar a eficiência da abordagem proposta, simulações computacionais foram realizadas nos sistemas de 14, 30, 57, 118 e 300 barras do IEEE e num sistema real brasileiro, e os resultados comparados com trabalhos já apresentados na literatura.

Palavras-chave— Estimação de estado em sistemas elétricos, alocação de medidores, medidores fasoriais sincronizados, otimização combinatória, Algoritmo Evolutivo Multiobjetivo.

1 Introdução

O Estimador de Estado (EE) estático é uma importante ferramenta utilizada na análise da segurança operacional em tempo real de Sistemas Elétricos de Potência (SEP). Uma de suas principais funções é fornecer um modelo completo e confiável para aplicações em sistemas de energia, análise de contingência e o cálculo de preço em função da previsão de carga (Castillo et al. 2011).

Independente do EE utilizado, a confiabilidade do processo de estimação de estado depende do sistema de medidores disponível, isto é, da distribuição topológica dos medidores e das Unidades Terminais Remotas (UTRs) (London Jr. et al. 2007; Coser et al. 2006). De acordo com a literatura de estimação de estado, um Sistema de Medição Confiável (SMC) deve garantir os seguintes requisitos de performance: (i) observabilidade durante condições normais de operação e na presença de situações de contingência causando a perda de uma ou duas medidas ou, até mesmo, a perda de uma UTR; e (ii) livre de Medidas Críticas (MCs), Conjuntos Críticos de Medidas (CCMs) e UTRs críticas (Coser et al. 2006; Bozz et al. 2014; Vigliassi et al. 2009; Souza et al. 2005; London Jr. et al. 2007).

Pesquisadores têm investigado diversos métodos para melhorar a precisão e confiabilidade do processo de estimação de estado através de Medidores Fasoriais Sincronizados (MFS), obtidos pelas Unidades de Medição Fasoriais (UMF) (Phadke 2002; London Jr. et al. 2009). A UMF instalada em uma barra possibilita a medição do fasor de tensão da barra onde ela está localizada e dos fasores de corrente de algumas ou todas as linhas adjacentes conec-

tadas àquela barra. Para considerar medidores convencionais SCADA e MFSs foram desenvolvidos os EEs híbridos (Korres & Manousakis 2011).

O planejamento de SMCs, sem considerar o custo de investimento para a instalação de medidores, UTRs e UMFs, é um problema de otimização combinatorial que requer a investigação de muitas soluções (London Jr. et al. 2003), sendo tratado como um problema NP-completo (Brueni & Heath 2005). Quando o custo do investimento é incluído o problema torna-se ainda mais complexo, devido aos objetivos conflitantes de minimizar o custo e maximizar os requisitos de performance (London Jr. et al. 2003; Manousakis et al. 2012).

Meta-heurísticas têm sido empregadas para resolver o problema, porém a maioria delas utiliza fatores de ponderação para transformar o problema em mono-objetivo (Castro & Müller 2016; Gamm et al. 2008; Jamuna & Swarup 2011; Karegar & Dalali 2016). Segundo (Deb 2011), essa estratégia possui várias desvantagens. O método proposto em (Milosevic & Begovic 2003) utiliza o algoritmo *Non-dominated Sorting Genetic Algorithm* (NSGA) para alocação ótima de UMFs e conseguiu bons resultados. No entanto, esse método não considera o planejamento de SMCs utilizando medidas SCADA e MFSs.

Métodos numéricos também têm sido desenvolvidos, porém não tratam o problema de maneira completa, abrangendo o custo de investimento e todos os requisitos de performance atendidos por um SMC (Abbasy & Ismail 2009; Pal et al. 2017).

Este artigo propõe uma formulação multiobjetivo e um método para resolver o problema de alocação de medidores para projeto de SMCs, consideran-

do o custo de investimento e todos os requisitos de performance (observabilidade, ausência de MCs, CCMs, UTR e UMF críticas). Baseia-se no método proposto em (Vigliassi et al. 2016), que combina um Algoritmo Evolutivo Multiobjetivo (AEMO), baseado em tabelas de subpopulações, com as propriedades da matrix H_A (London Jr. et al. 2007). Ele permite considerar a existência de somente medidas convencionais SCADA, somente MFSs ou a existência de ambas. Através do armazenamento das soluções candidatas em tabelas de subpopulações é possível realizar o tratamento dos requisitos de performance dos SEP e a exploração do espaço de busca, enquanto as propriedades da matriz H_A é responsável para minimizar o esforço computacional através de uma busca local.

