

Obtenção de planos de medição observáveis para estudos de estimação de estado

Lucas Tito Carmona

Universidade Federal Fluminense
Niterói - Rio de Janeiro
lucastc@id.uff.br

Rainer Zanghi

Universidade Federal Fluminense
Niterói - Rio de Janeiro
rzanghi@id.uff.br

Julio Cesar Stacchini de Souza

Universidade Federal Fluminense
Niterói - Rio de Janeiro
julio@ic.uff.br

Andre Abel Augusto

Universidade Federal Fluminense
Niterói - Rio de Janeiro
aaaugusto@id.uff.br

RESUMO

Ao longo das últimas décadas diversos métodos têm sido propostos para corrigir problemas que afetam a confiabilidade da função *Estimação de Estado* (EE), a maioria com foco na garantia da observabilidade e no tratamento de erros grosseiros. É importante que a eficácia dos métodos propostos seja avaliada para diferentes planos de medição, uma vez que a redundância e a localização das medidas podem ter influência significativa no desempenho de tais métodos e da própria função EE. Neste trabalho, o conjunto de planos de medição é obtido através de um método sistemático com base no *Algoritmo Genético* (AG). São avaliadas diferentes abordagens na sintonia dos parâmetros do processo de obtenção de planos. Por fim, são propostos métodos capazes de extrair uma base diversa além de propor um critério de parada, que utiliza inferência bayesiana para estimar a quantidade de planos observáveis. Resultados e avaliações são obtidos com a rede IEEE-14 barras.

PALAVRAS CHAVE. Estimação de Estado. Observabilidade. Algoritmo Genético.

Engenharia Elétrica, Otimização, Mineração de dados

ABSTRACT

Over the last few decades, several methods have been proposed to correct problems that affect the reliability of the *State Estimation* (SE) function, most of them focusing on ensuring observability and treating gross errors. It is important that the effectiveness of the proposed methods is evaluated for different measurement planes, since redundancy and location of measurements can have a significant influence on the performance of such methods and the SE function itself. In this work, the set of measurement plans is obtained through a systematic method based on the *Genetic Algorithm* (GA). Different approaches to tuning the parameters of the plan obtaining process are evaluated. Finally, methods capable of extracting a diverse base are proposed in addition to proposing a stopping criterion, which uses Bayesian inference to estimate the number of observable planes. Results and evaluations are obtained with the IEEE-14 network.

KEYWORDS. First keyword. Second keyword. Last keyword.

Electrical Engineering, Optimization, Data Mining

"Este trabalho foi realizado com o apoio da Fundação de Amparo à Pesquisa do Estado do Rio de Janeiro (FAPERJ), processos nº E-26/211.233/2019 e E-26-010-101251-2018."

1. Introdução

A supervisão de sistemas elétricos de potência depende do sucesso da utilização da função EE, a qual é essencial para a rede elétrica [ONS, 2023]. A EE por sua vez, requer que a redundância de medidas e sua distribuição pela rede elétrica sejam adequadas. Diversos trabalhos são encontrados na literatura propondo métodos para lidar com problemas que podem ser enfrentados pela EE, a maioria deles relacionados à manutenção da observabilidade, conforme visto em Alguacil et al. [2023], e ao tratamento de erros nos dados, sejam estes erros grosseiros de medidas, analisados em [Ascari e Costa, 2024], de topologia, [Soltani et al., 2023], como também em [Crawford e Baran, 2022], ou de parâmetros, [Conte et al., 2020].

