State Estimation of Electrical Distribution Power System Using the Grey Wolf Optimizer

Gabriel H. Carboni*, Leonardo Willer de Oliveira*, Edimar José de Oliveira*, Victor Ribeiro Lucio*.

**Department of Electrical Engineering, Federal University of Juiz de Fora-UFJF, Juiz de Fora, MG, Brazil. (carboni.gabriel@engenharia.ufjf.br)*

Abstract: State estimation is a crucial activity in power systems to ensure efficient operation and maintain system security. This article presents an innovative approach using the Grey Wolf Optimizer (GWO) for state estimation in electric power systems. The GWO algorithm is a population-based metaheuristic inspired by the social behavior of grey wolves in hunting. In this approach, the GWO algorithm is applied to estimate the state variables of the power system, including voltage magnitudes and phase angles at all buses. The proposed method is validated using the IEEE 14-bus and 33-bus test systems and compared with the Extended Optimal Power Flow (E-OPF) approach. The results demonstrate the effectiveness of the GWO-based state estimator, especially with increased measurement redundancy. Additionally, the performance of the estimator was evaluated with randomly varying load values from light to heavy, highlighting its ability to handle diverse system conditions. Despite its promising performance, the proposed estimator exhibits a relatively high execution time, suggesting the need for optimization in computational efficiency.

Resumo: A estimação de estados é uma atividade muito importante em sistemas de energia para garantir operação eficiente e manter a segurança do sistema. Este artigo apresenta uma abordagem inovadora utilizando o Otimizador do Lobo Cinzento (GWO) para estimação de estado em sistemas elétricos de potência. O algoritmo GWO é uma meta-heurística baseada em população inspirada no comportamento social dos lobos cinzentos na caça. Nesta abordagem, o algoritmo GWO é aplicado para estimar as variáveis de estado do sistema de energia, incluindo magnitudes de tensão e ângulos de fase em todos os barramentos. O método proposto é validado usando os sistemas de teste IEEE 14-barras e 33-barras e comparado com a abordagem de Fluxo de Potência Ótimo Estendido (E-OPF). Os resultados demonstram a eficácia do estimador de estado baseado no GWO, especialmente com o aumento da redundância de medições. Além disso, o desempenho do estimador foi avaliado com valores aleatórios de carga indo de leve à pesada, destacando sua capacidade de lidar com diversas condições do sistema. Apesar de seu desempenho promissor, o estimador proposto apresenta um tempo de execução relativamente alto, sugerindo a necessidade de otimização em eficiência computacional.

Keywords: State estimation, Phasor Measurement Unit (PMU), Meta-heuristic.

Palavras-chaves: Estimação de estados, Unidade de medição fasorial, Meta-heurística.

1. INTRODUÇÃO

As funcionalidades essenciais em um centro de operação do sistema (COS) visam garantir a operação eficiente dos Sistemas Elétricos de Potência (SEP), mantendo-os em estado normal seguro à medida em que as condições operacionais variam durante o dia. (Abur et al., 2004). Para isto, utilizam-se algoritmos computacionais que realizam análises da rede visando assegurar o fornecimento adequado de energia, respeitando os limites de qualidade estabelecidos (Melo, 2022). Estas incluem análise de fluxo de potência, despacho de geração, análise de contingências e fluxo de potência ótimo, sendo a eficácia de todas estas dessas funcionalidades dependentes do processo de estimação de estados, reconhecido como fundamental para a operação dos SEPs (Bi et al., 2008). A estimação de estados viabiliza todas as outras aplicações no centro de controle, permitindo a execução de ferramentas para análise contínua da segurança da rede (Monticelli et al., 2012). O estimador de estados é o algoritmo implementado no COS, encarregado de determinar o estado mais provável da rede, computando os módulos de tensão e os ângulos de fase em todas as barras, considerando um número mínimo de medidores, estrategicamente distribuídos para otimização do processo (Melo, 2022).

A concepção da estimação de estados em sistemas elétricos foi pioneiramente apresentada por Fred Schweppe no início dos anos 70 (SCHWEPPE & WILDES - SCHWEPPE & ROM – SCHWEPPE, 1970), desempenhando um papel crucial na modelagem em tempo real da rede elétrica. Desde então, o método dos Mínimos Quadrados Ponderados (MQP) emergiu como a técnica primordial para a Estimação de Estados (EE) em sistemas elétricos, utilizando informações das medições de campo e da topologia da rede (Mingorança et al., 2022). Diversas propostas foram apresentadas para evoluir as técnicas de EE. Baran et al. (1994) propôs um método

trifásico de estimação de estados, baseado em uma abordagem de MQP, para melhorar a precisão dos dados obtidos (por meio de um procedimento de previsão de carga) e utilizados para monitoramento em tempo real de alimentadores de distribuição. Em Lu et al. (1995), um algoritmo para sistemas de distribuição trifásicos é proposto utilizando o método da equação normal para calcular os estados em tempo real, sendo uma formulação baseada em correntes introduzida e comparada com outras formulações.