Este trabalho é a continuação dos estudos de (Vigliassi et al. 2016) e difere dos anteriores da literatura (Coser et al. 2006; Bozz et al. 2014; Vigliassi et al. 2009; Souza et al. 2005; Milosevic & Begovic 2003; Abbasy & Ismail 2009; Rocha et al. 2013) porque propõe uma nova formulação para o problema. As contribuições mais importantes da nova formulação e método propostos são: (i) a estratégia de selecionar bons indivíduos (soluções) e armazena-los em subpopulações de acordo com cada objetivo; (ii) possibilitar o projeto de sistemas de medição com grande número de barras, como o IEEE de 118 e 300 barras; (iii) utilizar os conceitos da Fronteira de Pareto para tratar os objetivos conflitantes; (iv) capaz de gerar, em uma única execução, quatro tipos de sistemas de medição: **Tipo 1:** Sistema de medição convencional ou híbrido observável; **Tipo 2:** Sistema de medição convencional ou híbrido observável, livre de MCs; **Tipo 3:** Sistema de medição convencional ou híbrido observável, livre de MCs e CCMs; e, **Tipo 4:** SMC convencional ou híbrido.

2 Fundamentação Teórica

Os problemas de otimização multiobjetivo possuem, normalmente, um conjunto de funções objetivo a serem otimizadas e também restrições a serem respeitadas (Deb 2011). Os AEMOs têm sido utilizados para resolver esses problemas complexos e buscam soluções ótimas para o problema através da manipulação de um conjunto de soluções candidatas (indivíduos), chamada população. Normalmente, a primeira população é gerada aleatoriamente. Em seguida, um subconjunto dessa população é selecionado, mapeando regiões promissoras do espaço de busca (Sanches et al. 2014), e os operadores genéticos são aplicados a ele, dando origem a uma nova população.

A literatura sobre AEMOs mostra que estratégias adequadas para selecionar subpopulações podem alcançar a solução ótima ou quase ótima após um certo número de iterações (Deb 2011). Um dos algoritmos mais promissores para lidar com até dois objetivos é o *Non-dominated Sorting Genetic Algorithm – II* (NSGA-II), porém, abordagens baseadas no ranking de dominância podem falhar para pro-

blemas de otimização combinatória com três ou mais objetivos. O AEMO proposto em (Sanches et al. 2014), chamado de Algoritmo Evolutivo Multiobjetivo em Tabelas (AEMT), apresenta desempenho satisfatório para problemas combinatórios com três ou mais objetivos. O método armazena as potenciais soluções em subpopulações (tabelas) de acordo com cada objetivo do problema. A seleção do indivíduo para reproduzir e gerar uma nova solução é realizada em duas etapas: (i) seleção aleatória da(s) tabela(s); e (ii) seleção aleatória do(s) indivíduo(s) pertencente à tabela (Camillo et al. 2016).

Ao se tratar da análise de observabilidade para estimação de estado, um SEP é dito observável se as medidas disponíveis forem suficientes para permitir a estimação de todas as variáveis de estado do sistema (as tensões complexas nodais). O modelo de estimação de estado linearizado, também conhecido como $P\theta$, é geralmente utilizado para análise de observabilidade (Bozz et al. 2014; London Jr. et al. 2007; Souza et al. 2005). A seguir, 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 com n -barras que possua apenas medidas SCADA é dito ser algebricamente observável se (London Jr. et al. 2007):

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

onde $(n-1)$ é a dimensão do vetor de estado no modelo $P\theta$, pois uma barra 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. Entretanto, no problema de estimação de estado considerando somente medidas fasoriais, ou medidas convencionais SCADA e fasoriais, a escolha do ângulo de fase de tensão da barra de referência não será mais uma decisão arbitrária (London Jr. et al. 2009). Quando há pelo menos uma medição do ângulo da fase de tensão, o ângulo de fase da tensão da barra de referência é fornecido por essa medida, ou seja, em relação à referência de tempo fornecida pelo GPS (London Jr. et al. 2009; Korres & Manousakis 2011).