Uma mesma redundância global para a EE pode estar associada a configurações diferentes do sistema de medição, ou seja, a diferentes localizações de um conjunto de *Unidades de Medição* (UMs). As UMs podem contemplar medidas de injeção e fluxos de potência, magnitudes de tensão, e, no caso de unidades de medição fasorial, também medidas de fasores de corrente e tensão. Portanto, quando se deseja analisar o comportamento da EE frente a um plano de medição que possui uma determinada redundância, diferentes planos de medição, de igual redundância, podem ser selecionados para teste. Vale ressaltar que a localização das medidas pode influenciar significativamente o desempenho da EE em diferentes situações, uma vez que uma mesma redundância global pode estar associada a diferentes condições de redundância local para cada plano de medição. Logo, é interessante que a robustez de métodos propostos seja avaliada considerando não apenas planos de medição de diferentes redundâncias globais, mas também diferentes planos de medição para cada nível de redundância. Além de ter um método sistemático capaz de identificar um conjunto de planos de medição que atenda certos critérios (como, por exemplo, o nível de redundância pré-estabelecido), os parâmetros e operadores do método devem estar otimizados para que seja possível diversificar o processo de busca de planos diferentes entre si em um tempo computacional adequado.

A obtenção de planos de medição tem uma natureza combinatória e requer um processo de busca que depende de um algoritmo capaz de encontrar soluções que sejam representativas do espaço de soluções como um todo. O AG possui operadores genéticos que podem ser ajustados a fim de permitir que o algoritmo identifique planos de medição diferentes entre si, ou seja, percorrendo diferentes regiões do espaço de soluções, conforme visto em [Davis, 1991] e [Theodorakatos et al., 2014].

O presente artigo analisa o processo de ajuste dos parâmetros relacionados ao AG que compõem o processo de busca sistematizado para a obtenção de planos de medição observáveis e distintos. Além disso, avalia métodos de parada para garantir a convergência do AG em um tempo computacional adequado, mas garantindo a formação de uma base representativa de planos observáveis. Resultados de testes obtidos através da rede IEEE 14 barras são apresentados para ilustrar os efeitos do ajuste *offline* dos parâmetros relacionados ao AG e a avaliação do critério de parada, atualizado de forma *online*.

O restante deste artigo está estruturado da seguinte forma. A Seção 2 introduz os principais conceitos sobre a EE. A Seção 3 descreve brevemente sobre o Algoritmo Genético, que é o responsável direto pela obtenção dos planos de medição observáveis. Tanto o método de busca para identificação de planos de medição observáveis quanto a metodologia para sintonização dos parâmetros são apresentados na Seção 4. Os resultados e avaliações são discutidos na Seção 5. Por fim, a Seção 6 analisa a aplicabilidade do modelo utilizado.

2. Estimação de Estado

O supervisionamento completo depende de que toda a rede elétrica seja observável, ou seja, se é possível obter todos os estados da rede a partir do plano de medição fornecido, segundo [Abur e Expósito, 2004]. Entende-se como estado, as medidas de grandezas elétricas, tais

como tensão nas barras, corrente elétrica e fluxo de potência ativa/reativa nos ramos e injeções de potência nas barras. A observabilidade de um sistema depende do conjunto de medidas disponíveis na base de dados e da topologia da rede.

O plano de medição indica a localização (barra) e o tipo de grandeza medida de todos os medidores, definindo o nível de redundância do sistema, onde a redundância é o excesso entre a quantidade de medidas coletadas na rede e a quantidade total de variáveis de estado a estimar. Quanto maior o nível de redundância, maior será a confiabilidade da EE. Embora representem uma redução de custo, níveis baixos podem causar a inobservabilidade da rede.

A análise da observabilidade começa com a elaboração da matriz jacobiana H . A EE linear simplifica o desenvolvimento da matriz jacobiana, permitindo que somente as medidas de injeção e fluxo de potência ativa sejam utilizadas.

As equações (1) e (2) são referentes às medidas de fluxo de potência ativa e representam a matriz jacobiana H no modelo linear. Já as equações (3) e (4) relacionam-se com as medidas de injeção de potência ativa. Nota-se que a equação (4), que é a componente da matriz H relacionada a injeção de potência ativa/reativa, é equivalente a equação (2) (componente da matriz H relacionada ao fluxo de potência ativa/reativa).

$$H(l, i) = b_{ik} \quad (1)$$

$$H(l, k) = -b_{ik} \quad (2)$$

$$H(l, i) = \sum_k b_{ik}, i \neq k \quad (3)$$

$$H(l, k) = -b_{ik} \quad (4)$$

Onde, l é o índice da medida, i é a "barra origem", k é a "barra destino" e b_{ik} é a susceptância presente entre as barras i e k .