Além destas técnicas, diversas meta-heurísticas têm sido utilizadas para a estimação de estados. Devido a uma série de fatores, como a expansão das redes, complexidade operativa, contingências e eventos de natureza diversa, os sistemas de distribuição requerem tomadas de decisões difíceis e uma abordagem redundante para a estimação de estados. Por isso, Naveenkumar et al. (2020) propõem uma técnica que utiliza a otimização baseada na estratégia de formigas-leão (ALO) para identificar com precisão os locais ideais para a instalação de unidades de medição de fasorial (PMU), considerando interrupções em cascata de linhas. O objetivo é aprimorar o desempenho da rede inteligente, garantindo uma representação precisa de sua topologia. Asada et al. (2005) utilizam a meta-heurística Busca Tabu para determinar os locais ideais de instalação dos medidores de forma a melhorar a estimação de estados e a maximizar o índice de observabilidade da rede. Andic et al. (2023) propuseram a utilização do CSA (*Crow Search Algorithm*) para realizar a alocação ótima de PMU levando em consideração a restrição do número de canais disponíveis e o custo de implantação. Em seguida, a meta-heurística foi aplicada ao problema de EE e sua eficácia em relação a outros algoritmos bem conhecidos, como Algoritmo Genético (GA), Otimização por Enxame de Partículas (PSO) e Otimização por Enxame de Abelhas Artificiais (ABSO), foi demonstrada através da comparação dos resultados obtidos. Selvi et al. (2005) propuseram o Algoritmo Genético para resolver o problema EE, abordando a detecção e a identificação de erros em conjuntos de dados de medição. Tungadio et al. (2015) discutiram a aplicação de um algoritmo de inteligência artificial (IA) e de PSO para resolver o problema de EE visando minimizar o erro quadrado médio ponderado (WLS) e o menor valor absoluto ponderado (WLAV). Kumar et al. (2011) apresentaram um estimador de estado híbrido baseado em redes neurais artificiais (ANN) na presença de medidas de fasores convencionais assíncronas e síncronas. Mallick et al. (2013) aplicaram duas novas técnicas de busca evolucionária baseadas no algoritmo *Enhanced Particle Swarm Optimization* (IPSO) e no Algoritmo de Busca Gravitacional (GSA) para resolver a EE. Mukherjee (2020) avaliou a adequação de uma nova técnica meta-heurística chamada *Whale Optimization Algorithm* (WOA) para reduzir os erros de medição a fim de avaliar o ponto ótimo do sistema de energia quando alguns valores suscetíveis são inadequados, utilizando uma estratégia de caça em rede de bolhas que imita o comportamento social das baleias jubarte para obter a melhor solução candidata.

Seguindo essa linha de aplicação de meta-heurísticas ao problema de EE, o presente trabalho propõe uma abordagem inovadora para este problema utilizando a técnica conhecida como *Grey Wolf Optimizer* (GWO). Esta é uma das meta-heurísticas populacionais propostas por Mirjalili et al. (2014). Os indivíduos da população armazenam informações candidatas para as demandas nodais do sistema, com um erro correspondente à precisão típica de pseudomedidas, uma vez que essas demandas são as variáveis do GWO. A função de aptidão é o erro de estimação de estado (SEE) proveniente do método de Mínimos Quadrados Ponderados, junto a indicadores suplementares correlacionados às variáveis de estado. Para cada solução candidata, um fluxo de potência via método de Newton-Raphson (NR) é executado para obter estimativas de tensões em módulo e fase, que são comparadas com as medidas disponíveis nas funções de aptidão. Os sistemas do IEEE de 14 e 33 barras foram utilizados para validar o estimador de estado baseado no GWO, e sua eficácia é medida em comparação com o trabalho de Duque et al. (2017), que apresenta uma nova alternativa para EE utilizando Fluxo de Potência Ótimo Estendido (E-OPF).

Este trabalho está estruturado da seguinte forma: a Seção II descreve a respeito de medições utilizadas nos SEPs para EE. Na Seção III, a metodologia utilizada é descrita. A Seção IV apresenta o estudo de caso realizado com os resultados obtidos. Finalmente, a Seção V fornece uma parte de conclusão e sugere trabalhos futuros.

