

Abordagem baseada em Algoritmo Evolutivo Multiobjetivo e no Método de Monte Carlo para Monitoramento Otimizado de Afundamentos de Tensão em Sistemas de Distribuição de Energia Elétrica

Sávio Mota Carneiro, Antonio José de Oliveira Alves, Ricardo de Andrade Lira Rabêlo

Universidade Federal do Piauí- UFPI

saviod2@gmail.com, aj.alves@zerokol.com, ricardoalr@ufpi.edu.br

Hermes Manoel Galvão Castelo Branco

Universidade Estadual do Piauí - UESPI

hermesb@uespi.br

José de Ribamar Lima Filho

Eletróbrás Distribuição Piauí

ribamarlima@eletroraspiuai.com

Resumo – Afundamentos de tensão são uns dos mais sérios problemas de qualidade de energia elétrica enfrentados tanto pelas concessionárias quanto pelos consumidores de um Sistema Elétrico de Potência. O monitoramento constante é essencial para identificar os distúrbios existentes em um sistema de distribuição, no entanto os custos envolvidos inviabilizam o monitoramento completo do sistema, assim apenas um número reduzido de monitores estão disponíveis para cobrir a maior quantidade de eventos possíveis. Desta forma, percebe-se que a determinação dos pontos de instalação dos equipamentos é um fator crucial para o sucesso do plano de monitoramento. Neste trabalho é apresentada uma abordagem para alocação otimizada de monitores de qualidade de energia elétrica em sistemas de distribuição. Utilizou-se técnicas de otimização evolutiva multiobjetivo, mais especificamente o algoritmo *Non-Dominated Sorting Genetic Algorithm II - NSGA-II* para a resolução do problema de alocação de monitores. A modelagem adotada na formulação do problema considera apenas os aspectos relacionados aos afundamentos de tensão, desta forma, os objetivos considerados foram: maximizar a quantidade de afundamentos observados pelos monitores distribuídos no sistema e reduzir o custo desse monitoramento. A ocorrência de faltas monofásicas, bifásicas fase-fase, bifásicas fase-fase-terra e trifásicas foram consideradas na metodologia proposta e os comportamentos das frequências de cada um dos tipos de falta foram modelados usando o Método de Monte Carlo. A abordagem apresentada foi submetida aos sistemas de testes de 13 e 34 barras do IEEE, simulados no software DigSILENT Power Factory 15.1. Os resultados obtidos permitem ao usuário a escolha da solução de monitoramento que mais se adequa a sua realidade técnica e financeira, demonstrando assim a boa eficiência da metodologia proposta.

Palavras-chave – Sistemas de Distribuição, Qualidade da Energia, Alocação de Monitores, Simulação de Monte Carlo, otimização multiobjetivo e NSGA-II.

Abstract – Voltage sags are some of the most serious quality problems of electricity faced by both concessionaires as consumers of Electric Power System. Constant monitoring is essential to identify the disturbances in a distribution system, however the costs involved make impossible the complete monitoring system, as only a limited number of monitors are available to cover the largest possible number of events. Thus, it is clear that the determination of the equipment installation points is a crucial factor for the success of the monitoring plan. In this paper an approach to optimized allocation of quality monitors electricity in distribution systems is presented. We used techniques of multi-objective evolutionary optimization, specifically Non-Dominated Sorting Genetic Algorithm II algorithm - NSGA-II to solve the problem of allocation monitors. The model adopted in the problem formulation considers only those aspects related to voltage sags, therefore, considered the objectives were to maximize the amount of subsidence observed by monitors distributed in the system and reduce the cost of monitoring. The occurrence of single-phase, two-phase and three-phase faults were considered in the proposed methodology and the conduct of the frequencies of each of the fault types were modeled using the Monte Carlo method. The presented approach was subjected to IEEE test 13 and 34 nodes feeders, simulated in DigSILENT Power Factory 15.1 software. The results allow the user the choice of monitoring solution that best fits their technical and financial reality, thus demonstrating the good efficiency of the proposed methodology.

Keywords – Distribution Systems, Power Quality, Allocation Monitors, Monte Carlo simulation, Multi-Objective Optimization and NSGA-II.

1. INTRODUÇÃO

Considerando a grande quantidade de cargas não lineares e a alta suscetibilidade a distúrbios aos quais os sistemas elétricos estão sujeitos, muitos esforços foram realizados para minimizar as perturbações e perdas decorrentes da falta de Qualidade de

Energia Elétrica (QEE) [1]. Dentre esses distúrbios, os afundamentos de tensão são uns dos mais sérios problemas de QEE enfrentados tanto pelas concessionárias quanto pelos consumidores de um Sistema Elétrico de Potência (SEP) devido aos prejuízos financeiros ocasionados pelo mal funcionamento ou parada do processo industrial [2].

Levando isso em consideração, o monitoramento constante da QEE é essencial para identificar os distúrbios de QEE existentes e corrigir possíveis falhas no plano de controle desses eventos. Assim, um monitoramento eficiente pode ser utilizado em diversas aplicações, tais como: diagnóstico das condições de operação; localização de eventos associados a falta de qualidade de QE; compartilhamento de informações entre locais remotos; estudo da propagação dos eventos relacionados a QEE; avaliação dos custos envolvidos na QEE; aperfeiçoamento dos programas de manutenção preventiva, entre outros [3]. No entanto, o monitoramento completo de um SEP possui um alto custo envolvido e por questões práticas e econômicas a sua aplicação pode ser inviável [4].

Como alternativa, o monitoramento do SEP pode ser realizado considerando apenas alguns pontos estratégicos do sistema, consequentemente, um novo problema surge com essa abordagem: a identificação dos melhores pontos de monitoramento no sistema. Por questões técnicas e operacionais, no contexto da QEE, não há nenhum conhecimento prévio sobre os locais em que os monitores devem ser instalados de forma a proporcionar a melhor visão geral da situação enfrentada pelos SEP. Além disso, a maioria dos distúrbios tem um caráter estocástico, o que também dificulta um plano de monitoramento contínuo [5].

