

Alocação Ótima de um Sistema de Medição Fasorial Sincronizada utilizando Algoritmo Evolucionário

Lucas L. Lunarti* Victor L. Valadão**
Maury M. G. Junior***

* Programa de Pós-Graduação em Engenharia Elétrica, PUC- MG,
(e-mail: lucas.lunarti@sgapucminas.br)

** Faculdade de Engenharia Elétrica, Instituto Federal de Goiás, GO
(e-mail: lunarti@gmail.com)

*** Programa de Pós-Graduação em Engenharia Elétrica, PUC- MG,
(e-mail: maury@pucminas.br)

Abstract: The Phasor Measurement Unit (PMU) is a device that allows the synchronized measurement of the voltage and current of electrical systems in microseconds. The PMU are installed in substations of the energy system and their measurements are sent and processed by the Phasor Data Concentrator (PDC). In recent years, different methods for finding the optimal allocation of PMU have been addressed in the literature. The contribution of this research is, through an Evolutionary Algorithm, to find the optimal simultaneous allocation of the PMU and PDCs, considering the number of channels of the PMUs, the distance between the PMUs and the PDCs and to consider the observability situation for n-1 contingency. The proposed methodology allowed to find the allocation of PMUs and PDCs for IEEE 14 and 30 bus systems.

Resumo: A Unidade de Medição Fasorial (UMF) é um equipamento que possibilita a medição sincronizada da tensão de sequência positiva e corrente dos sistemas elétricos em microssegundos. As UMFs são instaladas em subestações do sistema de energia e suas medições são enviadas e processadas pelo Concentrador de Dados Fasoriais, do inglês, Phasor Data Concentrator (PDC). Nos últimos anos, diferentes métodos para encontrar a alocação ótima das UMFs foram abordados na literatura. A contribuição desta pesquisa é, por meio de um Algoritmo Evolucionário, encontrar a alocação ótima simultânea das UMFs e PDCs, considerando a quantidade de canais das UMFs, a distância entre as UMFs e os PDCs e considerar a situação de observabilidade para contingência n-1. Com a metodologia proposta foi possível encontrar a alocação das UMFs e PDCs para os sistemas de 14 e 30 barras do IEEE.

Keywords: Evolutionary Algorithm; Optimal Placement; PMU; PDC; Power Systems

Palavras-chaves: Algoritmos Evolucionários; Alocação Ótima; UMF; PDC; Sistemas Elétricos.

1. INTRODUÇÃO

Com a crescente demanda de energia elétrica, os sistemas elétricos têm se tornado cada vez mais interligados e extensos, aumentando assim a complexidade operacional do mesmo. Diante dessa complexidade operacional surge a necessidade do aperfeiçoamento e desenvolvimento de novos instrumentos de monitoração e controle do Sistema Elétrico de Potência (SEP). Dentre deste contexto se insere o Sistema de Medição Fasorial Sincronizada (SMFS). (Dubey et al., 2018)

Os SMFS são constituídos basicamente por Unidades de Medição Fasorial (UMFs) e por Concentradores de Dados Fasoriais (Babu e Bhattacharyya, 2016). De acordo com Taher et al. (2016), a UMF é considerada um dos mais importantes dispositivos de medição do sistema elétrico do futuro. Basetti e Chandel (2017) descrevem que o princípio de funcionamento do SMFS consiste na captura de dados fasoriais sincronizados no tempo (tensão e corrente)

pela UMF, que os envia para o Concentrador de Dados Fasoriais, conhecidos também como (PDC), via rede de comunicação. O Concentrador de Dados Fasoriais reúne esses dados medidos e organiza-os com base no registro de data e hora do sistema de posicionamento global (GPS) e os envia para a Interface Homem Máquina (IHM) para controle do sistema de energia. Basetti e Chandel (2017) afirmam também que uma vez que a UMF é instalada em uma barra é obtido o fasor de tensão da barra instalada e o fasor de corrente de alguns ou todos os ramos conectados a barra instalada com a UMF. A quantidade de ramos que são medidos pela UMF depende da quantidade de canais da mesma, quanto maior o número de canais, maior é o número de ramos medidos.