Como a análise da observabilidade do sistema é vista como um problema estrutural, considera-se as susceptâncias b_{ik} iguais a 1 nas equações (1) à (4).

A observabilidade do sistema é garantida se a matriz de ganho, calculada através da equação (5), for inversível, conforme visto em [Filho et al., 2009]. Assim, o determinante dessa matriz deve ser diferente de zero.

$$G = H^t H \quad (5)$$

Onde, G é a matriz de ganho, H é a matriz jacobiana.

3. Algoritmo Genético

Os *Algoritmos Genéticos* (AGs) são meta-heurísticas que permitem gerar e selecionar boas soluções dos problemas analisados. Cada solução é também chamada de indivíduo e suas características são codificadas em um cromossomo para que seja possível utilizar operadores inspirados nos processos de Seleção Natural. Esses operadores atuam sobre uma população de indivíduos, utilizando características de diversas soluções para identificar uma solução otimizada.

A Figura 1 apresenta, de forma simplificada, as etapas do AG utilizado no problema proposto desse artigo, conforme visto em [Davis, 1991]. A primeira etapa consiste em inicializar uma população de soluções de forma aleatória utilizando uma distribuição normal. O processo continua e cada indivíduo é avaliado através da função de aptidão. Após essa etapa, é realizada a seleção dos indivíduos pelo método do torneio, conforme proposto em [Goldberg e Deb, 1991]

Os operadores de cruzamento e mutação podem ser executados a fim de controlar a diversidade da população. Os ajustes dos operadores possibilitam que o AG percorra o espaço de soluções e não fique preso em soluções ótimas locais. Caso o critério de parada seja atendido, o AG é encerrado. Caso contrário, é utilizado outro operador para controlar a diversidade da população, que mantém o indivíduo de elite e repopula os demais de forma aleatória caso a população da geração atual seja similar à população da geração anterior. Durante o processo de elitismo é realizada a identificação dos indivíduos mais aptos, que preserva as soluções mais promissoras para a próxima geração.





Figura 1: Etapas do Algoritmo Gen tico

4. Metodologia proposta

4.1. Codifica o da solu o

Os planos de medi o s o codificados em vetores bin rios e cada  ndice do vetor corresponde   posi o da barra da respectiva rede analisada. Quando uma *Unidade de Medi o* (UM)   inserida em determinada barra, o valor 1   atribu do ao respectivo  ndice. J  quando determinado  ndice do vetor est  preenchido com o valor bin rio 0, n o h  UM alocada nessa barra. Considera-se que quando uma UM est  presente em uma determinada barra, h  medida de inje o de pot ncia na barra e medidas de fluxo de pot ncia em todos os ramos nela incidentes, tomadas no lado da barra. A Figura 2 ilustra um plano de medi o com uma quantidade de 3 UMs alocadas na rede IEEE-6 barras.



(a) Rede IEEE-6 barras

1	2	3	4	5	6
1	0	1	0	0	1

(b) Codifica o bin ria do plano de medi o

Figura 2: Processo de codifica o

4.2. Fun o de aptid o

A fun o de aptid o utilizada para avaliar os planos de medi o   apresentada na equa o 6.

$$F.A_i = Qtd.Zeros_i \times c_1 + Observabilidade_i \times c_2 \quad (6)$$

Em que i é o i -ésimo plano de medição avaliado, $Qtd.Zeros_i$ contabiliza a quantidade de colunas com todos os termos iguais a zero na matriz jacobiana H . Já o termo $Observabilidade_i$ é uma variável binária que indica se o plano de medição é observável ou não. O primeiro e o segundo termo da equação (6) são ponderados empregando-se os pesos c_1 e c_2 respectivamente.