Para a identificação dos melhores pontos de monitoramento no sistema, várias metodologias de alocação otimizada de monitores de QEE em SEP's estão presentes na literatura. Por exemplo, há estudos que visam assegurar uma cobertura completa dos afundamentos de tensão [6]; outros estão voltados para a garantia da cobertura redundante no monitoramento desses eventos [7,8]; existem trabalhos que buscam empregar a alocação otimizada de monitores para identificação da localização da ocorrência de faltas [9]; há também artigos relatando a utilização de otimização da alocação para monitoramento de distorções harmônicas [10]; bem como na localização da origem de flutuações de tensão que podem ser observadas por cintilação [11].

Com base nessa revisão de literatura, um aspecto identificado foi a necessidade de sempre fornecer soluções com o menor custo possível, desconsiderando a relação custo/benefício existente entre o investimento a ser realizado e a qualidade do monitoramento resultante desse investimento. Como consequência, soluções que demandam um investimento um pouco maior, mas que, em contrapartida, possuem uma relação custo/benefício maior ou igual a solução de menor custo podem ser desprezadas.

Neste contexto, este trabalho apresenta uma abordagem multiobjetivo para resolução do problema de alocação de monitores de QEE em sistemas de distribuição (SD), considerando os afundamentos de tensão e o custo de monitoramento. Como resultado, esta abordagem fornece um conjunto de soluções ótimas que permite uma análise mais criteriosa do custo/benefício de cada cenário proposto.

O restante do artigo está organizado da seguinte forma: A Seção 2 traz alguns dos fundamentos teóricos necessários para o entendimento deste trabalho. A Seção 3 explica o funcionamento da abordagem desenvolvida. Na sequência, a Seção 4 descreve os sistemas elétricos utilizados nos testes. Em seguida os resultados obtidos são apresentados na Seção 5. Finalizando o artigo, a Seção 6 apresenta as conclusões.

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Método de Monte Carlo

O Método Monte Carlo (MMC) é um método numérico desenvolvido para explorar e resolver problemas de formulação matemática por meio de simulações com variáveis aleatórias. As simulações estatísticas contrastam com métodos convencionais de discretização por, em muitos casos, poderem ser aplicadas diretamente, eliminando a necessidade de se descrever as funções matemáticas que representam o comportamento do sistema [12, 13]. No entanto, é necessário conhecer o comportamento histórico do sistema a fim de se fazer a modelagem correta das variáveis aleatórias envolvidas.

O funcionamento básico do MMC pode ser entendido em quatro passos, conforme descritos a seguir:

1. Modelar o problema definindo uma função de densidade de probabilidade (FDP) que represente o comportamento de cada uma das variáveis;
2. Gerar valores aleatórios conforme a FDP para cada variável do problema;
3. Calcular o resultado determinístico substituindo as variáveis pelos valores gerados;

Os passos 2 e 3 devem ser repetidos um determinado número de vezes.

4. Agregar e manipular os resultados da amostra de forma a obter uma estimativa da solução do problema.

Como as soluções obtidas com aplicação do método são aproximadas, existe um erro de aproximação ($\sigma_{\bar{x}}$) que pode ser expressado pela Equação 1:

$$\sigma_{\bar{x}} = \frac{\sigma_x}{\sqrt{N}} \quad (1)$$

Em que σ_x é o valor do desvio padrão da amostra e N é o tamanho da amostragem realizada. Pela análise da equação, é possível constatar que o valor do erro é inversamente proporcional ao tamanho da amostra observada. Logo, o valor de N deve ser suficientemente grande visando a diminuição do erro associado.

2.2. Algoritmos Genéticos

Os Algoritmos Genéticos (AG) são uma classe de algoritmos da Computação Evolucionária [14] que são inspirados nos mecanismos de seleção natural para resolver problemas por meio do emprego de estratégias de busca paralela, estruturada e randômica [14]. Um AG convencional pode ter o seu funcionamento explicado por meio das etapas ilustradas na Figura 1 e descritas a seguir:

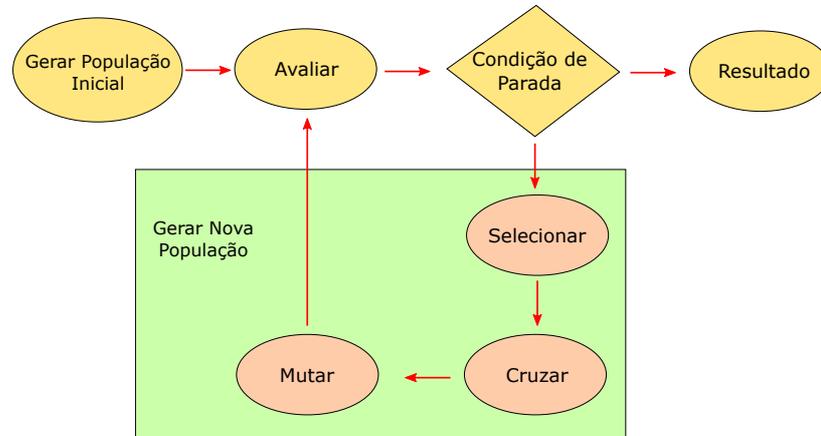


Figura 1: Etapas do funcionamento de um AG convencional.

1. *Gerar a População inicial*: Conjunto inicial de soluções que podem ser geradas aleatoriamente ou baseadas no conhecimento de um especialista;
2. *Avaliar*: Cada solução é submetida a uma função de avaliação (*fitness*) de modo a associar a qualidade da solução;
3. *Condição de Parada*: Algum critério de parada é avaliado para determinar se o algoritmo deve ser encerrado ou se uma nova população deve ser gerada. Comumente são usados como critérios: a verificação do número máximo de iterações, a detecção de estagnação do processo de evolução, a qualidade das soluções já obtidas, entre outras;
4. *Seleção*: Escolha dos indivíduos baseados no *fitness*, sendo que os mais aptos possuem maiores chances de serem selecionados;
5. *Cruzamento*: Recombinação das soluções selecionadas visando a criação de novos indivíduos que possuam características dos pais;
6. *Mutação*: Introdução de pequenas alterações nos novos indivíduos objetivando introduzir/manter a diversidade no intuito de reduzir a chance de estagnação das soluções;
7. *Resultado*: Ao final, os melhores indivíduos são retornados como solução para o problema.