Manousakis e Korres (2015) afirmam que para instalar um SMFS é necessário um alto investimento. Diversos pesquisadores buscam formas de minimizar esse problema, onde buscam um equilíbrio entre um número mínimo de UMFs instaladas para um sistema completamente observá-

vel. Porém, Almasabi e Mitra (2018) afirmam que apenas considerar o número de UMFs instaladas no sistema não é a forma mais completa e realista de reduzir custos, ou seja, não é a solução ótima. Existem diversos fatores que influenciam no custo final na instalação de um SMFS, tais como quantidades de canais da UMF, quantidades de PDCs e distância entre ambos. Para Phadke e Thorp (2017), é considerada alocação ótima, na maioria das aplicações, quando as UMFs e os Concentradores de Dados Fasoriais estão instaladas no seu menor número e menor distância entre si, garantindo um sistema totalmente monitorado. A garantia de um sistema totalmente monitorado diante de contingências e falhas também deve ser considerada para uma análise completa.

A alocação ótima de UMFs já foi alvo de pesquisa por diversos autores (Noureen et al., 2017). Mandich et al. (2019) apresentaram alocação ótima de UMFs utilizando programação linear inteira. Manousakis e Korres (2015) além de apresentarem a alocação ótima das UMFs também consideraram a quantidade de canais de medição das UMFs. Ghosh et al. (2017) consideraram a alocação ótima das UMFs para uma condição de falha, isto é, o monitoramento do sistema elétrico não seria afetado mesmo com a perda de uma UMFs. Appasani e Mohanta (2018) realizaram a alocação ótima simultânea das UMFs e PDCs, com objetivo de diminuir o atraso da informação.

O objetivo do presente trabalho é realizar a alocação ótima simultânea das UMFs e dos PDCs, considerando a quantidade de canais de medição das UMFs e o caminho mínimo para a transferência de informação entre as UMFs e os PDCs. Para alcançar esse objetivo, é proposto a utilização de um algoritmo evolucionário.

Este artigo está organizado como a seguir. A Seção 2 apresenta os trabalhos relacionados ao tema que têm sido publicados recentemente. A Seção 3 expõe o referencial teórico. Na Seção 4 consta a metodologia abordada. A Seção 5 expõe os resultados obtidos e uma breve comparação com outros resultados encontrados na literatura. A Seção 6 apresenta a conclusão do artigo.

2. TRABALHOS RELACIONADOS

Nesta seção são apresentados os trabalhos relacionados a proposta deste trabalho nas áreas de alocação ótima de UMFs e PDCs e uma revisão dos algoritmos utilizados.

Babu e Bhattacharyya (2016) utilizaram o algoritmo de otimização conhecido como enxame de partículas para buscar alocação ótima das UMFs para a total observação do sistema elétrico. A técnica utilizada mostra em qual barras do sistema elétrico as UMFs devem ser instaladas. Porém, os autores não consideraram condições de contingências e também não abordaram a localização do PDC.

Taher et al. (2016) utilizaram um algoritmo evolucionário chamado Algoritmo Competitivo Imperialista Modificado na busca da alocação ótima das UMFs. No artigo é incrementada a situação em caso de perda de uma UMF, ou seja, é considerado um sistema de segurança, onde no caso da perda de uma UMF o sistema ainda continua totalmente observável. Entretanto, os autores não consideraram a alocação do PDC.

Manousakis e Korres (2015) apresentam um método para encontrar a alocação ótima de UMFs, considerando números fixos de canais e possíveis equipamentos de medição convencionais já existentes. Considerar uma quantidade fixa de canais de medição limita as possibilidades de soluções e dificulta a busca pela solução ótima, visto que o custo da UMF é diretamente proporcional a sua quantidade de canais, o ideal é ter a mínima quantidade de canais por UMF, de forma a garantir o monitoramento completo do SEP.