A avaliação da observabilidade dos planos de medição só é realizada se sua matriz jacobiana H não possuir colunas com termos iguais a zero, pois, caso contrário, o plano de medição será considerado inobservável. Essa estratégia é utilizada para diminuir o esforço computacional no cálculo do determinante da matriz vista na equação 5. A quantidade de colunas com todos os termos iguais a zero indica o quão distante o plano está de ser observável.

4.3. Armazenamento e agrupamento dos planos de medição

A tabela hash empregada neste trabalho permite a consulta rápida dos planos armazenados e o armazenamento exclusivo de planos de medição observáveis e distintos entre si. Cada plano de medição é convertido de binário para real e, posteriormente, seu índice na tabela é calculado como o resto da divisão entre o valor real e a dimensão da tabela pré-definida.

Para inserir um novo plano de medição na Tabela Hash, é crucial garantir que o elemento da tabela apontado pelo índice esteja vazio, ou seja, o valor desse elemento deve ser igual a zero. Essa condição assegura que o plano de medição não foi analisado e evita a sobrescrita de planos previamente armazenados.

O agrupamento dos planos de medição é realizado através do algoritmo hierárquico aglomerativo, visto em Duda et al. [2012]. O método cria diversos *clusters*, sendo que cada um deles contém planos de medição com um determinado grau de diversidade. Esse grau corresponde a uma certa distância de Hamming entre eles, que pode ser pré-definida. Esse índice de dissimilaridade garante a identificação de planos de medição com UMs dispostas em barras diferentes.

4.4. Fluxograma do Método de Busca

A Figura 3 apresenta o fluxograma do processo de busca. A primeira etapa consiste em inicializar os parâmetros, que são: quantidade de agrupamentos, que atende a distância de Hamming idealizada, o total de planos de medição desejados, o valor da distância de Hamming para identificar planos que possuem certo grau de variabilidade e os parâmetros do AG. Além disso, é nessa parte que a tabela hash é inicializada.




Figura 3: Metodologia para identificação de planos de medição

O processo de busca se inicia pelo AG, cujas etapas mais detalhes são vistas na Figura 1. Ao avaliar a função de aptidão, é analisado se o plano de medição é observável ou não. Caso seja e esse plano não esteja presente na tabela Hash, o mesmo é lá armazenado. Quando o critério de parada é atingido, o processo de busca é encerrado. Assim, com uma base de planos observáveis e distintos já formada, o algoritmo hierárquico agrupa os planos e permite a identificação de *clusters* para diferentes distâncias de Hamming.

Ao fim do processo de agrupamento, o método apresenta como resposta um conjunto de planos de medição observáveis e diferentes entre si, para níveis de redundância (quantidades pré-definidas de UMs presentes) distintos e considerando diferentes graus de diversidade (expressos pelas distâncias de Hamming entre os planos de medição).

A partir do método sistemático, ilustrado na Figura 3 para a obtenção de planos de medição observáveis distintos (para diferentes níveis de redundância), avalia-se os operadores do AG e o tamanho da população, parametrizados de forma *offline*. O objetivo é mensurar a diversidade e se é possível obter uma base robusta de planos observáveis no processo de busca antes de realizar o agrupamento em *clusters*. Além disso, é avaliado se o critério de parada também é capaz de obter uma base de planos robusta em um tempo computacional adequado quando estima-se a quantidade de planos de medição observáveis.

4.5. Ajuste dos parâmetros *offline* do AG

O processo de obtenção de planos de medição observáveis é avaliado à medida que o tamanho da população é alterado. O objetivo é analisar como essa variação afeta o processo evolutivo, visando tanto medir o tempo computacional necessário para formar a base de planos de medição quanto avaliar os impactos da diversidade em cada geração para diferentes tamanhos de população.