A modelagem da solução geralmente é realizada por meio da representação de um indivíduo. Cada indivíduo possui um código genético chamado de cromossomo, normalmente o cromossomo de um indivíduo é representando por meio de um vetor de *bits*, conforme ilustrado na Figura 2.

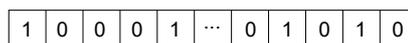


Figura 2: Ilustração da representação de um cromossomo.

A população de um AG é um conjunto de indivíduos selecionados durante cada iteração do algoritmo. O tamanho da população pode influenciar diretamente no desempenho de um AG. Populações muito pequenas não são capazes de garantir a diversidade de soluções necessárias para a convergência, devido a uma baixa exploração do espaço de busca. Já o contrário, poderá levar a uma degradação da performance do AG pela quantidade de indivíduos a serem avaliados em cada geração e pelos recursos computacionais despendidos.

2.3. Otimização Evolutiva Multiobjetivo

Problemas práticos do mundo real exigem tomadas de decisões que envolvem a análise simultânea de vários critérios concorrentes. Em determinadas situações podem existir várias soluções que atendam aos critérios analisados sem, contudo, ser possível afirmar qual é a melhor em comparação às demais. Sendo assim, quando o processo de escolha envolver critérios concorrentes, a priorização de um critério acarretará prejuízo em relação aos demais critérios e a tomada de decisão envolverá a análise do custo/benefício relativo à escolha de uma solução. Esses tipos de problemas são denominados como Problemas de Otimização Multiobjetivos (POM).

Um POM envolve um número de funções objetivos que devem ser maximizadas ou minimizadas visando buscar um conjunto de soluções ótimas para o problema estudado. Conforme o autor em [15], as soluções ótimas de um POM podem ser definidas por meio do conceito de dominância, apresentado a seguir:

Definição 1. Uma solução x_1 é dita dominante de outra solução x_2 se ambas as seguintes condições forem satisfeitas:

1. A solução x_1 não é pior que x_2 em todos os objetivos;
2. A solução x_1 é melhor do que x_2 em pelo menos um objetivo.

Seguindo a definição apresentada, uma solução será ordenada conforme sua dominância em relação às demais para formar a fronteira de não dominância ou Fronteira de Pareto (FP) [16, 17]. Para exemplificar, considere um problema multiobjetivo qualquer com duas funções objetivos definidas: $f(x)$ e $g(x)$, onde deseja-se minimizar a primeira e maximizar a segunda. A FP desse problema pode ser visualizada na Figura 3, em que as soluções pertencentes à fronteira estão representadas em vermelho.

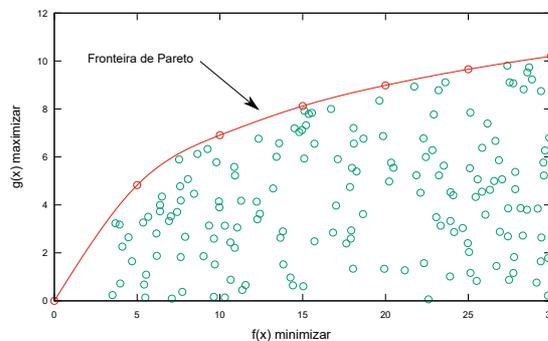


Figura 3: Fronteira de Pareto para um problema com dois objetivos.

Existem na literatura [18] vários métodos propostos visando encontrar as soluções pertencentes à FP de um POM, tais como: Colônia de Formigas (*Ant Colony Optimization*), Procedimento Aleatório Adaptativo Guloso (*Greedy Randomized Adaptive Procedure - GRASP*) [19], Algoritmos Meméticos (*Memetic Algorithms*) [20], Busca Tabu (*Tabu Search*) [21], Busca por Dispersão (*Scatter Search*) [22], Recozimento Simulado (*Simulated Annealing*) [23], Enxame de Partículas (*Particle Swarm*) [24], Busca de Vizinhança Variável (*Variable Neighbourhood Search - VNS*) [25] e Algoritmos Genéticos (*Genetics Algorithms*) [14].

Dentre todas as técnicas desenvolvidas, um dos algoritmos que se destaca é o Algoritmo Genético de Ordenação Não Dominante II (*Non-Dominated Sorting Genetic Algorithm II - NSGA-II*) proposto em [26]. A ideia básica do NSGA-II é encontrar um conjunto de indivíduos não dominados em relação ao restante da população e apontar este conjunto como o de nível de dominância mais alto. Em seguida repetir o mesmo procedimento com o restante da população, separando-a em vários níveis de dominância. O NSGA-II também introduz o conceito de distância de aglomeração (*crowding distance*), objetivando favorecer as soluções que sejam mais bem distribuídas ao longo da FP, preservando a diversidade das soluções e evitando uma possível convergência prematura para um ótimo local. A Figura 4 é do procedimento básico do NSGA-II, que será explanado por completo a seguir.

O primeiro passo do NSGA-II é a inicialização de uma população inicial ($P_{t=0}$), aleatória com tamanho N . Em seguida, aplica-se os operadores de seleção, cruzamento e mutação para gerar uma população filha ($Q_{t=0}$), também de tamanho N . Uma população auxiliar ($R_{t=0}$), com tamanho $2N$, é formada com a junção das duas populações. A população auxiliar é então ordenada por níveis de dominância e, em seguida, os indivíduos da fronteira de cada nível são inseridos seguindo uma ordem crescente dos níveis na nova população P_{t+1} até que esta atinja o tamanho N . Caso a fronteira do último nível a ser inserido tenha mais indivíduos que o necessário para completar a nova população de tamanho N , realiza-se a ordenação dos indivíduos desse nível por distância de aglomeração. Somente os melhores indivíduos deste último nível, suficientes para completar o tamanho da nova população, serão inseridos. O restante dos indivíduos do último nível serão descartados juntamente com o restante dos indivíduos que não foram inseridos na nova população. Sobre a nova população P_{t+1} é feita a seleção, cruzamento e mutação para que esta dê origem a sua prole, Q_{t+1} . O processo continua até que sejam atingidos os critérios de parada. Ao final do algoritmo, os indivíduos do primeiro nível de dominância representam a solução do problema.