No artigo de Mohammadi et al. (2015), o objetivo é minimizar o custo do SMFS de forma geral, é considerado o menor número de UMFs e distância de comunicação até o PDC por meio de dois algoritmos a seguir, algoritmo evolucionário chamado Algoritmo Competitivo Imperialista Binário e o Algoritmo de Dijkstra para encontrar o menor caminho entre as UMFs e o PDC. Um fator importante neste artigo é a implementação de custos reais dos equipamentos a serem instalados e a situação de contingência para falha de UMFs.

Noureen et al. (2017) compararam diversas técnicas utilizadas na literatura para alocação ótima de UMF. O Algoritmo Genético foi avaliado pelos autores como tendo baixa necessidade de informação das UMFs e garantem um alto monitoramento do sistema, quando comparado com outras técnicas de otimização, tornando assim, uma ferramenta de otimização importante para alocação ótima de UMFs.

Basetti e Chandel (2017) apresentam uma nova técnica para alocação ótima de UMF utilizando otimização heurística baseada na ecolocalização dos morcegos. Essa técnica identifica o menor número de UMFs a serem instaladas e as melhores barras para instala-las e posteriormente é comparada com outras técnicas na literatura. Os autores abordaram a alocação ótima de UMFs em condições de normais de operação e condição de contingência, porém não abordam a quantidade de canais das UMFs e não apresentaram a alocação do PDC.

Dubey et al. (2018) utilizam uma técnica de otimização chamada Evolução Diferencial para a localização das UMFs e PDCs, considerando a situação em caso de perda de UMF. Por fim é mostrado o custo relacionado com a instalação dos equipamentos. Os autores utilizaram o Algoritmo de Dijkstra para encontrar o caminho mínimo entre as UMFs e o PDC, porém os autores não consideraram a quantidade de canais das UMFs.

No artigo de Appasani e Mohanta (2018), o foco é em minimizar o atraso da comunicação entre a UMF e o PDC, aumentando como consequência a confiabilidade do sistema. Para alcançar esse objetivo foi utilizado como ferramenta de otimização o Algoritmo Genético.

Conforme apresentados nesta seção, diversas considerações e ferramentas de otimização foram utilizadas na literatura para alocação ótima de UMFs e os PDCs. Os Algoritmos Evolucionários e o Algoritmo de Dijkstra apresentaram resultados relevantes na literatura para alocação simultânea de UMFs e PDCs, desta forma, serão utilizados como ferramenta para alcançar o objetivo do presente trabalho.

3. REFERENCIAL TEÓRICO

Nesta seção serão apresentados os conceitos do problema de alocação ótima de UMF e PDCs, Algoritmos Evolucionários (AE) e Algoritmo de Dijkstra.

3.1 Problema de Alocação Ótima de UMF e Concentrador de Dados Fasoriais (PDCs)

De acordo com Asgari e Firouzjah (2018), ao instalar a UMF em uma barra do sistema elétrico, a tensão dessa barra será observável e, caso a UMF tenha canais suficientes, as correntes de todas as barras conectadas a ela também serão observáveis. Mandich et al. (2019), consideram alocação ótima de UMF quando se encontra o número mínimo de UMFs a serem instalados para assegurar o total monitoramento do sistema elétrico.

Em conformidade com Asgari e Firouzjah (2018), o monitoramento de cada sistema depende das suas equações de estado. Essas equações são baseadas na Lei de Kirchhoff das correntes e tensões e são utilizadas nas três regras a seguir:

- 1- Se a tensão da barra I e a corrente entre a barra I e a barra J for conhecida, então a tensão da barra J também é conhecida;
- 2- Se a barra I e a barra J são conectadas e suas respectivas tensões são conhecidas, então a corrente entre elas também é conhecida;
- 3- Se a tensão entre todas as barras conectadas a barra J são conhecidas, então a tensão da barra J também é conhecida.

A alocação ótima do PDC é obtida quando todas as UMFs estão conectadas ao PDC por meio do trajeto mais curto, pois, de acordo com Dubey et al. (2018), quanto maior a distância entre a UMF e o PDC maior é o custo com a rede de comunicação, isto é, a quantidade de fibra ótica necessária para transmitir as informações coletadas e calculadas pela UMF para o PDC.