Os parâmetros relacionados as taxas de cruzamento e mutação são ajustados com objetivo de avaliar a diversidade durante o processo de obtenção de planos de medição observáveis. Assim, são avaliados se a base de planos de medição é significativa e se durante cada iteração, os operadores são capazes de ampliar a diversidade no processo de busca e garantir a convergência do AG. Para cada valor atribuído às taxas de cruzamento e mutação, avaliam-se os valores médios e o desvio padrão, com o objetivo de identificar os melhores resultados que garantam a diversidade no processo de busca e a obtenção de uma base significativa de planos observáveis em tempo adequado.

4.6. Estimativa dos Planos de Medição observáveis

Como o espaço de soluções contém tanto planos de medição observáveis quanto inobserváveis, foi estimada a quantidade de planos observáveis de forma empírica por inferência bayesiana [Gelman et al., 2013] durante a execução do método de busca, ou seja, de forma *online*. Tal estratégia servirá como base para definir o critério de parada e a modelagem da tabela hash.

A estimativa baseia-se em avaliar um conjunto de planos de medição inicializados de forma randômica obtidos pela distribuição uniforme, a qual utilizou-se o método de Monte Carlo [Caldeira e Vieira, 2024]. Tal estimativa baseia-se em um processo iterativo, onde a cada iteração é atualizado o valor estimado de planos de medição observáveis. Inicialmente, obtêm-se os parâmetros *alfa* e *beta* da distribuição beta do conjunto de planos de medição gerados de forma aleatória. A partir dessa etapa, são calculados, para cada iteração, os mesmos parâmetros a posteriori. Por fim, é realizada a estimativa total dos planos de medição observáveis, conforme a equação (7). A fim de garantir a confiabilidade no processo de estimação por inferência bayesiana, esse processo se repete por n iterações, a qual os dados a posteriori da interação $n - 1$ são utilizados como valores a priori na interação n .

$$Estimativa_{obs} = Planos_{Total} \cdot \left(1 - \frac{alfa_p}{alfa_p + beta_p}\right) \quad (7)$$

Onde, $Planos_{Total}$ é a combinação simples de planos de medição que podem ser adotados na rede IEEE-14 barras para uma quantidade pré-definida de UMs. Já os parâmetros a posteriori $alfa_p$ e $beta_p$ são obtidos durante o processo de estimação.

A avaliação baseia-se na comparação entre a média da estimativa de planos observáveis e o total de planos observáveis obtidos por meio de um método exaustivo, que encerra o processo de busca quando não seja mais possível identificar planos observáveis após determinado número de gerações.

4.7. Critério de Parada

O critério de parada pode encerrar o AG de forma prematura, não identificando uma quantidade suficiente de planos de medição observáveis. Além disso, caso o critério de parada seja superdimensionado, o tempo computacional para obtenção dos planos de medição observáveis pode ser extremamente longo. Assim, é avaliado um critério de parada com o objetivo de obter uma base de planos observáveis representativa, ou seja, capaz de fornecer uma quantidade suficiente de planos para análise a posteriori. Além disso, tal base deve ser obtida em um tempo computacional adequado.

O critério de parada a ser avaliado baseia-se em encerrar o AG caso pelo menos uma das três seguintes condições ocorra: a variação de planos de medição observáveis novos inseridos na base de dados seja inferior a um certo limiar; a quantidade total de planos de medição inseridos na tabela hash seja igual ao valor estimado de planos observáveis (visto na equação (7)); ou o AG não seja capaz de identificar planos distintos após determinado número de gerações.

O critério de parada proposto é avaliado pela comparação com o critério de parada que encerra o AG quando não há inserção de novos planos de medição observáveis após determinado número de gerações (método exaustivo).

5. Testes e resultados

A quantidade de planos observáveis, o tempo de processamento e a quantidade de gerações são indicados pelo valor médio (μ) e o desvio padrão (σ) em cada tabela presente nessa seção. O parâmetro n é a razão entre a quantidade média de planos observáveis obtida e o tempo médio relacionado ao processo de extração de planos observáveis.

A Tabela 1 ilustra os valores médios e os respectivos desvios padrões quando se varia a população entre 100, 500 e 1000 indivíduos e se mantém a taxa de cruzamento e mutação fixas em 90% e 10% respectivamente.