2. FUNDAMENTOS TEÓRICOS

Para realizar a estimação de estados, é necessário que a rede seja observável. Diversos fatores influenciam na observabilidade, como localização, tipo e quantidade de medidores. Alguns fenômenos podem levar o sistema de observável a não observável, como mudanças na topologia, erros na comunicação, e falha nos medidores (da Cunha et al., 2022). Desta forma, diferentes medidas existentes são utilizadas no banco de dados e podem ser processadas durante as etapas de estimação de estados.

Sistemas SCADA (Supervisory Control and Data Acquisition) são utilizadas no processo de EE. Estes sistemas são constituídos utilizando transformadores de corrente e potencial (TCs e TPs) que são conectados a unidades de transmissão remota (RTUs), fornecendo medições de módulos de tensão, corrente, potência ativa e reativa, apresentando desvio padrão na ordem de 0,4% para tensão e 0,8% para corrente (Abur et al., 2004). Normalmente, as medidas são fornecidas em intervalos de tempos regulares como 5 a 10 minutos (Melo, 2022). Como alternativa a sistemas Scada, são utilizadas PMUs que têm alta taxa de atualização ou pseudomedidas organizadas como banco de dados históricos.

2.1 PMUs

A Unidade de Medição de Fasorial (UMF ou PMU) desempenha um papel fundamental na aquisição, processamento das grandezas elétricas e cálculo dos fasores correspondentes. Essa unidade é composta por um sistema de aquisição de dados e um microprocessador dedicado aos cálculos dos fasores. Cada PMU requer a integração com um receptor de sinal de GPS para garantir a sincronização temporal adequada (COSTA et al., 2008).

As PMUs estão conectadas no secundário dos transformadores de corrente e de potencial, sendo estes os responsáveis por fornecer os sinais de corrente e tensão,

respectivamente. Dada a estrutura e o funcionamento, é necessário estabelecer canais de comunicação eficientes para a transmissão de dados entre as PMUs e o concentrador de dados, sendo a escolha do canal de comunicação dependente da quantidade de informações transmitidas, taxa de geração dos fasores, e do tempo de latência aceitável para a aplicação (Phadke, 1993).

No *phasor data concentrator* (PDC), os dados chegam de forma desordenada e são organizados utilizando etiquetas de tempo para formar conjuntos de medidas fasoriais correspondentes ao mesmo instante. Além disso, o PDC desempenha um papel importante no gerenciamento do sistema, monitorando a comunicação com as PMUs, detectando falhas de sincronismo e armazenando dados para análises (Ehrensperger, 2004).

A medição fasorial sincronizada requer uma fonte de sincronismo extremamente confiável, com precisão de tempo adequada para diversas aplicações. Um pequeno erro de tempo pode resultar em grandes discrepâncias nos dados medidos. Por exemplo, um erro de tempo de 1 ms equivale a um erro de 21,6 graus, na frequência de 60 Hz (COSTA et al., 2008). Atualmente, o único sistema comercial de grande escala capaz de atender aos requisitos mínimos de precisão de tempo e de confiabilidade é o sistema GPS (*Global Positioning System*). Os satélites transmitem simultaneamente um sinal de 1 pulso por segundo, com precisão da ordem de 100 nanosegundos, o que possibilitou uma redução significativa nos erros de sincronização (COSTA et al., 2008).

2.2 PSEUDOMEDIDAS

O uso de pseudomedidas é uma alternativa para garantir que a rede continue observável na ausência de monitoramento de todas as variáveis necessárias para a EE, ou em caso de falhas na aquisição de medidas. Essa alternativa está associada a dados históricos disponíveis em centros de controle a partir de faturas de energia de consumidores considerando, por exemplo, dados médios de consumo e demanda. Estes, não são monitorados em tempo real e podem pertencer à classe comercial e residencial. O grau de imprecisão deste tipo de medida pode chegar a 50% (Melo, 2022). Alguns dados podem ser considerados pseudomedidas, como cargas constantes ou que obedecem a curvas constantes ao longo do dia, potência nominal contratada para intercâmbio entre sistemas, e outro registros (Neto, 2017).

3 METODOLOGIA

3.1 Meta-heurística

Os lobos cinzentos são conhecidos por seguirem uma hierarquia rigorosa, constituída por líderes denominados alfa, seguidos de membros betas, deltas e ~~ômegas~~. Além da estrutura hierárquica, os lobos cinzentos também exibem comportamentos sociais interessantes durante a caça em grupo. O processo de caça envolve três fases distintas: rastreamento, perseguição e aproximação da presa; perseguição, cerco e assédio à presa até que ela pare de se mover; e, finalmente, o ataque à presa.