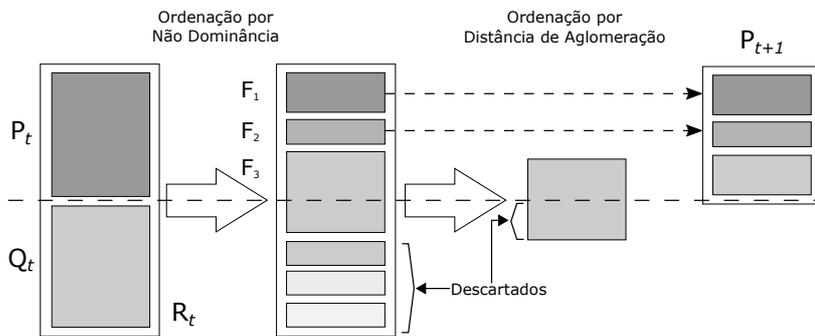


Figura 4: Procedimento de seleção do NSGA-II, adaptado de [26].

2.4. Método de Posição de Falta

O Método de Posição de Falta foi proposto pelos autores em [27] para o cálculo de afundamentos de tensão em sistemas de transmissão de grande porte. Este método consiste na simulação de um curto-circuito em cada uma das barras do sistema (uma por vez), seguido do cálculo das tensões remanescentes em todas as demais barras. Desta forma, é possível determinar os afundamentos de tensão em todo o sistema elétrico sob análise, para qualquer situação de falta em um nó do sistema.

A Figura 5 é o fluxograma do algoritmo do método das posições de falta, conforme o qual, a cada posição de falta f (geralmente uma barra do sistema) é simulada uma situação de curto-circuito e as tensões em todas as outras barras do sistema são calculadas e armazenadas. O algoritmo é executado até que todas as posições das faltas sejam contempladas, ou seja, até que tenha sido realizado o cálculo do curto-circuito em todas as barras desejadas. Pelo método, as tensões remanescentes podem ser calculadas pela Expressão 2:

$$T_{(k,f)} = T_{(PF)} - \frac{Z_{(k,f)}}{Z_{(f,f)}} \tag{2}$$

em que $T_{(k,f)}$ é a tensão na barra k devido uma falta na barra f , $T_{(PF)}$ é a tensão de pré-falta na barra k (normalmente considerada como 1 p.u.), $Z_{(k,f)}$ é a impedância de curto-circuito da barra k dada uma falta em f e $Z_{(f,f)}$ é a impedância de curto-circuito da barra f dada uma falta em f .

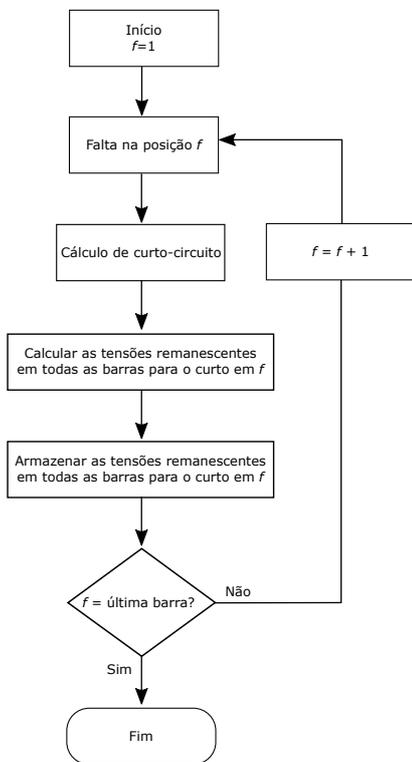


Figura 5: Fluxograma do algoritmo do método das posições de falta. (Adaptado de [28]).

De posse das tensões remanescentes, é construída a Matriz de Tensões Durante a Falta (MTDF), na qual as colunas possibilitam determinar as áreas afetadas pelas faltas aplicadas em cada uma das barras e as linhas possibilitam determinar a área de vulnerabilidade de cada barra.

3. ABORDAGEM PROPOSTA

A resolução de um POM necessita, primeiramente, da definição de uma estrutura adequada para a representação computacional do problema. Nesta abordagem a estrutura de dados de árvore foi escolhida para a representação do SD. Essa escolha foi baseada na equivalência existente entre um SD e a estrutura de árvore. Para exemplificar, pode-se estabelecer as seguintes relações: as barras de um sistema podem ser comparadas aos nós de uma árvore, as ligações entre barras pode ser vista como as arestas que conectam os nós e a presença de hierarquia entre os diversos níveis do sistema é a característica primordial de uma árvore. A eficiência apresentada por essa estrutura na representação de um SD já foi explorada por outros autores em trabalhos existentes na literatura como o visto em [29].

Para a definição dos pontos de monitoramento, esta abordagem utiliza como base o Método de Posição de Faltas. Entretanto, diferentemente do método original, a MTDF gerada por esta abordagem baseia-se na série histórica de faltas ocorridas em um SD, cujo comportamento foi modelado utilizando-se o MMC. Durante o processo de construção da MTDF foram considerados curtos-circuitos francos.

De posse da MTDF, um limiar e deve ser definido para a construção da Matriz de Cobertura (MC_e), que possui as mesmas dimensões da MTDF e é preenchida atribuindo-se o valor 1 às posições da MC_e correspondentes a valores abaixo do limiar e o valor 0 às posições com valores acima do limiar, conforme Equação 3:

$$MC_e = \begin{cases} 1, & \text{se } mtdf_i < e \\ 0, & \text{caso contrário} \end{cases} \quad (3)$$

Sendo que $mtdf_i$ é o elemento i da MTDF gerada e e é o limiar para indicar abaixo de qual valor de tensão o monitor de qualidade de energia deve passar a registrar as ocorrências.

A indicação se uma determinada barra b_i é monitorada ou não é realizada por meio do vetor de alocação (X), que possui um elemento para cada barra existente no SD. Os valores possíveis para o vetor de alocação foram definidos como sendo 0 (zero) ou 1 (um), no qual o primeiro representa a ausência de um monitor na barra correspondente e o segundo representa a situação contrária, conforme a Equação 4.

$$x_i = \begin{cases} 1, & \text{se existe um monitor instalado na barra } b_i \\ 0, & \text{caso contrário} \end{cases} \quad (4)$$

Para facilitar o entendimento da Equação 4, considere o sistema de distribuição fictício com seis barras ilustrado na Figura 6 (A). Nessa figura, os monitores são apresentados pelos quadrados de cor vermelha e foram alocados nas barras de número 1, 4 e 5. O vetor de alocação X para este exemplo é apresentado na Figura 6 (B).