3.2 Algoritmo Evolucionário (AE)

Conforme Linden (2012) um Algoritmo Evolucionário (AE) é um algoritmo de busca global baseado na teoria da evolução de Darwin. O AE é constituído de uma população de indivíduos, ou possíveis soluções para o problema em questão, formados pelas variáveis de decisão do problema, conhecidas como genes. Os indivíduos da população são avaliados por uma função chamada fitness. Conforme as avaliações, as próximas gerações da população tendem a atingir avaliações melhores baseadas em uma ação de seleção, onde os indivíduos com as piores avaliações tendem a ser eliminados e os melhores avaliados são mantidos. Ao longo das gerações, os indivíduos sofrem modificações por meio de dois operadores a seguir, cruzamento e mutação. Portanto, um AE tende a produzir uma população com fitness médio melhor do que a da inicial.

A Fig. 1 apresenta o fluxograma com as etapas de um AE. O indivíduo, avaliação (fitness), seleção, cruzamento e mutação são conceitos básicos de um AE. Cada conceito será definido nas subseções a seguir.



Figura 1. Fluxograma de um Algoritmo Evolucionário

Indivíduo O indivíduo é uma peça fundamental para a adequada aplicação do AE. Ele consiste na representação da informação do problema de uma forma viável a ser tratada pelo algoritmo. A qualidade dos resultados obtidos é diretamente proporcional ao tanto que o indivíduo representa de forma adequada o problema (Gouvêa Jr e Araújo, 2015).

Avaliação (fitness) A avaliação é a forma que o Algoritmo Evolucionário utiliza para estabelecer a qualidade de um indivíduo como solução do problema proposto (Gouvêa Jr e Araújo, 2015).

Seleção A seleção natural pode ser definida, de maneira simples, na capacidade de sobrevivência e reprodução dos indivíduos. O AE utiliza três principais métodos para realizar a seleção, o Método de Torneio, Método Roleta e o Elitismo (Linden, 2012).

O Método de Torneio consiste em selecionar indivíduos de forma aleatória e fazer com que os indivíduos entrem em competição pelo direito de ser pai por meio da nota obtida na avaliação, sendo as maiores notas os vencedores (Linden, 2012).

No Método da Roleta, cada indivíduo da população será representado, em uma roleta, proporcionalmente ao valor de sua qualidade. Assim, para indivíduos com alta qualidade é dada uma porção maior da roleta (Linden, 2012).

A ideia base que o Método por Elitismo traz é que os melhores indivíduos de cada geração não devem “morrer” e devem ser passados para a próxima geração para que nenhum dos seus genes sejam perdidos (Linden, 2012).

Cruzamento e Mutação O cruzamento visa realizar uma troca de informações de dois indivíduos que foram selecionados na população fazendo uma analogia com a troca de material genético na reprodução sexuada (Linden, 2012).

A mutação é um processo espontâneo, que altera os genes dos indivíduos “filhos” durante o processo de recombinação gênica (Gouvêa Jr e Araújo, 2015).

3.3 ALGORITMO DE DIJKSTRA

O Algoritmo de Dijkstra é conhecido como algoritmo do caminho mínimo, é normalmente utilizado para encontrar o menor caminho. O peso do caminho é mencionado acima das bordas. Inicialmente, assume-se que o peso de todos os nós é infinito. O método começa com a fonte s , seus nós adjacentes são a e b com peso de 5 e 1 respectivamente. Conseqüentemente o nó mais próximo de s é o nó b . Da mesma maneira, o processo é realizado para todos os nós, conforme a Fig. 2 de (a) a (e). Assim o algoritmo encontra o caminho mais curto da origem para todos os nós, considerando todos os caminhos (Dubey et al., 2018).