Em um espaço de busca abstrato, não se tem ideia sobre a localização do ponto ótimo (presa). Para simular matematicamente o comportamento de caça dos lobos cinzentos, os membros alfa, beta, delta correspondem, nessa ordem, às melhores soluções obtidas a cada iteração, que atualizam suas posições de acordo com o melhor agente de busca. Os indivíduos são codificados como vetores numéricos decimais que representam as soluções candidatas para o problema em questão. A inicialização dos indivíduos na codificação GWO é feita aleatoriamente dentro dos limites do espaço de busca do problema. Durante a execução do algoritmo, os indivíduos (ou "lobos") são ajustados iterativamente para buscar melhores soluções. É importante ressaltar que, enquanto a codificação dos indivíduos é uma parte fundamental do GWO, a essência do algoritmo reside principalmente em como os lobos se movem e interagem entre si para explorar o espaço de busca das soluções ótimas.

Para modelar matematicamente o comportamento de cada animal as seguintes equações são propostas:

$$\vec{D} = \left|\vec{C}.\overrightarrow{X_P}(t) - \vec{X}(t)\right| \quad 1$$

$$\vec{X}(t+1) = \overrightarrow{X_P}.(t) - \vec{A}\vec{D} \quad 2$$

onde, t indica a iteração atual, $\vec{A}$ e $\vec{C}$ são vetores de coeficientes, $\overrightarrow{X_P}$ é a posição da presa e $\vec{X}$ é o vetor de posição de um lobo. Os vetores A e C são calculados da seguinte forma:

$$\vec{A} = 2\vec{a}\overrightarrow{r_1} - \vec{a} \quad 3$$

$$\vec{C} = 2\overrightarrow{r_2} \quad 4$$

onde, os componentes de $\vec{a}$ são reduzidos linearmente de 2 a 0 ao longo das iterações e $\overrightarrow{r_1}$ e $\overrightarrow{r_2}$ são vetores aleatórios em [0,1]. As três melhores soluções são armazenadas nos indivíduos alfa, beta e delta e todos os demais agentes de busca são direcionados a atualizar suas posições com base neles.

$$\overrightarrow{D_\alpha} = \left|\overrightarrow{C_1}.\overrightarrow{X_\alpha} - \vec{X}\right| \quad 5$$

$$\overrightarrow{D_\beta} = \left|\overrightarrow{C_2}.\overrightarrow{X_\beta} - \vec{X}\right| \quad 6$$

$$\overrightarrow{D_\delta} = \left|\overrightarrow{C_3}.\overrightarrow{X_\delta} - \vec{X}\right| \quad 7$$

$$\overrightarrow{X_1} = \overrightarrow{X_\alpha} - \overrightarrow{A_1}.\left(\overrightarrow{D_\alpha}\right) \quad 8$$

$$\overrightarrow{X_2} = \overrightarrow{X_\beta} - \overrightarrow{A_2}.\left(\overrightarrow{D_\beta}\right) \quad 9$$

$$\overrightarrow{X_3} = \overrightarrow{X_\delta} - \overrightarrow{A_3}.\left(\overrightarrow{D_\delta}\right) \quad 10$$

$$\vec{X}(t+1) = \frac{\overrightarrow{X_1} + \overrightarrow{X_2} + \overrightarrow{X_3}}{3} \quad 11$$

3.2 Algoritmo

O algoritmo aplicado ao processo de estimação de estados segue os passos da **Erro! Fonte de referência não encontrada.**. Inicialmente, define-se a quantidade de indivíduos (agentes de busca) e o número total de iterações. No Passo 1, é feita a inicialização dos indivíduos, em que cada um é um vetor de valores de potência ativa e reativa para todas as barras de carga do sistema. Logo, o número de posições é igual ao dobro do número de barras de carga. Os valores são inicializados de forma aleatória dentro dos limites superior e inferior, dados pela incerteza associada aos dados históricos de carga (pseudomedidas). Em seguida, no Passo 2, a população é avaliada, através da resolução do fluxo de potência pelo

método de Newton-Raphson (Monticelli, 1983). Desta forma, a população é completamente avaliada, sendo redefinida a melhor solução candidata. Os lobos alfa, beta e delta recebem as três melhores soluções.