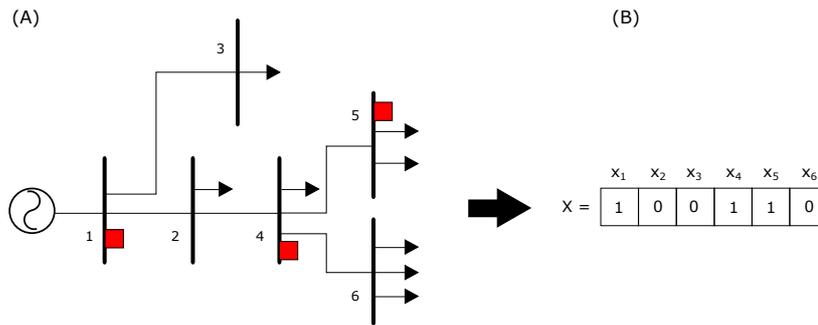


Figura 6: Exemplo do vetor de alocação X para um sistema de distribuição fictício com seis barras.

A Equação 5 representa o produto vetorial entre MC_e e o vetor de alocação (X) que resulta no vetor (V), no qual as posições com valores maiores que zero representam as barras em que os afundamentos de tensão podem ser monitorados pelos monitores alocados, considerando o limiar estabelecido.

$$V = MC_e \cdot X \quad (5)$$

Contudo, nem todas as posições deste vetor com valor igual a zero implicam, necessariamente, em afundamentos de tensão não monitorados. Uma posição do vetor V pode ser igual a zero porque todos os elementos de uma linha da matriz MC_e são iguais a zero, o que resulta de não haver afundamentos de tensão naquela linha de MC_e com valores abaixo do limiar estabelecido. Portanto, é fundamental garantir que esta situação não influencie na determinação da quantidade de afundamentos de tensão que não são percebidos por um arranjo de monitores. Esta garantia é obtida pela multiplicação da matriz MC_e por um

vetor que possua todas as posições iguais a 1, como mostra a Equação 6. O resultado possibilita afirmar que se alguma posição do vetor resultante (\bar{V}) for igual a zero é devido ao fato desta linha da matriz MC_e ter todos os elementos iguais a zero.

$$\bar{V} = MC_e \cdot 1 \quad (6)$$

Dispondo dos vetores V e \bar{V} o número de barras do SD nas quais os afundamentos de tensão podem ser monitorados é dado pela Equação 7:

$$u_i = \begin{cases} 1, & \text{se } v_i = 0 \text{ e } \bar{v}_i > 0 \\ 0, & \text{caso contrário} \end{cases} \quad (7)$$

na qual as posições com valor igual a 1 no vetor U indicam as barras em que os afundamentos de tensão não serão monitorados. Desta forma, o primeiro objetivo do problema de alocação pode ser expresso pela Equação 8, em que n representa o número de barras do sistema:

$$f_1(x) = \sum_{i=1}^n u_i \quad (8)$$

O custo da instalação dos monitores em cada um dos possíveis pontos de monitoramento é determinado pela Equação 9, apresentada a seguir:

$$p_i = \text{custo de instalação na barra } i \quad (9)$$

Assim, o custo total do monitoramento do sistema é determinado pelo produto entre o vetor de alocação e o vetor de custos, portanto o segundo objetivo pode ser expresso como segue pela Equação 10:

$$f_2(x) = \sum_{i=1}^n p_i \cdot x_i \quad (10)$$

em que p_i representa o custo de instalação do monitor na barra i .

Logo, a função objetivo do POM tratado neste trabalho é definida pela Equação 11.

$$\begin{aligned} & \text{minimize } (f_1(x)) \\ & \text{minimize } (f_2(x)) \end{aligned} \quad (11)$$

4. SISTEMAS ELÉTRICOS UTILIZADOS

4.1. Circuito alimentador IEEE de 13 barras

O circuito alimentador IEEE de 13 barras [30] utilizado neste trabalho pode ser visualizado por meio do seu diagrama unifilar na Figura 7. Apesar deste alimentador ser pequeno, o mesmo apresenta algumas características interessantes para o propósito, como:

- É um alimentador curto que opera com tensão nominal de 4,16 kV bastante carregado;
- Possui linhas aéreas e subterrâneas;
- Cargas modeladas como concentradas e como distribuídas; e
- As cargas são desequilibradas.

A Tabela 1 apresenta os trechos que conectam cada barra do alimentador de 13 barras, evidenciando que estas não são muito longas. Na tabela apresentada, o trecho 633 - 634 é um transformador, e o trecho 671 - 692 é uma chave.

A Tabela 2 apresenta as cargas conectadas às barras do circuito alimentador IEEE de 13 barras. Já a Tabela 3 apresenta as cargas distribuídas ao longo dos trechos. Importa ressaltar que nestas tabelas, a potência informada de cada carga é o somatório das potências das 3 fases.

4.2. Circuito alimentador IEEE de 34 barras

O circuito alimentador IEEE de 34 barras, representando pelo seu diagrama unifilar na Figura 8, é um alimentador real localizado no Arizona EUA [30], no qual é possível evidenciar as seguintes características:

- Opera com tensão nominal de 24,9 kV;
- É um sistema com linhas muito longas e é bastante carregado;
- Apresenta um transformador abaixador para um pequeno trecho que opera com tensão nominal de 4,16 kV;

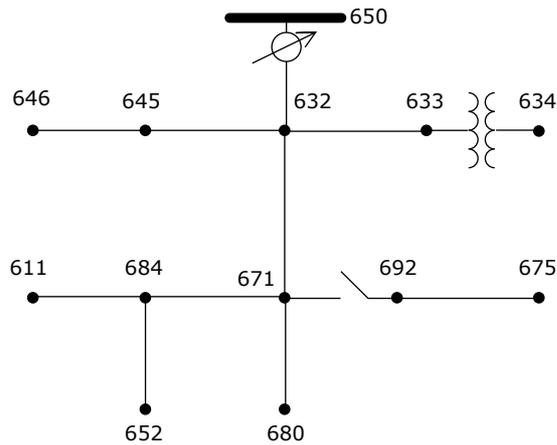


Figura 7: Representação unifilar do circuito alimentador IEEE de 13 barras [30].