Com base na definição de observabilidade algébrica supracitada, em (London Jr. et al. 2007) foi desenvolvido um método que possibilita análise de observabilidade considerando apenas medidas SCADA, através da análise da matriz H_A , que é obtida a partir da fatoração triangular da matriz H .

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

$$H_A = \left[\begin{array}{c|c} I_{(n-1)} & 0 \\ \hline R & 0 \end{array} \right], \quad (2)$$

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.

A análise de observabilidade através da matriz H_A pode ser estendida para sistemas contendo apenas medidas fasoriais, ou medidas SCADA e fasoriais (sistemas de medição híbridos). Para isso, inicialmente é necessária a inclusão de medidas fasoriais na matriz H do modelo $P\theta$, conforme proposto em (Zhu & Abur 2007). Em seguida, essa matriz é fatorada para obtenção da matriz H_A (London Jr. et al. 2009).

Métodos que combinam a matriz H_A com Algoritmos Evolutivos convencionais foram desenvolvidos para planejamento de SMCs (Bozz et al. 2014; Vigliassi et al. 2017; Vigliassi et al. 2009). . Isto em razão de essa matriz permitir: (i) análise e restauração de observabilidade (London Jr. et al. 2003); (ii) identificação de MCs e CCMs (London Jr. et al. 2007); e (iii) planejamento de um novo SMC, bem como avaliar um sistema de medição existente e, se necessário, indicar onde os medidores (SCADA e/ou MFSs) e as UTRs devem ser instalados para obter um SMC. Este artigo propõe uma nova estratégia para a combinação dessa matriz com um AEMO baseado em tabelas de subpopulação, bem como uma formulação multiobjetivo para o problema de planejamento de sistemas de medição.

3 Formulação do Problema

O problema de alocação de medidores para planejamento de SMCs tem dois objetivos conflitantes: (1) minimizar o custo do investimento (ou seja, o custo de compra e instalação de medidores, UTRs e UMFs); e (2) maximizar o número de medidores, UTRs e UMFs a serem instaladas para atender aos requisitos de performance relacionados à observabilidade e redundância. No entanto, esse problema é formulado normalmente como mono-objetivo (minimizar o custo), sujeito às restrições de performance (observabilidade e redundância) (Coser et al. 2006; Bozz et al. 2014; Vigliassi et al. 2009; Souza et al. 2005). Essas metodologias convencionais, baseadas em Algoritmos Evolutivos, utilizam penalidades para tratar as restrições (Coser et al. 2006; Bozz et al. 2014; Vigliassi et al. 2009; Souza et al. 2005; Castro & Müller 2016; Saha Roy et al. 2012; Do Coutto Filho et al. 2005).

Este artigo propõe a seguinte formulação multi-objetivo:

$$\begin{aligned} \text{Min } (\text{Custo}(M), 1/IP(M)) \\ \text{s. a. Rank } H(M) = (n - 1), \end{aligned} \quad (3)$$

onde:

- M é um vetor em que cada elemento é associado a um medidor e sua UTR ou UMF correspondente e sua localização no sistema de medição. A dimensão de M corresponde ao número máximo de medidores (SCADA e MFS) possível de ser instalado no siste-

ma. Cada elemento de M pode assumir valores binários, sendo igual a 1 (um) para medidor selecionado para instalação e 0 (zero) para medidor não selecionado. Portanto, os elementos não nulos de M definem um sistema de medição;

$$-\text{Custo}(M) = (C_{med\ SCADA}(M) + C_{UTR}(M) + C_{UMF\ barra}(M) + C_{UMF\ ramo}(M)),$$

onde $C_{med\ SCADA}(M)$ é o custo de aquisição e instalação de medidores convencionais SCADA correspondentes a elementos não nulos de M ; $C_{UTR}(M)$ é o custo de aquisição e instalação de UTRs correspondentes a elementos não zero de M ; $C_{UMF\ barra}(M)$ é o custo de aquisição e instalação de UMFs associadas aos elementos não nulo de M , com canais de comunicação suficientes para fornecer a tensão fasorial na barra instalada e correntes fasoriais em todos os ramos adjacentes àquela barra; $C_{UMF\ ramo}(M)$ é o custo de aquisição e instalação das UMFs associadas aos elementos não nulo de M com canais de comunicação suficientes para fornecer a tensão fasorial na barra em que foi instalada e o fasor de corrente de apenas um dos ramos adjacentes àquela barra;