A convergência é atingida pelo número máximo de iterações. Se a convergência não é alcançada, os mecanismos da meta-heurística referidos no Passo 3 evoluem toda a população de acordo com as três melhores soluções, alfa, beta e delta, conforme apresentado na seção 3.1.

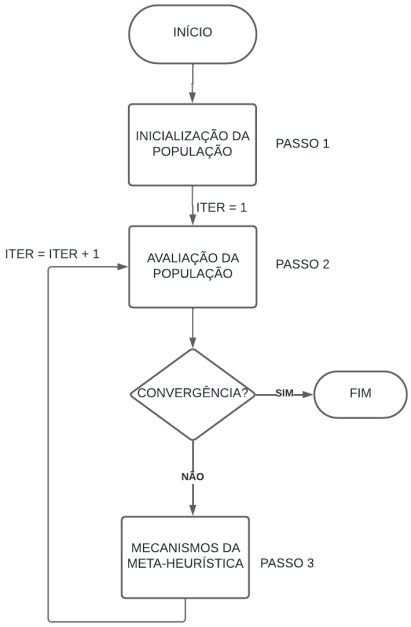

Figura 1 Fluxograma do estimador de estados proposto

4 RESULTADOS

Esta seção apresenta os testes com os sistemas de 14 barras 23kV proposto por Civanlar et al. (1988) e 33 barras proposto por Baran et al. (1989) para avaliar a metodologia proposta. Para este propósito, vamos compará-lo com o que foi desenvolvido no artigo de Duque et al. (2017).

Para iniciar a resolução do problema de estimação de estados, é necessário estabelecer o número de agentes de busca, isto é, o tamanho da matilha, que neste caso foi ajustado em 30 lobos. Cada agente é representado como um vetor que contém as soluções candidatas para a potência ativa e reativa em cada barra do sistema. Esses agentes são inicializados de maneira aleatória dentro de limites 40% abaixo ou acima em relação às pseudomedidas disponíveis para os sistemas. Essa abordagem visa manter o sistema observável mesmo com baixa redundância no número de PMUs.

O modelo de rede elétrica monofásica não linear é considerado nos testes. Embora as cargas de um sistema de distribuição sejam desbalanceadas, os testes com um modelo monofásico podem mostrar a eficácia da abordagem proposta no problema de estimativa de estado.

Os testes do GWO são realizados utilizando somente PMUs com medições de magnitude de tensão e ângulo de fase em diferentes barras do sistema. Erros nas medições das PMUs são dados por 0,4% para a magnitude de tensão e as barras definidas para fornecerem dados de medição são as mesmas utilizadas por Duque et al. (2017), para fins de comparação.

Os resultados estimados do GWO são comparados com os valores reais correspondentes obtidos do Fluxo de Potência Convencional e ao E-OPF. Portanto, os resultados do fluxo de potência para magnitude e ângulo de fase das tensões são tomados como os valores reais para avaliar o estimador.

As simulações foram realizadas em um processador Intel(R) Celeron(R) CPU 1007U @ 1.50GHz com 12 GB de RAM. O pacote MATLAB® foi usado para desenvolver o modelo.

4.1. Teste 1 – Sistema de 14 barras com uma PMU

Neste teste foi considerado a instalação de somente uma PMU alocada na barra 1, ou seja, na saída da subestação. As Figura 2 e Figura 3 apresentam o comparativo entre o resultado do estimador proposto e o resultado real obtido do fluxo de potência, denominado valor de referência. Pode-se observar que há grande divergência entre os valores de referência e estimados nas barras mais distantes da subestação. Isto ocorre devido ao baixo número de PMUs alocadas. A utilização de pseudomedidas para inicializar a população garante que o sistema permaneça observável, mas devido à baixa precisão apresenta discrepâncias consideráveis.