Tabela 1: Trechos do circuito alimentador IEEE de 13 barras.

Barra Origem	Barra Destino	Comprimento (ft)
632	645	500
632	633	500
633	634	0
645	646	300
650	632	2000
684	652	800
632	671	2000
671	684	300
671	680	1000
671	692	0
684	611	300
692	675	500

Tabela 2: Cargas conectadas às barras do circuito alimentador IEEE de 13 barras.

Barra	Potência (kW)
634	400
645	170
646	230
652	128
671	1155
675	613
692	170
611	170
Total	3266

Tabela 3: Cargas modeladas com parâmetros distribuídos no circuito alimentador IEEE de 13 barras.

Barra Origem	Barra Destino	Potência (kW)
632	671	200
	Total	200

- O circuito apresenta poucas ramificações laterais;
- Cargas modeladas como concentradas e como distribuídas; e
- As cargas são desequilibradas.

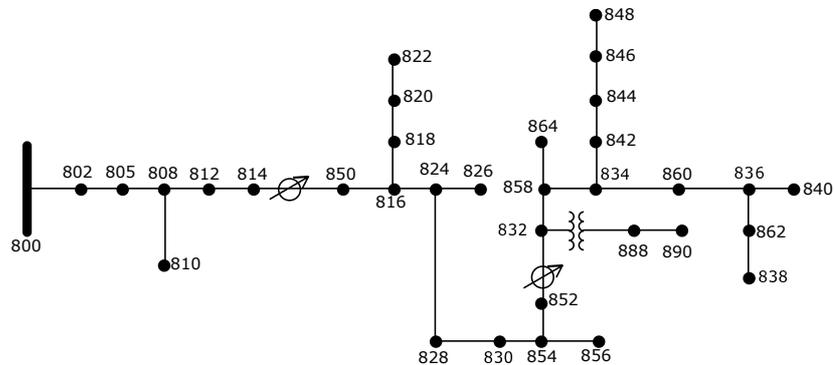


Figura 8: Representação unifilar do circuito alimentador IEEE de 34 barras [30].

A Tabela 4 apresenta as linhas que conectam cada barra do alimentador de 34 barras, incluindo a linha 832 - 888 que é um transformador. A Tabela 5 apresenta as cargas conectadas às barras do circuito alimentador IEEE de 34 barras, enquanto a Tabela 6 discrimina as cargas modeladas com parâmetros distribuídos circuito alimentador. Como nas outras tabelas que apresentam dados de cargas, nas Tabelas 5 e 6, para cada carga, é informado o somatório das potências das 3 fases.

Tabela 4: Trechos do circuito alimentador IEEE de 34 barras.

Barra Origem	Barra Destino	Comprimento (ft)
800	802	2580
802	806	1730
806	808	32230
808	810	5804
808	812	37500
812	814	29730
814	850	10
816	818	1710
816	824	10210
818	820	48150
820	822	13740
824	826	3030
824	828	840
828	830	20440
830	854	520
832	858	4900
832	888	0
834	860	2020
834	842	280
836	840	860
836	862	280
842	844	1350
844	846	3640
846	848	530
850	816	310
852	832	10
854	856	23330
854	852	36830
858	864	1620
858	834	5830
860	836	2680
862	838	4860
888	890	10560

Tabela 5: Cargas conectadas às barras do circuito alimentador IEEE de 34 barras.

Barra	Potência (kW)
860	60
840	27
844	405
848	60
890	450
830	45
Total	1047

Tabela 6: Cargas modeladas com parâmetros distribuídos no circuito alimentador IEEE de 34 barras.

Barra Origem	Barra Destino	Potência (kW)
802	806	55
808	810	16
818	820	34
820	822	135
816	824	5
824	826	40
824	828	4
828	830	7
854	856	4
832	858	15
858	864	2
858	834	32
834	860	146
860	836	82
836	840	40
862	838	28
842	844	9
844	846	45
846	848	23
	Total	722

5. RESULTADOS

Para fins de validação, a abordagem proposta neste artigo foi testada nos dois circuitos apresentados na Seção 4. Por motivo de simplificação, em todos os testes foi considerado que o custo de instalação dos monitores em qualquer barra é igual e com valor unitário. O comportamento de cada SD, em face as ocorrência de faltas, foi simulado no software DigSILENT Power Factory 15.1. O MMC foi aplicado na modelagem do comportamento das ocorrências de faltas no SD, sendo a frequência de ocorrência de faltas monofásicas, bifásicas e trifásicas definidas em 80%, 15% e 5%, respectivamente. A abordagem considerou um período de 1000 unidades de tempo nas simulações. O algoritmo de otimização utilizado foi o NSGA-II [26] e os seus parâmetros foram ajustados conforme a Tabela 7:

Tabela 7: Parâmetros utilizados no NSGA II.

Parâmetro	Valor
Tamanho da população	500 indivíduos
Quantidade de gerações	1000
Método de seleção	Torneio (tamanho 16)
Método de <i>crossover</i>	<i>Single Point</i> (Probabilidade 0,75)
Método de mutação	<i>Bit Flip</i> (Probabilidade 0,01)

Em ambos os circuitos foi analisado o comportamento da abordagem para dois limiares: 0,9 p.u. e 0,6 p.u..

Os resultados obtidos quando aplicado o limiar de 0,9 p.u. aos dois circuitos são apresentados na Figura 9.

Pode-se verificar que a abordagem apontou apenas duas soluções possíveis: A instalação de um único monitor ou a ausência de monitores instalados. A primeira solução representa a melhor cobertura possível dos afundamentos, na qual nenhum afundamento acontece sem ser monitorado. Nos circuitos testados, considerando o limiar de 0,9 p.u., um único monitor instalado é capaz de cobrir todo o sistema quanto ao monitoramento dos afundamentos. Já a segunda solução representa o melhor custo possível, ou seja, custo zero sem a instalação de monitores, e como consequência, a pior cobertura quanto ao monitoramento dos afundamentos.