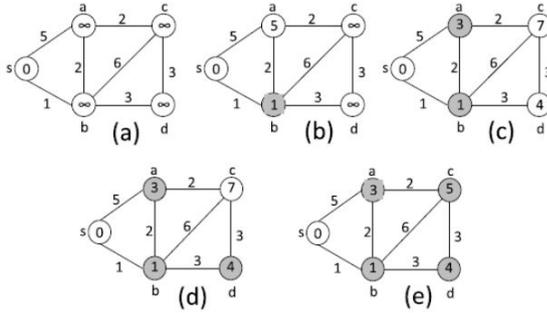


Figura 2. Algoritmo de Dijkstra (Dubey et al., 2018)

4. METODOLOGIA

Trata-se de um problema multi-objetivo, onde busca-se maximizar o número de barras monitoradas do SEP e minimizar a quantidade de canais, UMFs e distância entre UMFs e PDCs de forma a garantir o critério $n-1$ para caso de falha dos equipamentos.

4.1 AE Aplicado na Alocação Ótima

Cada etapa do algoritmo é detalhada a seguir, começando com a modelagem do indivíduo e terminando no critério de parada.

Indivíduo Nesta metodologia, o indivíduo é representado por 3 vetores que determinam, respectivamente, a localização da UMF, a quantidade de canais da UMF e a localização dos PDCs. O primeiro vetor do indivíduo é modelado como $1 \times B$, onde B representa a quantidade de barras do SEP. Os genes do primeiro vetor, $G_p(i)$, são representados como segue.

$$G_p(i) = \begin{cases} 1 & \text{UMF instalada na barra } i \\ 0 & \text{UMF não instalada na barra } i \end{cases} \quad (1)$$

O segundo vetor do mesmo indivíduo é responsável por receber as informações referentes as quantidades de canais de cada UMF, sendo modelado como $1 \times B$, onde B representa também o número de barras do SEP. Os genes do segundo vetor do indivíduo, $G_c(i)$, são representados como segue.

$$0 \leq G_c(i) \leq N_{Cmax} \quad (2)$$

Sendo N_{CHmax} a quantidade máxima de canais e $G_c(i)$ o número de canais da UMF instalada na barra i .

O terceiro vetor é responsável pela localização dos PDCs, tem dimensão $1 \times s$, sendo s o número de PDCs, s é dependente da contingência, no caso de contingência $n-1$ a variável s recebe o valor 2, no caso de contingência $n-2$ a variável s recebe o valor 3 e assim por diante. Os valores dos genes do indivíduo são representados por $G_{pdc}(i)$, conforme a seguir.

$$1 \leq G_{pdc}(i) \leq B \quad (3)$$

Sendo $G_{pdc}(i)$ a barra onde está localizado o PDC e B o número de barras do sistema.

Avaliação (Fitness) Após a definição do indivíduo, inicia-se a etapa de avaliação. Na metodologia abordada, o fitness do indivíduo é calculado pelas funções de minimização $f1$ e maximização $f2$, a função $f1$ representa os custos com as UMFs, representado por G_p , os custos dos canais das UMFs, representado por G_c e pela distância entre as UMFs e os PDCs (G_{pdc}) representado por R_c , a função $f2$ representa a observabilidade do sistema elétrico, $f1$ e $f2$ estão apresentadas a seguir.

$$f1 = \sum_{i=1}^b \alpha G_p(i) + \sum_{i=1}^b \beta G_c(i) + \sum_{i=1}^b \sum_{j=1}^s \gamma R_c(G_p(i), G_{pdc}(j)) \quad (4)$$

$$f2 = \frac{Nb(i)}{b} \quad (5)$$

Sendo α , β e γ coeficientes de custos, $N_b(i)$ o número de barras monitoradas pelo indivíduo i , b a quantidade de barras do sistema, s a quantidade de PDCs no sistema e R_c a rede de comunicação entre as UMFs e o PDC. A nota final do indivíduo é calculada conforme a seguir.

$$fitness = \frac{f1_{min}}{f1} + f2 \quad (6)$$

Sendo $f1_{min}$ o menor $f1$ encontrado durante todas as gerações, $f2 \geq 1$ para um sistema totalmente monitorado e $f2 \geq 2$ para um sistema totalmente monitorado para situação de contingência $n - 1$.