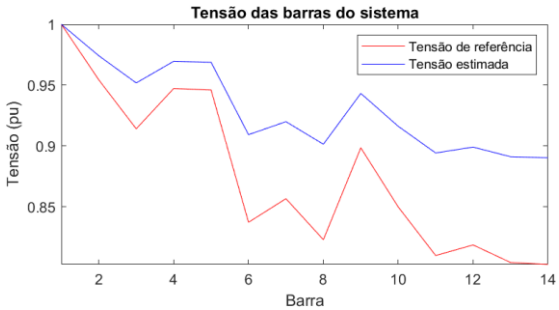

Figura 2 Tensão nas barras para uma PMU alocada na subestação

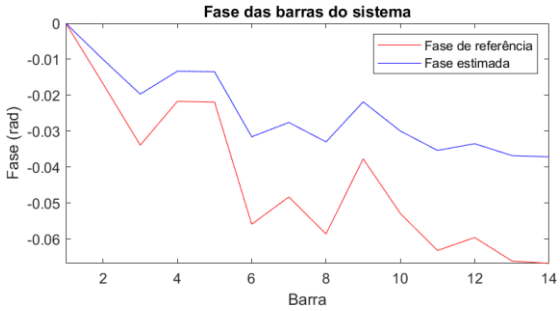

Figura 3 Fase das barras para uma PMU alocada na subestação

4.2 Teste 2 – Sistema de 14 barras com múltiplas PMUs

Nesta etapa, PMUs são distribuídas ao longo da rede a fim de observar o desempenho do estimador com o aumento de medições disponíveis. As localizações dos dispositivos de medição foram definidas no artigo base. Além disso, diferentes índices foram otimizados em cada caso teste.

4.2.1 Simulação 2.1 – Minimização do SEE

Esta simulação considera a minimização do desvio quadrático, isto é, o índice SEE. A Tabela 1 apresenta os índices calculados após o processo de estimação para o GWO e o E-OPF. A melhor solução considerando o SEE é observada quando são instaladas 4 PMUs.

Nº de PMU's	1		2		3		4	
Localização	12		5-11		4-5-11		2-4-5-11	
Algoritmo	GWO	E-OPF	GWO	E-OPF	GWO	E-OPF	GWO	E-OPF
IPA(CRAD)	0.32975	0.08500	0.10778	0.03633	0.22526	0.03582	0.17570	0.03123
SEE(%)	2.03190	1.28557	0.65439	1.30872	0.67230	1.30994	0.23742	1.31400
IVM(%)	0.39433	0.558053	0.32635	0.42115	0.17638	0.42085	0.15994	0.41956
OBF	2.75598	1.9286	1.08852	1.76619	1.07394	1.76661	0.57306	1.76479

Tabela 1 Resultados simulação 2.1

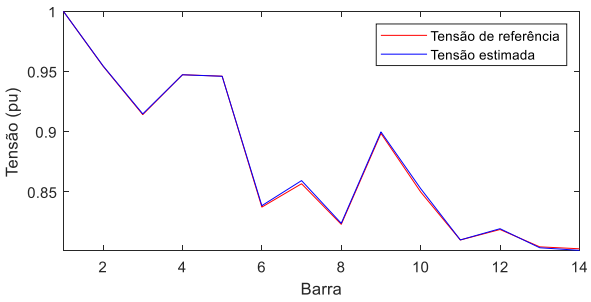

Figura 4 Tensão em todas as barras para 2 PMUs instaladas

A partir de 2 PMU's, o GWO apresentou excelente desempenho com resultados melhores que o E-OPF, tanto no SEE quanto no OBF (objective function). A Figura 4 apresenta o comparativo das tensões estimadas e obtidas pelo fluxo de potência.

4.2.2 Simulação 2.2 – Minimização do OBF

Nesta etapa foi realizada a minimização do OBF que é constituído da soma dos índices SEE, IPA e IVM. A Tabela 2 apresenta os resultados.

Nº de PMU's	1		2		3		4	
Localização	11		6-14		8-9-14		2-10-12-13	
Algoritmo	GWO	E-OPF	GWO	E-OPF	GWO	E-OPF	GWO	E-OPF
IPA(CRAD)	0.34219	0.03754	0.34522	0.02671	0.08951	0.02671	0.10544	0.02674
SEE(%)	2.88740	1.31020	1.68080	1.32894	0.51269	1.31851	0.48999	1.31674
IVM(%)	0.61355	0.420989	0.40061	0.40862	0.33859	0.40422	0.26024	0.40046
OBF	3.84314	1.7687	2.42663	1.76427	0.94079	1.74943	0.85567	1.74394

Tabela 2 Resultados simulação 2.2

O GWO apresentou desempenho muito superior que o E-OPF a partir da instalação de 3PMUs. Isto aponta o E-OPF como um melhor estimador para casos onde houver baixa redundância nas medições. Entretanto, casos onde há boa redundância o GWO se mostra superior. A Figura 5 apresenta o comparativo da evolução do índice OBF ao variar o número de PMUs instaladas no sistema.

O tempo médio de execução do estimador para o Sistema de 14 barras foi de 16,25s. Este tempo é considerado alto quando comparado a outros estimadores e considerando a filosofia de um estimador. Entretanto, ele pode ser melhorado utilizando processadores mais potentes e dedicados somente a esta atividade.