- $H(M)$ é a matriz Jacobiana do modelo $P\theta$ associada aos elementos não nulos de M ;

- IP é o Índice de Performance relacionado aos requisitos de performance (observabilidade e ausência de MCs, CCMs, UTRs críticas e UMFs críticas) do sistema de medição definido por M , que é calculado pelo pseudocódigo apresentado no Algoritmo 1, onde N_M^X é o número total de: Medidas Críticas (para $X=MCs$), medidas convencionais SCADA e MFSs (para $X=Medidas$), CCMs (para $X=CCMs$), medidas pertencentes a CCMs (para $X=Med_CCMs$), UMFs (para $X=UMFs$), UTRs críticas (para $X=UTRs_Cr$), UTRs (para $X=UTRs$) e UMFs críticas (para $X=UMFs_Cr$) no sistema de medição associado aos elementos não nulos de M .

Algoritmo 1 – Pseudocódigo para cálculo do IP

Índice de Performance ()

$IP \leftarrow 20$

If ($N_M^{MCs} > 0$)

$$IP \leftarrow IP - (6 * \frac{N_M^{MCs}}{N_M^{Medidas}})$$

If ($N_M^{CCMs} > 0$)

$$IP \leftarrow IP - (5 * \frac{N_M^{Med_CCMs}}{N_M^{Medidas}})$$

If ($N_M^{UMFs} = 0$) and ($N_M^{UTRs_Cr} > 0$)

$$IP \leftarrow IP - (4 * \frac{N_M^{UTRs_Cr}}{N_M^{UTRs}})$$

If ($N_M^{SCADA} = 0$) and ($N_M^{UMFs_Cr} > 0$)

$$IP \leftarrow IP - (4 * \frac{N_M^{UMFs_Cr}}{N_M^{UMFs}})$$

If ($N_M^{SCADA} > 0$) and ($N_M^{UMFs} > 0$)

If ($N_M^{UTRs_Cr} > 0$)

$$IP \leftarrow IP - (2 * \frac{N_M^{UTRs_Cr}}{N_M^{UTRs}})$$

If ($N_M^{UMFs_Cr} > 0$)

$$IP \leftarrow IP - (2 * \frac{N_M^{UMFs_Cr}}{N_M^{UMFs}})$$

O IP aumenta de acordo com a confiabilidade do sistema de medição, ou seja, um sistema de medição tipo 1 (observável) tem valores pequenos de IP , enquanto os sistemas tipo 4 (SMCs) têm $IP=20$. Importa destacar que o tratamento dos requisitos de performance como objetivos a serem minimizados, permite melhor exploração do espaço de soluções (Camillo et al. 2016).

4 Metodologia Proposta

O planejamento de SMC deve determinar o número, tipo e localização dos medidores, UTRs e UMFs para obter um sistema de medição que atenda aos requisitos de performance. O ideal seria que os sistemas de medição fossem altamente redundantes, porém existem as restrições financeiras a serem atendidas. Portanto, para resolver esse problema é necessário estabelecer um *trade-off* entre os requisitos de performance e o custo do sistema de medição. O método proposto combina o Algoritmo Evolutivo Multiobjetivo em Tabelas com a matriz H_A . Como será detalhado na sequência, a matriz H_A é utilizada para analisar os sistemas e instalar medidores a fim de aumentar a redundância. O Algoritmo Evolutivo Multiobjetivo é responsável por fazer o *trade-off* entre os requisitos de performance e o custo do sistema de medição.