Seleção Com a avaliação dos indivíduos realizada, inicia a etapa do algoritmo que é responsável por selecionar um indivíduo ou grupo de uma população. Neste trabalho foram utilizadas a seleção por elitismo e torneio. Elitismo é utilizado para assegurar os melhores indivíduos da população atual na população da próxima geração, prevenindo a perda da melhor solução já encontrada. Após a seleção por elitismo é realizada a seleção por torneio.

Cruzamento e Mutação No processo de cruzamento há um ponto de corte aleatório nos pais, $P1$ e $P2$, que define como os filhos são formados, $F1$ e $F2$. O processo de como são geradas as gerações futuras é visto na Fig. 3.

		Ponto de corte		
P1	G_{p1}	G_{p2}	...	G_{pB}
	G_{c1}	G_{c2}	...	G_{cB}
	G_{pdc1}	G_{pdc2}	...	G_{pdcS}
P2	G_{p1}	G_{p2}	...	G_{pB}
	G_{c1}	G_{c2}	...	G_{cB}
	G_{pdc1}	G_{pdc2}	...	G_{pdcS}

Figura 3. Operador de Cruzamento

Após o cruzamento, o primeiro filho (F1) é composto por meio da associação da parte do primeiro pai (P1) à esquerda do ponto do corte com a parte do segundo pai (P2) à direita do ponto de corte. O segundo filho (F2) é composto através da junção das partes restantes, conforme a Fig. 4.

F1	G_{p1}	G_{p2}	...	G_{pB}
	G_{c1}	G_{c2}	...	G_{cB}
	G_{pdc1}	G_{pdc2}	...	G_{pdcS}
F2	G_{p1}	G_{p2}	...	G_{pB}
	G_{c1}	G_{c2}	...	G_{cB}
	G_{pdc1}	G_{pdc2}	...	G_{pdcS}

Figura 4. Geração de Filhos

Após o cruzamento, a mutação é executada. Na metodologia proposta, a mutação é realizada em todos os vetores do indivíduo, pois caso a mutação altere o gene do vetor de UMF, consequentemente o mesmo gene para o vetor de canais de UMF será alterado, conforme Fig. 5.

F1	G_{p1}	G_{p2}	...	G_{pB}
	G_{c1}	G_{c2}	...	G_{cB}
	G_{pdc1}	G_{pdc2}	...	G_{pdcS}
F1'	G_{p1}	G_{p2}'	...	G_{pB}
	G_{c1}	G_{c2}'	...	G_{cB}
	G_{pdc1}	G_{pdc2}'	...	G_{pdcS}

Figura 5. Mutação

Critério de Parada O processo de avaliação e os operadores genéticos são aplicados de forma contínua durante as gerações até que um critério de parada seja satisfeito. O critério de parada utilizado na metodologia é de 700 gerações.

4.2 Algoritmo de Dijkstra aplicado na Alocação Ótima

Para encontrar a alocação ótima das UMFs e do PDC, busca-se encontrar o caminho mínimo entre o PDC e todas as UMFs, desta forma, executamos o algoritmo de Dijkstra

com n iterações, sendo n o tamanho do sistema. Com a informação da localização do PDC, executa o algoritmo de Dijkstra para calcular o caminho mais curto do PDC para todos os nós com UMF instalada.

5. RESULTADOS

Para avaliar a eficiência da metodologia proposta, foram abordadas duas condições com o software MATLAB. Cada condição foi aplicada para os sistemas de 14 e 30 barras do Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE) com o objetivo de poder comparar com os trabalhos de Basetti e Chandel (2017) e Ghost et al. (2017). A primeira condição abordada foi para um sistema operando em condições normais, ou seja, sem a falha de qualquer equipamento. Os resultados encontrados pelo AE utilizado estão apresentados na Tabela 1.