Reduzindo o valor do limiar podemos verificar um novo perfil das fronteiras de pareto obtidas. Em ambos os circuitos analisados, um único monitor já não é mais capaz de perceber os afundamentos em todo o sistema quando o limiar definido é de 0,6 p.u., conforme a Figura 10.

Observando as fronteiras de pareto apresentadas na Figura a Figura 10, percebe-se que a solução de custo zero, ou seja, aquela em que não é instalado nenhum monitor possui o pior desempenho quanto ao monitoramento dos afundamentos de tensão, pois não é possível monitorar a ocorrência de afundamento em nenhum ponto do sistema. Já a solução de maior custo em ambos os

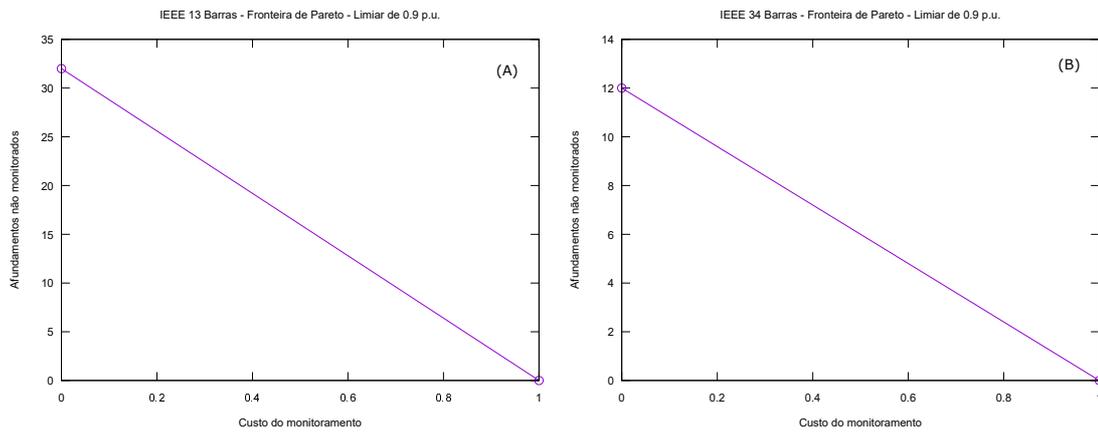


Figura 9: Fronteira de Pareto obtida para o limiar de 0,9 p.u. no circuito de 13 (A) e 34 (B) barras do IEEE.

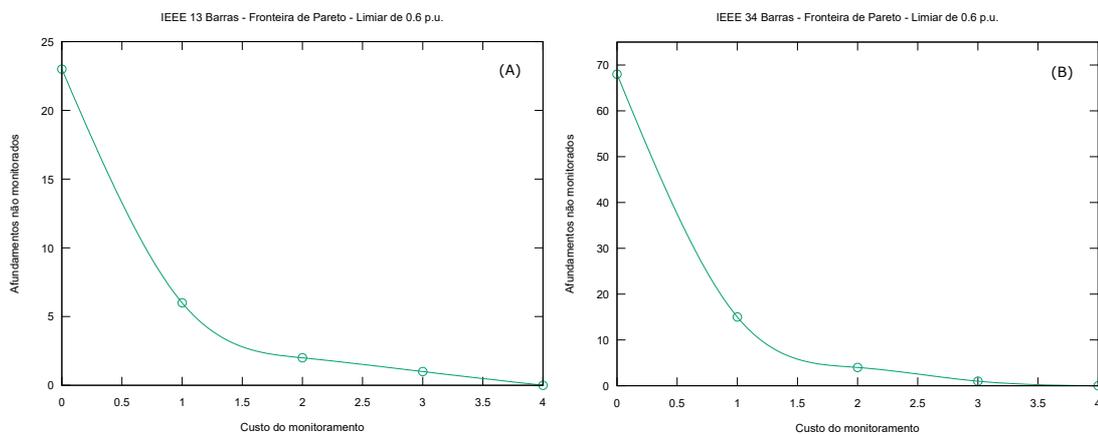


Figura 10: Fronteira de Pareto obtida para o limiar de 0,6 p.u. no circuito de 13 (A) e 34 (B) barras do IEEE.

casos, permite a observação dos afundamentos em todo o sistema com a instalação de 4 monitores. É possível perceber que há uma certa relação de compromisso entre o custo de monitoramento e a quantidade de afundamentos de tensão que podem ser monitorados. À medida que se aumenta o custo, melhora-se o desempenho do sistema de monitoramento. Neste caso, o operador do sistema deve avaliar até qual ponto é interessante investir na melhoria do sistema de monitoramento.

6. CONCLUSÕES

Neste artigo foi apresentada uma abordagem para alocação otimizada de monitores de qualidade de energia elétrica para sistemas de distribuição (SD) por meio da aplicação de técnicas de otimização multiobjetivo visando cobrir a maior quantidade de afundamentos de tensão com o menor custo possível. Na metodologia proposta foram aplicados o Método da Posição de Falhas e Simulação de Monte Carlo para obter uma Matriz de Tensões Durante a Falta com perfil médio das tensões observadas ao longo do tempo, considerando as probabilidades de ocorrências de falta nos circuitos estudados. Esta MTFD foi utilizada para determinar a quantidade de afundamentos monitorados por um dado arranjo de monitores. Já a quantidade de monitores do arranjo determina o custo deste. Para resolver o modelo multiobjetivo proposto utilizou-se o algoritmo NSGA.

Os resultados obtidos permitem o auxílio à tomada de decisões sobre as quantidades de monitores que devem ser instalados no sistema, possibilitando que a concessionária possa adequar sua estratégia baseada nos recursos disponíveis e evitando gastos desnecessários que não se traduzem em melhoria significativa do monitoramento.

Para trabalhos futuros pretende-se ampliar o modelo multiobjetivo, incluindo no modelo outros aspectos relevantes para o monitoramento do sistema, considerando inclusive a otimização do monitoramento de outros distúrbios de qualidade da energia.