Os principais aspectos do método proposto são:

- **Cromossomo:** cada cromossomo (ou indivíduo) é representado por um vetor binário M , definido anteriormente;
- **Tabelas:** diferente de (Vigliassi et al. 2016), o método proposto utiliza apenas quatro tabelas: T_1 – armazena soluções (sistemas de medição Tipo 1) com baixo custo; T_2 – armazena soluções de SMCs com baixo custo; T_3 – armazena soluções observáveis com maiores valores de IP ; T_4 – armazena soluções observáveis não dominadas (de acordo com os dois objetivos conflitantes apresentados na equação 3);
- **Parâmetros:** os parâmetros do método proposto são: $G_{inicial}$ – tamanho da população inicial; S_{T_i} – quantidade de soluções armazenadas em cada tabela T_i , com $i = 1, \dots, 4$; e G_{max} – o máximo número de indivíduos gerados pelo método proposto. Neste artigo, G_{max} é também utilizado como critério de parada do algoritmo;
- **Inicialização:** a população inicial $G_{inicial}$ de soluções candidatas é gerada randomicamente;
- **Processo evolutivo:** o processo de avaliação de cada solução candidata gerada (ou indivíduo) é realizado em duas etapas: Etapa 1 – as soluções candidatas são analisadas pelo método da matriz H_A (London Jr. et al. 2007; London Jr. et al. 2003) e verificadas quanto aos requisitos de performance; e Etapa 2 – cálculo do custo do sistema de medição de acordo com a equação (3). O custo da compra e instalação de medidores (SCADA e MFSs), UTRs e UMFs estão apresentados Tabela 1, onde N_d é o número de

ramos adjacentes à barra com a UMF instalada (Bozz et al. 2014; Coser et al. 2006; Vigliassi et al. 2017).

- **Armazenamento de soluções:** cada tabela T_i recebe os novos indivíduos avaliados de acordo com os seu critério de armazenamento. Caso a tabela já contenha o número máximo S_{T_i} e o novo indivíduo for melhor que o pior armazenado nessa tabela, ele o substituirá. Por exemplo, quando T_1 estiver cheia, receberá apenas soluções observáveis (condição de armazenamento de T_1) com um custo menor do que a solução observável mais cara já armazenada em T_1 ;

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

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

- **Seleção e reprodução usando mutação:** a seleção é realizada em duas etapas: Etapa 1: uma tabela T_i é escolhida aleatoriamente; e Etapa 2: um indivíduo é selecionado para aplicar a mutação (Deb 2011). Após a aplicação da mutação, a solução é avaliada de acordo com o processo apresentado anteriormente;

- **Busca local usando a matriz H_A :** a busca local é realizada através da matriz H_A para melhorar o processo evolutivo. Após a avaliação de cada nova solução candidata gerada, o método proposto em (London Jr. et al. 2003) é aplicado e são geradas quatro novas soluções candidatas: 1ª – um sistema de medição observável (Tipo 1); 2ª – um sistema observável e livre de MCs (Tipo 2); 3ª – um sistema observável e livre de MCs e CCMs (Tipo 3); e 4ª – um SMC (Tipo 4);

- **Fronteira de Pareto:** a Fronteira de Pareto é formada pelos indivíduos não dominados considerando os objetivos conflitantes da equação (3). Essas soluções são armazenadas em T_4 e representam sistemas Tipo 1, 2, 3 e 4 com custo mínimo.

O fluxograma da Figura 1 ilustra o método proposto.

5 Testes e Análise dos Resultados

O método proposto 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. Os parâmetros utilizados nas simulações foram: $G_{inicial} = 10.000$; $T_i = 20$, com $i=1, \dots, 4$; $G_{max} = 10.000$; e taxa de mutação: 10%.

O método proposto pode ser usado para planejar novos SMCs contendo medições SCADA e/ou MFSs, bem como avaliar um sistema de medição existente e, se necessário, indicar onde os medidores (SCADA e/ou MFS) devem ser instalados para obter um SMC.

A Tabela 2 apresenta os resultados para os SMCs do IEEE e de um sistema brasileiro de 61 barras. Os resultados dos sistemas IEEE de 14, 30 e 57 barras e o do sistema brasileiro de 61 barras são semelhantes aos publicados em (Vigliassi et al.

2016), porém o método proposto é mais eficiente para os sistemas maiores, de 118 e 300 barras.




Figura 1. Fluxograma do método proposto.

Tabela 2. Resultados para SMCs.