Tabela 1. Alocação UMFs e PDC em Condições Normais

Barras IEEE	No. UMFs	Localização UMFs	No. Canais	PDC
Proposto 14 Barras	4	2, 6, 7 e 9	10	4
Vedik e Chandel 14 Barras	4	2, 8, 10 e 13	10	-
Ghost et al. 14 Barras	4	2, 6, 7 e 9	-	-
Proposto 30 Barras	10	3, 6, 7, 9, 10, 12, 19, 24, 25 e 27	23	9
Vedik e Chandel 30 Barras	10	2, 4, 6, 9, 10, 12, 15, 19, 25 e 27	25	-
Ghost et al. 30 Barras	10	2, 4, 6, 9, 10, 12, 15, 19, 25 e 27	-	-

Com a metodologia abordada foram encontradas quatro UMFs para o sistema de 14 barras e dez UMFs para um sistema de 30 barras. A quantidade de UMFs em ambos os casos convergiram com as soluções encontradas por Basetti e Chandel (2017) e Ghost et al. (2017). A diferença da nossa metodologia está na abordagem da quantidade de canais das UMFs e na localização do PDC. Ghost et al. (2017) não abordaram a quantidade de canais e também não consideraram a localização do PDC.

Basetti e Chandel (2017) consideraram na metodologia deles a quantidade de canais das UMFs para condições normais de operação, o resultado apresentado por eles, para manter o SEP totalmente monitorado, foram necessários 10 e 25 canais respectivamente para os sistemas de 14 e 30 barras.

A solução encontrada pela metodologia proposta pelos autores para alcançar o mesmo objetivo de Basetti e Chandel (2017), isto é, o monitoramento do SEP por completo, foi de 10 canais para o sistema de 14 barras e 23 canais para o sistema de 30 barras, ou seja, para o sistema de 30 barras a nossa metodologia encontrou uma solução equivalente a de Basetti e Chandel (2017) com duas unidades de canais a menos.

A localização ideal do PDC, considerando a instalação das UMFs nas apresentadas na Tabela 1, pelo Algoritmo de

Dijkstra, foi na barra 4 para o sistema de 14 barras e na barra 9 para o sistema de 30 barras.

A segunda condição abordada pela metodologia proposta, foi para um sistema em contingência $n-1$, isto é, o SEP tem que permanecer completamente monitorado mesmo com a perda de qualquer equipamento do sistema. O resultado é apresentado na Tabela 2.

Tabela 2. Alocação UMF e PDC em contingência $n-1$

Barras IEEE	No. UMFs	Localização UMFs	No. Canais	PDC
Proposto 14 Barras	9	2, 4, 5, 6, 7, 8, 9, 10 e 13	29	4 e 5
Vedik e Chandel 14 Barras	9	2, 4, 5, 6, 7, 8, 9, 11 e 13	-	-
Ghost et al. 14 Barras	9	2, 4, 5, 6, 7, 8, 9, 10 e 13	-	-
Proposto 30 Barras	21	2, 3, 4, 6, 7, 8, 9, 10, 11, 12, 13, 15, 16, 18, 19, 21, 24, 25, 26, 27 e 29	72	9 e 6
Vedik e Chandel 30 Barras	21	2, 3, 4, 5, 6, 9, 10, 11, 12, 13, 15, 17, 18, 19, 21, 24, 25, 26, 27, 28 e 30	-	-
Ghosh et al. 30 Barras	21	1, 2, 4, 5, 6, 9, 10, 11, 12, 13, 15, 17, 18, 19, 22, 24, 25, 26, 27, 28 e 30	-	-

Com a metodologia proposta foram encontrados 29 canais para um sistema de 14 barras do IEEE e 72 canais para um sistema de 30 barras do IEEE, ambos os sistemas em contingência $n-1$. As localizações encontradas para a instalação dos PDCs foram nas barras 4 e 5 para o sistema de 14 barras e nas barras 9 e 6 para o sistema de 30 barras. Desta forma, o objetivo de garantir o sistema completamente monitorado mesmo com a perda de qualquer equipamento (UMF ou PDC) foi alcançado.