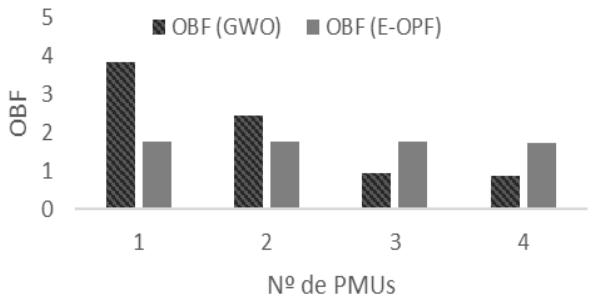

Figura 5 Evolução do OBF com a variação de PMUs

Nº de PMU's	1		2		3		4	
Localização	8		12-32		4-13-27		7-14-26-27	
Algoritmo	GWO	E-OPF	GWO	E-OPF	GWO	E-OPF	GWO	E-OPF
IPA(CRAD)	0.47512	0.04842	0.08525	0.04015	0.18443	0.00703	0.08136	0.00737
SEE(%)	1.86880	2.08530	1.98000	2.01847	0.78434	2.04097	0.10238	2.03162
IVM(%)	0.31969	0.464907	0.57989	0.40614	0.25916	0.40476	0.065062	0.40716
OBF	2.66361	2.5986	2.645144	2.46476	1.22793	2.45276	0.248802	2.44615

Tabela 3 Resultados simulação 3

4.3 Teste 3 – Sistema de 33 barras com múltiplas PMUs

Análogo ao que foi feito para o sistema de 14 barras, o estimador foi testado para o sistema de 33 barras. Variou-se o número de PMUs de 1 a 4 minimizando o OBF. Os resultados comparativos são apresentados na Tabela 3.

Conforme explanado anteriormente para o processo de estimação de estado o plano de medições é de extrema importância. No presente trabalho este envolve a utilização de pseudomedidas na inicialização dos indivíduos com alta margem de erro, isto é, baixa precisão, uma vez que são baseadas em dados históricos. Isto garante a observabilidade do sistema mesmo com número reduzido de PMUs no sistema.

5 Conclusão

A aplicação da meta-heurística Grey Wolf Optimizer (GWO) para o problema de estimação de estados em sistemas elétricos de potência (SEP) demonstrou resultados promissores, revelando-se uma alternativa eficaz e competitiva. Os resultados obtidos destacam a capacidade do GWO de melhorar a eficiência da estimação quando há um aumento na redundância das medições disponíveis. Esse aumento na redundância, alcançado pela instalação de um número de PMUs, revelou-se crucial para aprimorar a precisão das estimativas de estado. Além disso, o GWO demonstrou excelente desempenho em diversos cenários de carga do sistema, evidenciando sua capacidade de adaptação e robustez. No entanto, um ponto de melhoria identificado é o tempo de execução do estimador, que foi considerado ineficiente em comparação com outros métodos. No entanto, esta questão pode ser mitigada com o uso de processadores mais potentes dedicados ao problema.

Para futuros trabalhos, sugere-se investigar estratégias para otimizar ainda mais o desempenho do estimador, bem como explorar diferentes abordagens para a alocação ótima de PMUs, visando alcançar resultados ainda

mais precisos e eficientes. Ainda, propõe-se que o método apresentado seja avaliado para um sistema trifásico, tendo em vista as particularidades existentes nestes sistemas. Adicionalmente, consideração de erros grosseiros é incluída pelos autores como proposta.

AGRADECIMENTOS

Os autores gostariam de agradecer ao suporte do Conselho Nacional de Pesquisa e Desenvolvimento (CNPq), Instituto Brasileiro de Ciência e Tecnologia em Energia Elétrica (INERGE), FAPEMIG, CAPES, aos grupos de pesquisa GOPT e SMART4GRIDS, e à "Red para la integración a gran escala de energías renovables en los sistemas eléctricos (RIBIERSE-CYTED)".

REFERÊNCIAS

Abur, A., & Exposito, A. G. (2004). Power system state estimation: theory and implementation. CRC press.

Andic, C., Ozturk, A., & Turkay, B. (2023). Power system state estimation using a robust crow search algorithm based on PMUs with limited number of channels. Electric Power Systems Research, 217, 109126.

Asada, E. N., Garcia, A. V., & Romero, R. (2005, June). Identifying multiple interacting bad data in power system state estimation. In IEEE Power Engineering Society General Meeting, 2005 (pp. 571-577). IEEE.

Baran, M. E., & Kelley, A. W. (1994). State estimation for real-time monitoring of distribution systems. IEEE Transactions on Power systems, 9(3), 1601-1609.