Sistemas IEEE				
Sistema	Medidas		UTRs	Custo (UM)
	Injeção	Fluxo		
IEEE 14	8	8	9	972,00
IEEE 30	19	16	21	2.257,50
IEEE 57	33	33	33	3.597,00
Bras. 61	46	38	46	4.914,00
IEEE 118	67	75	70	7.639,00
IEEE 300	218	289	224	24.681,50

A Tabela 3 mostra os custos de investimento dos melhores SMCs IEEE, considerando somente medidores convencionais SCADA, para vários métodos. Vale destacar que o método proposto apresenta melhores resultados para sistemas com grande número de barras.

Tabela 3. Comparação entre métodos – Sistemas IEEE SCADA.

Sistemas	Metodologias	Custo (UM)
118 barras	(Vigliassi et al. 2009)	7.927,00
	(Rocha et al. 2013)	7.684,00
	(Vigliassi et al. 2017)	7.683,00
	Método proposto	7.639,00
300 barras	(Vigliassi et al. 2017)	24.786,00
	Método proposto	24.668,00

O método proposto necessita somente de uma execução para planejar os quatro tipos de sistemas de medição, delimitando assim, a Fronteira de Pareto.

Para demonstrar a flexibilidade do método proposto e o aumento de redundância, a Figura 2 apresenta a topologia gerada a partir de um sistema IEEE

de 30 barras híbrido (medidores SCADA e fasoriais) e Tipo 1 (observável). Nesse teste, o método proposto foi aplicado para avaliar este sistema de medição e, se necessário, indicar onde os medidores SCADA devem ser instalados para obter um SMC híbrido. Os medidores previamente instalados estão destacados na cor azul e os novos propostos pelo método, na cor verde.

A Figura 2 mostra uma característica relevante do método proposto, que é o agrupamento de medidores em UTRs, que incrementa o IP e minimiza o custo do sistema de medição.

A Figura 3 apresenta as Fronteiras de Pareto geradas pelo método proposto para os sistemas do IEEE de 14, 30, 57, 118 e 300 barras e para o sistema brasileiro de 61 barras.




Figura 2. SMC IEEE de 30 barras híbrido proposto a partir de um sistema Tipo 1. Medidores: - fasor de tensão; - fasor de corrente; - injeção de potência ativa e reativa; - fluxo de potência ativa e reativa; - UTR; e - UMF.

6 Conclusões

Este artigo apresentou uma nova formulação multiobjetivo e um método para resolver o problema de projeto de SMCs. O método proposto explora o espaço de busca de soluções através de um AEMO baseado em tabelas de subpopulação e usa as propriedades da matriz H_A .

Essa nova formulação utiliza os conceitos de (Vigliassi et al. 2016), porém difere desse e de outros da literatura (Bozz et al. 2014; Vigliassi et al. 2009; Saha Roy et al. 2012; Castro & Müller 2016; Souza et al. 2005; Coser et al. 2006), pois utiliza o conceito da Fronteira de Pareto para calcular o Índice de Performance dos sistemas, além de possibilitar apresentar, em uma única execução do algoritmo, o projeto de quatro tipos de sistemas de medição. Esse índice representa o grau de redundância dos sistemas em relação aos requisitos de performance: observabilidade




Figura 3. Fronteiras de Pareto (—). Os pontos destacados em vermelho são os sistemas Tipo 1, 2, 3 e 4 com menor custo. a Fronteira de Pareto para o sistema IEEE 14 barras. b Fronteira de Pareto para o sistema IEEE 30 barras. c Fronteira de Pareto para o sistema IEEE 57 barras. d Fronteira de Pareto para o sistema brasileiro de 61 barras (Bozz et al. 2014). e Fronteira de Pareto para o sistema IEEE 118 barras. f Fronteira de Pareto para o sistema IEEE 300 barras.

de e ausência de MCs, CCMs, UTRs críticas e UMFs críticas.

Os resultados de diversas simulações comprovam a eficiência do método, principalmente em sistemas maiores (com 118 e 300 barras), quando comparados a outras metodologias existentes.