6. CONCLUSÃO

A inserção da medição fasorial tende a aumentar conforme os incentivos e necessidades do sistema elétrico. Este trabalho apresentou uma revisão na literatura e um método utilizando Algoritmo Evolucionário aplicado na alocação ótima das Unidades de Medições Fasoriais (UMFs) e dos Concentradores de Dados Fasoriais (PDCs). O resultado mostra que método proposto atinge o objetivo. A contribuição do trabalho apresentado está na consideração da alocação simultânea de UMFs e PDCs, bem como na consideração da quantidades de canais das UMFs, do caminho entre as UMFs e os PDCs e na abordagem do sistema em contingência $n-1$. Com o método proposto foi possível realizar, utilizando o software MATLAB, a alocação de um Sistema de Medição Fasorial Sincronizada para os sistemas de 14 e 30 barras do IEEE.

AGRADECIMENTOS

Os autores agradecem a Pontifícia Universidade Católica de Minas Gerais por todo o apoio prestado.

REFERÊNCIAS

- Almasabi, S. and Mitra, J. (2018). Multistage optimal pmu placement considering substation infrastructure. *IEEE Transactions on Industry Applications*, 54(6),6519-6528.
- Appasani, B. and Mohanta, D.K. (2018). Co-optimal placement of pmus and their communication infrastructure for minimization of propagation delay in the wams. *IEEE Transactions on Industrial Informatics*, 14(5),2120-2132.
- Asgari, A. and Firouzbah, K.G. (2018). Optimal pmu placement for power system observability considering network expansion and $n-1$ contingencies. *IET Generation, Transmission & Distribution*, 12(8), 4216 – 4224.
- Babu, R. and Bhattacharyya, B. (2016). Optimal allocation of phasor measurement unit for full observability of the connected power network. *International Journal of Electrical Power & Energy Systems*, 79, 89 – 97.
- Basetti, V. and Chandel, A.K. (2017). Optimal pmu placement for power system observability using taguchi binary bat algorithm. *Measurements*, 95,8-20.
- Dubey, R., Popov, M., and Muro, J.D.J.C.(2018). Cost effective wide area measurement systems for smart power network. *IEEE Power and Energy Technology Systems Journal*, 5(3),85-93.
- Ghosh, P.K., Chatterjee, S., and Roy, B.K.S. (2017). Optimal pmu placement solution: graph theory and mcdm-based approach. *IET Generation, Transmission & Distribution*, 11(13), 3371 – 3380.
- Gouvêa Jr, M.M and Araújo, A.F. (2015). Evolutionary algorithm with diversity-reference adaptive control in dynamic environments. *International Journal on Artificial Intelligence Tools*, 24(01),1450013.
- Linden, R. (2012). *Algoritmos genéticos*. Ciência Moderna. Vol. 3.
- Mandich, M., Xia, T., and Sun, K. (2019). Optimal pmu placement using stochastic methods. In 2019 IEEE Power & Energy Society General Meeting (PESGM) 1-5.
- Manousakis, N.M. and Korres, G.N. (2015). Optimal pmu placement for numerical observability considering fixed channel capacity-a semidefinite programming approach. *IEEE Transactions on Power Systems*, 31(4),3328-3329.
- Mohammadi, M.B., Hooshmand, R.A., Fesharaki, F.H. (2015). A new approach for optimal placement of pmus and their required communication infrastructure in order to minimize the cost of the wams. *IEEE Transactions on smart grid*, 7(1),84-93.
- Noureen, S.S., Roy, V., and Bayne, S.B. (2017). Phasor measurement unit integration: A review on optimal pmu placement methods in power system. In 2017 IEEE Region 10 Humanitarian Technology Conference (R10-HTC), 328-332.
- Phadke, A.G. and Thorp, J.S. (2017). *Synchronized phasor measurement and their applications*. Springer, Vol. 2.
- Taher, S.A., Mahmoodi, H., and Aghaamouci, H. (2016). Optimal pmu location in power systems using mica, *Alexandria Engineering Journal*, 54(1),399-406.