Tabela 1: Variação do tamanho da população no processo de obtenção de planos observáveis

População		100		500		1000	
Redundância	Parâmetro	μ	σ	μ	σ	μ	σ
6	Qtd. Planos Obs.	328	6	334	0	342	0
	Tempo (s)	11	2	19	2	26	4
	Gerações	108	15	38	5	25	3
	n	30		18		13	
7	Qtd. Planos Obs.	976	7	989	1	972	0
	Tempo (s)	19	2	31	3	39	444
	Gerações	181	21	59	6	36	4
	n	51		32		25	
8	Qtd. Planos Obs.	1512	7	1492	1	1481	0
	Tempo (s)	23	2	39	6	43	4
	Gerações	203	20	66	8	38	3
	n	67		39		34	
9	Qtd. Planos Obs.	1348	3	1382	1	1378	0
	Tempo (s)	11	1	30	3	39	1
	Gerações	167	18	52	6	33	3
	n	128		46		35	

O tamanho da população não foi relevante na obtenção de planos observáveis, já que a dimensão do sistema elétrico é pequena. Assim, optou-se pela população com 500 indivíduos, visto

que a perda no tempo de processamento para cada população é baixa.

A Tabela 2 ilustra os resultados quando mantém-se fixo a população com 500 indivíduos, a taxa de mutação igual a 10% e varia a taxa de cruzamento. Os resultados indicam que a medida que a taxa de cruzamento decai, o tempo computacional para formação da base de planos observáveis aumenta. Essa análise pode ser vista também pelo parâmetro n , já que a taxa de planos observáveis obtidos por segundo é reduzida à medida que a taxa de cruzamento decresce.

Tabela 2: Variação da taxa de cruzamento


Taxa de Cruzamento		90%		50%		0%	
Redundância	Parâmetro	μ	σ	μ	σ	μ	σ
6	Qtd. Planos Obs.	334	0	350	1	338	2
	Tempo (s)	5	1	7	1	11	2
	Gerações	39	5	49	8	80	14
	n	62		50		31	
7	Qtd. Planos Obs.	988	1	981	1	960	3
	Tempo (s)	8	1	11	2	17	2
	Gerações	58	5	13	12	117	16
	n	121		90		57	
8	Qtd. Planos Obs.	1496	1	1516	2	1495	3
	Tempo (s)	10	1	13	1	18	2
	Gerações	64	7	86	9	119	14
	n	157		119		85	
9	Qtd. Planos Obs.	1361	0	1360	1	1375	2
	Tempo (s)	8	1	11	1	16	2
	Gerações	52	5	71	1	104	12
	n	161		120		85	

A Figura 4a ilustra a extração de planos para diferentes taxas de cruzamento quando o nível de redundância é igual a 8. Conforme a taxa de cruzamento eleva-se, a convergência no processo de obtenção de planos observáveis torna-se mais rápida e o AG não fica preso em mínimos locais. Já a Figura 4b ilustra a inserção de planos distintos por geração. Os resultados apresentados indicam que a taxa de cruzamento adequado para o processo de obtenção de planos é equivalente a 90%.


A Tabela 3 ilustra os resultados quando varia a taxa de mutação em 10%, 5% e 0%. Além disso, tanto a população quanto a taxa de cruzamento estão fixas em 500 indivíduos e 90%, respectivamente. Considerando os resultados similares apresentados na Tabela 3, não é possível assegurar o valor mais adequado para o operador de mutação. As Figuras 5a e 5b ilustram o papel do operador de mutação no processo de obtenção de planos de medição observáveis. Esse operador desempenha um papel complementar a taxa de cruzamento e realiza uma perturbação controlada para garantir a diversidade durante o processo evolutivo. Assim, os resultados indicam que o aumento da taxa resulta na capacidade do operador introduzir pequenas mudanças aleatórias em indivíduos existentes para gerar novas variações que podem explorar novas regiões do espaço de busca.