Referências Bibliográficas

- Abbasy, N.H. & Ismail, H.M., 2009. A unified approach for the optimal PMU location for power system state estimation. *IEEE Transactions on Power Systems*, 24(2), pp.806–813.
- Bozz, A.A.C., Vigliassi, M.P. & London Jr., J.B.A., 2014. Metering system planning for state estimation via evolutionary algorithm and HTΔ matrix considering SCADA and PMU measurements. *2014 IEEE PES General Meeting | Conference & Exposition*, p.110.
- Brueni, D.J. & Heath, L.S., 2005. The PMU Placement Problem. *Society for Industrial and Applied Mathematics*, 19(3), pp.744–761.
- Camillo, M.H.M. et al., 2016. Combining Exhaustive Search and Multi-Objective Evolutionary Algorithm for Service Restoration in Large-Scale Distribution Systems. *Electric Power Systems Research*, pp.1–8.
- Castillo, M.R.M. et al., 2011. Offline detection, identification, and correction of branch parameter errors based on several measurement snapshots. *IEEE Transactions on Power Systems*, 26(2), pp.870–877. Available at: <http://ieeexplore.ieee.org/document/5557797/> [Accessed July 29, 2017].
- 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.
- Coser, J., Simões Costa, A.J.A. & 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.
- Do Coutto Filho, M.B. et al., 2005. Application of Genetic Algorithms for Planning Metering Systems in State Estimation. *Power Systems Computational Conference*.
- Deb, K., 2011. *Multi-Objective Optimization Using Evolutionary Algorithms: An Introduction* I. K. Deb, ed., New York: Springer London.
- Gamm, A.Z. et al., 2008. PMU placement criteria for EPS state estimation. *Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*, (April), pp.645–649.
- Jamuna, K. & Swarup, K.S., 2011. Electrical Power and Energy Systems Optimal placement of

- PMU and SCADA measurements for security constrained state estimation. *International Journal of Electrical Power and Energy Systems*, 33(10), pp.1658–1665.
- Karegar, H.K. & Dalali, M., 2016. Optimal PMU placement for full observability of the power network with maximum redundancy using modified binary cuckoo optimisation algorithm. *IET Generation, Transmission & Distribution*, 10(11), pp.2817–2824. Available at: <http://digital-library.theiet.org/content/journals/10.1049/iet-gtd.2016.0287> [Accessed July 29, 2017].
- Korres, G.N. & Manousakis, N.M., 2011. State estimation and bad data processing for systems including PMU and SCADA measurements. *Electric Power Systems Research*, 81, pp.1514–1524.
- London Jr., 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 Jr., J.B.A., Alberto, L.F.C. & Bretas, N.G., 2007. Analysis of measurement-set qualitative characteristics for state-estimation purposes. *Generation, Transmission & Distribution, IET*, 1(1), pp.39–45.
- London Jr., J.B.A., Brito, G.L.R. & Bretas, N.G., 2003. Method for meter and RTU placement for state estimation purposes. *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.
- Milosevic, B. & Begovic, M., 2003. Nondominated sorting genetic algorithm for optimal phasor measurement placement. *IEEE Transactions on Power Systems*, 18(1), pp.69–75.
- Pal, A., Vullikanti, A.K.S. & Ravi, S.S., 2017. A PMU Placement Scheme Considering Realistic Costs and Modern Trends in Relaying. *IEEE Transactions on Power Systems*, 32(1), pp.552–561.
- Phadke, A.G., 2002. Synchronized phasor measurements-a historical overview. *IEEE/PES Transmission and Distribution Conference and Exhibition*, 1, pp.476–479.
- Rocha, H.R.O., De Souza, J.C.S. & Do Coutto Filho, M.B., 2013. Electrical Power and Energy Systems Planning high quality metering systems for state estimation through a constructive heuristic. *International Journal of Electrical Power and Energy Systems*, 52, pp.34–41.
- 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 Jr., 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., 2016. Algoritmo Evolutivo Multi-Objetivo para Redução de Custos na alocação de Medidores SCADA e PMU para Efeito de Estimação de Estado. *Congresso Brasileiro de Automática*.
- Vigliassi, M.P. et al., 2017. Combining Multi-objective Evolutionary Algorithm and H Matrix for SCADA and PMU Placement. *General Meeting*.
- Vigliassi, M.P. et al., 2009. Metering system planning for state estimation via evolutionary algorithm and H matrix. *IEEE Bucharest PowerTech*, pp.1–5.
- Zhu, J. & Abur, A., 2007. Effect of Phasor Measurements on the Choice of Reference Bus for State Estimation. *2007 IEEE Power Engineering Society General Meeting*, pp.1–5.