Baran, ME e Wu, FF (1989). Reconfiguração de redes em sistemas de distribuição para redução de perdas e balanceamento de carga. Transações IEEE sobre entrega de energia , 4 (2), 1401-1407.

Bi, T. S., Qin, X. H., & Yang, Q. X. (2008). A novel hybrid state estimator for including synchronized phasor measurements. Electric Power Systems Research, 78(8), 1343-1352.

Civanlar, S., Grainger, J. J., Yin, H., & Lee, S. S. H. (1988). Distribution feeder reconfiguration for loss reduction. IEEE Transactions on Power Delivery, 3(3), 1217-1223.

COSTA, A. S., MEYER, B. T., & DECKER, I. C. (2008). Análise dos benefícios de medições fasoriais sincronizadas quanto ao desempenho da estimação de estados em sistemas de potência. In XVII Brazilian Conference on Automatic Control. sn.

da Cunha, H. O. (2022). Detecçao e descarte de erros grosseiros obtidos na estimaçao de estado em linhas de transmissao. Revista de Engenharia e Tecnologia, 14(3).

Duque, F. G., de Oliveira, L. W., de Oliveira, E. J., & Augusto, A. A. (2017). State estimator for electrical distribution systems based on an optimization model. Electric Power Systems Research, 152, 122-129.

Ehrensperger, J. G. (2004). *Sistemas de medição fasorial sincronizada: análise do estado da arte e aplicações no monitoramento de sistemas de energia elétrica* (Doctoral dissertation, Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia Elétrica.).

Kumar, A., & Chakrabarti, S. (2011, December). ANN-based hybrid state estimation and enhanced visualization of power systems. In ISGT2011-India (pp. 78-83). IEEE.

Lu, C. N., Teng, J. H., & Liu, W. H. (1995). Distribution system state estimation. IEEE Transactions on Power systems, 10(1), 229-240.

Mallick, S., Ghoshal, S. P., Acharjee, P., & Thakur, S. S. (2013). Optimal static state estimation using improved particle swarm optimization and gravitational search algorithm. International Journal of Electrical Power & Energy Systems, 52, 254-265.

Melo, I. (2022). Estimaçao de estados: uma abordagem sistêmica sobre qualidade de energia. Sao Paulo, BR: Edgard Blucher.

Mingorança, J. S., de Melo, I. D., Antunes, M. P., de Oliveira, B. C., & de Souza, M. A. (2022). Uma nova abordagem para correção de erros grosseiros em estimação de estados utilizando algoritmo genético. Simpósio Brasileiro de Sistemas Elétricos-SBSE, 2.

Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. Advances in engineering software, 69, 46-61.

Monticelli, A. (2012). State estimation in electric power systems: a generalized approach. Springer Science & Business Media.

Monticelli, A. J. (1983). Fluxo de carga em redes de energia elétrica. E. Blucher.

Mukherjee, S., & Roy, P. K. (2020). State Estimation of Power Using the Whale Optimization Algorithm. International Journal of Applied Metaheuristic Computing (IJAMC), 11(4), 194-213.

Naveenkumar, K., Kannan, R., Ganesan, S., Subramanian, S., & Hariprasath, M. (2020). Distribution system state estimation with elegant PMU placements using a novel metaheuristic. International Journal of Smart Grid and Green Communications, 2(1), 38-59.

Neto, I., & Salem, M. (2017). Estimação de estado para redes de distribuição de energia elétrica avançadas (Doctoral dissertation, Universidade de São Paulo).

Phadke, A. G. (1993). „Time synchronizing techniques, coupled with the computer-based measurement techniques, provide a novel opportunity to measure phasors and phase angle differences in real time ". IEEE Computer Applications in Power, 10-15.

Schweppe, F. C., & Rom, D. B. (1970). Power system static-state estimation, Part II: Approximate model. IEEE Transactions on Power Apparatus and Systems, (1), 125-130.

Schweppe, F. C., & Wildes, J. (1970). Power system static-state estimation, Part I: Exact model. IEEE Transactions on Power Apparatus and systems, (1), 120-125.

Selvi, K., Ramara, N., & Kumar, M. S. (2005). Application of genetic algorithm for power system state estimation. IE (1) Journal-CP.

Shweppe, F. C. (1970). Power system static-state estimation, part i-iii. IEEE Trans. Power Apparatus System, 89(1), 120-135.

Tungadio, D. H., Numbi, B. P., Siti, M. W., & Jimoh, A. A. (2015). Particle swarm optimization for power system state estimation. Neurocomputing, 148, 175-180.