A Tabela 4 compara a estimativa média de planos observáveis obtidos, após 20 execuções, com a quantidade média de planos obtida após executar o AG pelo método exaustivo.

Os resultados presentes na Tabela 4 indicam valores estimados similares à quantidade total de planos de medição observáveis obtidos pelo método exaustivo. Pela similaridade do valor estimado com a quantidade de planos obtidos pelo método exaustivo, é possível utilizar a estimativa



(a) Quantidade total de Planos observáveis obtidos



(b) Planos de medição observáveis por geração


Tabela 3: Variação da taxa de Mutação

Taxa de Mutação		10%		5%		0%	
Redundância	Parâmetro	μ	σ	μ	σ	μ	σ
6	Qtd. Planos Obs.	334	0	334	1	342	1
	Tempo (s)	5	1	5	1	5	1
	Gerações	39	5	40	4	38	7374
	n	62		63		68	
7	Qtd. Planos Obs.	988	1	973	1	988	1
	Tempo (s)	8	1	9	2	9	1
	Gerações	58	5	61	9	63	6
	n	121		104		109	
8	Qtd. Planos Obs.	1496	1	1506	1	1480	1
	Tempo (s)	10	1	10	1	11	1
	Gerações	64	7	66	6	73	8
	n	157		154		136	
9	Qtd. Planos Obs.	1361	0	1383	1	1367	1
	Tempo (s)	8	1	9	1	10	1
	Gerações	52	5	55	6	61	6
	n	161		158		142	

para dimensionar o tamanho da tabela hash. Além disso, os resultados obtidos permitem a adoção da estimativa como critério de parada.

A Tabela 5 ilustra os resultados (para o nível de redundância igual a 8) do método que possui os parâmetros do AG sintonizados e o critério de parada baseado na inserção de novos planos, na convergência do AG e na estimativa de planos observáveis (Método 1). A segunda abordagem (Método 2) considera uma estratégia baseada na geração randômica de planos de medição sem a utilização de operadores que contralam a diversidade (cruzamento e mutação). Além disso, tal método encerra o processo de busca quando não é possível identificar novos planos distintos após certo número de gerações.

Os resultados indicam que a utilização dos operadores que garantam a diversidade, o ajuste dos parâmetros de tais operadores e a adoção do critério de parada proposto permitem a



(a) Quantidade total de Planos observáveis obtidos quando varia a taxa de mutação



(b) Planos de medição observáveis por geração quando varia a taxa de mutação

Tabela 4: Estimativa de planos observáveis e inobserváveis na rede IEEE-14

Redundância	6		7		8		9	
Parâmetro	μ	σ	μ	σ	μ	σ	μ	σ
Planos observáveis (Estimado)	354	12	1022	27	1552	25	1426	12
Planos observáveis (Total)	359	1	1023	5	1546	4	1427	8
Planos (Total)	3003	-	3432	-	3003	-	2002	-

Tabela 5: Comparação entre o método inteligente com o método exaustivo


Redundância	Método 1		Método 2	
Parâmetro	μ	σ	μ	σ
Qtd. Planos Obs.	1480	9	1495	3
Tempo (s)	6	0,6	23	2
Gerações	36	3	150	14
n	247		65	

extração de uma base representativa de planos de medição observáveis em um tempo computacional adequado. O parâmetro n indica que foi possível obter mais planos observáveis por segundo quando as estratégias propostas foram adotadas. Ademais, tanto a Figura 6a quanto a Figura 6b confirmam que o método 1 garantiu a convergência mais rápida em relação a um método que somente gera planos aleatórios.

6. Conclusão

Nos estudos realizados com a finalidade de avaliar o método de obtenção de planos de medição observáveis pelo AG, a partir de diferentes níveis de redundância, torna-se necessário analisar os parâmetros que compõem o método de busca: o tamanho da população, os operadores que controlam a diversidade e o critério de parada. A utilização dos parâmetros corretos permitem a convergência rápida do AG e a diversidade do processo de busca, resultando em uma base de planos representativa.