Agradecimentos

Este trabalho é resultado do Projeto de P&D: Metodologia para alocação otimizada de monitores de qualidade da energia elétrica em sistemas de distribuição pelo emprego de técnicas inteligentes - 0042/2014, financiado pela Eletrobrás Distribuição Piauí.

REFERÊNCIAS

- [1] M. H. Bollen and I. Gu. *Signal processing of power quality disturbances*, volume 30. John Wiley & Sons, 2006.
- [2] H. M. Branco, M. Oleskovicz, A. C. Delbem, D. V. Coury and R. P. Silva. “Optimized allocation of power quality monitors in transmission systems: A multiobjective approach”. *International Journal of Electrical Power & Energy Systems*, vol. 64, pp. 156–166, 2015.
- [3] M. Eldery, E. F. El-Saadany, M. M. Salama and A. Vannelli. “A novel power quality monitoring allocation algorithm”. *IEEE Transactions on Power Delivery*, vol. 21, no. 2, pp. 768–777, 2006.
- [4] T. R. Kempner, M. Oleskovicz and A. Q. Santos. “Optimal allocation of monitors by analyzing the vulnerability area against voltage sags”. In *2014 16th International Conference on Harmonics and Quality of Power (ICHQP)*, pp. 536–540, May 2014.
- [5] E. Espinosa-Juárez and A. Hernandez. “A method for voltage sag state estimation in power systems”. *IEEE Transactions on Power Delivery*, vol. 22, no. 4, pp. 2517–2526, 2007.
- [6] E. Espinosa-Juarez, A. Hernandez and G. Olguin. “An approach based on analytical expressions for optimal location of voltage sags monitors”. *IEEE Transactions on Power Delivery*, vol. 24, no. 4, pp. 2034–2042, 2009.
- [7] F. Salim and K. Nor. “Optimal voltage sag monitor locations”. In *Australasian Universities Power Engineering Conference (AUPEC)*, pp. 1–6. IEEE, 2008.
- [8] F. Salim and K. Nor. “Voltage sags observation through optimal monitor locations”. In *14th International Conference on Harmonics and Quality of Power (ICHQP)*, pp. 1–6. IEEE, 2010.
- [9] S. Lotfifard, M. Kezunovic and M. J. Mousavi. “Voltage sag data utilization for distribution fault location”. *IEEE Transactions on Power Delivery*, vol. 26, no. 2, pp. 1239–1246, 2011.
- [10] C. Muscas, F. Pilo, G. Pisano and S. Sulis. “Optimal measurement devices allocation for harmonic state estimation considering parameters uncertainty in distribution networks”. In *9th International Conference on Electrical Power Quality and Utilisatio (EPQU)*, pp. 1–6. IEEE, 2007.
- [11] N. Moaddabi, S. Sadeghi and H. A. Abyaneh. “Minimization of monitoring locations for detection of flicker sources by the direction of propagation method”. In *IEEE 2nd International Conference on Power and Energy (PECon)*, pp. 307–312. IEEE, 2008.
- [12] M. E. Newman, G. T. Barkema and M. Newman. *Monte Carlo methods in statistical physics*, volume 13. Clarendon Press Oxford, 1999.
- [13] W. Li and R. Billinton. *Reliability assessment of electric power systems using Monte Carlo methods*. Springer Science & Business Media, 2013.
- [14] D. E. Goldberg. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA, first edition, 1989.
- [15] K. Deb. *Multi-objective optimization using evolutionary algorithms*, volume 16. John Wiley & Sons, 2001.
- [16] K. Miettinen. *Nonlinear multiobjective optimization*, volume 12. Springer Science & Business Media, 2012.
- [17] H.-T. Kung, F. Luccio and F. P. Preparata. “On finding the maxima of a set of vectors”. *Journal of the ACM (JACM)*, vol. 22, no. 4, pp. 469–476, 1975.
- [18] D. A. Van Veldhuizen and G. B. Lamont. “Multiobjective evolutionary algorithms: Analyzing the state-of-the-art”. *Evolutionary computation*, vol. 8, no. 2, pp. 125–147, 2000.
- [19] T. A. Feo and M. G. Resende. “A probabilistic heuristic for a computationally difficult set covering problem”. *Operations research letters*, vol. 8, no. 2, pp. 67–71, 1989.
- [20] P. Moscato. “On evolution, search, optimization, genetic algorithms and martial arts: Towards memetic algorithms”. *C3P Report Caltech concurrent computation program*, vol. 826, pp. 1989, 1989.
- [21] F. Glover. “Tabu search-part I”. *ORSA Journal on computing*, vol. 1, no. 3, pp. 190–206, 1989.
- [22] F. Glover. “Heuristics for integer programming using surrogate constraints”. *Decision Sciences*, vol. 8, no. 1, pp. 156–166, 1977.
- [23] S. Kirkpatrick and M. P. Vecchi. “Optimization by simulated annealing”. *science*, vol. 220, no. 4598, pp. 671–680, 1983.

- [24] R. C. Eberhart and J. Kennedy. “A new optimizer using particle swarm theory”. In *Proceedings of the sixth international symposium on micro machine and human science*, volume 1, pp. 39–43. New York, NY, 1995.
- [25] N. Mladenović and P. Hansen. “Variable neighborhood search”. *Computers & Operations Research*, vol. 24, no. 11, pp. 1097–1100, 1997.
- [26] K. Deb, A. Pratap, S. Agarwal and T. Meyarivan. “A fast and elitist multiobjective genetic algorithm: NSGA-II”. *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, 2002.
- [27] L. Conrad, K. Little and C. Grigg. “Predicting and preventing problems associated with remote fault-clearing voltage dips”. *IEEE Transactions on Industry Applications*, vol. 27, no. 1, pp. 167–172, 1991.
- [28] T. R. Kempner. “A robustez de um sistema de distribuição e a alocação de medidores de qualidade da energia elétrica frente aos afundamentos de tensão”. Ph.D. thesis, Universidade de São Paulo, 2012.
- [29] D.-J. Won and S.-I. Moon. “Optimal number and locations of power quality monitors considering system topology”. *IEEE Transactions on Power Delivery*, vol. 23, no. 1, pp. 288–295, 2008.
- [30] W. Kersting. “Radial distribution test feeders”. *IEEE Transactions on Power Systems*, vol. 6, no. 3, pp. 975–985, 1991.