Este trabalho avaliou diferentes parâmetros relacionados com os operadores do AG além de propor um critério de parada baseado tanto na presença de novos planos na base quanto na



(a) Quantidade total de Planos observáveis obtidos para diferentes métodos



(b) Planos de medição observáveis por geração para diferentes métodos

estimativa de planos observáveis. Os resultados indicaram uma maior eficiência na obtenção de planos na rede IEEE-14 barras quando os parâmetros são sintonizados para garantir a convergência rápida da base e quando o critério de parada proposto é adotado.

Conclui-se que além de ter um método flexível para obtenção de planos de medição observáveis, devem-se utilizar estratégias capazes de obter uma base de dados diversa em um tempo computacional adequado. Torna-se muito mais promissor garantir a diversidade e avaliar o critério de parada durante a extração de planos do que simplesmente gerar planos de medição observáveis de forma aleatória.

Referências

- Abur, A. e Expósito, A. (2004). *Power System State Estimation: Theory and Implementation*. Power Engineering (Willis). CRC Press. ISBN 9780203913673. URL https://books.google.com.br/books?id=NQhbtFC6_40C.
- Alguacil, N., Herrero, H., e Solares, C. (2023). Observability analysis and restoration for distribution grids: A robust greedy numerical algorithm. *IEEE Transactions on Smart Grid*, 14(6): 4542–4552.
- Ascari, L. B. e Costa, A. S. (2024). A bad data resilient multisensor fusion framework for hybrid state estimation. *IEEE Transactions on Power Systems*, 39(1):132–146.
- Caldeira, A. e Vieira, W. (2024). *Método Monte Carlo de varredura de domínio (MCS)*. Editora Dialética. ISBN 9786527016984.
- Conte, F., Gabriele, B., e Schiapparelli, G.-P. (2020). Assessment of state estimation methods for power systems with uncertain parameters. In *2020 55th International Universities Power Engineering Conference (UPEC)*, p. 1–6.
- Crawford, K. e Baran, M. (2022). Improving topology error detection with distribution system state estimation. In *2022 IEEE Texas Power and Energy Conference (TPEC)*, p. 1–6.
- Davis, L. (1991). *Handbook of Genetic Algorithms*. VNR Computer Library VNR Computer Library. Van Nostrand Reinhold. ISBN 9780442001735. URL <https://books.google.com.br/books?id=Kl7vAAAAMAAJ>.

- Duda, R. O., Hart, P. E., e Stork, D. G. (2012). *Pattern Classification*. Wiley, New York, NY, 2nd edition.
- Filho, M. B. D. C., de Souza, J. C. S., e Tafur, J. E. V. (2009). Indicators of critical conditions for state estimation. In *2009 IEEE Power & Energy Society General Meeting*, p. 1–6.
- Gelman, A., Carlin, J., Stern, H., Dunson, D., Vehtari, A., e Rubin, D. (2013). *Bayesian Data Analysis, Third Edition*. Chapman & Hall/CRC Texts in Statistical Science. Taylor & Francis. ISBN 9781439840955.
- Goldberg, D. E. e Deb, K. (1991). A comparative analysis of selection schemes used in genetic algorithms. In RAWLINS, G. J., editor, *Foundations of Genetic Algorithms*, volume 1, p. 69–93. Elsevier. URL <https://www.sciencedirect.com/science/article/pii/B9780080506845500082>.
- ONS (2023). Especificação funcional: Evolução do estimador de estado reger. p. 1–19.
- Soltani, Z., Ma, S., Khorsand, M., e Vittal, V. (2023). Simultaneous robust state estimation, topology error processing, and outage detection for unbalanced distribution systems. *IEEE Transactions on Power Systems*, 38(3):2018–2034.
- Theodorakatos, N., Manousakis, N., e Korres, G. (2014). Optimal placement of pmus in power systems using binary integer programming and genetic algorithm. In *MedPower 2014*, p. 1–6.