

A Multi-objective Swarm Intelligence Approach for Field Crews Patrol Optimization in Power Distribution Systems Restoration

L. Desuó, M. Bessani, R. Fanucchi, T. Gross, and C. Maciel

Abstract—A fault on a power distribution system may cause electricity interruption for several consumers, so a good restoration plan is required to decrease such interruptions duration and, consequently, assure the quality of service. Among the measures for service restoration, there is the dispatch of inspection and maintenance crews. The routing of these teams can be classified as a case of the multiple traveling salesman problem. Although involved in series of decision problems, the power distribution system maintenance crews routing is addressed, in the most part of the literature, as a single-objective problem, an instance of a multi-objective one, or as a multi-objective aggregating approach, which generates a single solution in an optimization run, in contrast with the set of equally good solutions, known as Pareto set, the result of a multi-objective problem. In this paper, a Pareto based multi-objective discrete particle swarm optimization approach was applied with the aim of reducing the patrol duration and also the total crews displacement. Wherein the concept of epsilon-dominance was used to update the set of non-dominated solutions, resulting in a good spreading and convergence of them. To promote a uniform exploration of the Pareto set, the selection of the local leaders of the archive was based on square root distance metrics. The Dijkstra algorithm was employed to find the shortest path between two consecutive points of the route of each team. As a result, a set of solutions were obtained for the routing of maintenance crews for power distribution system restoration.

Index Terms—in field crews patrol, multi-objective, Pareto set, particle swarm optimization, power restoration, routing.

I. INTRODUÇÃO

A QUALIDADE do serviço de um sistema de distribuição de energia elétrica possui indicadores que especificam a continuidade de fornecimento [1], como o *System Average Interruption Duration Index* (SAIDI) [2]. Este aponta a duração esperada média de interrupção de energia que um cliente comum experimentará durante um determinado período de tempo, como por exemplo, um ano [3]. Em suma, as concessionárias buscam a redução do SAIDI, devido a multas elevadas, através de planos de restabelecimento de energia.

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001

L. Desuó N. and Carlos D. Maciel are with the Department of Electrical and Computer Engineering, Universidade de São Paulo, São Carlos, São Paulo, Brasil, luizdesuo@gmail.com, carlos.maciel@usp.br

M. Bessani is with the Department of Electrical Engineering, Federal University of Minas Gerais, Belo Horizonte, MG, Brazil, mbessani@eee.ufmg.br

R. Z. Fanucchi is with the Department of Electrical and Computer Engineering, Universidade de São Paulo, São Carlos, São Paulo, Brasil and also with the Department of Distribution Operation and Maintenance, COPEL Distribution S/A, Curitiba, Brasil, rodrigo.fanucchi@copel.com.

T. J. Gross is with the Polícia Científica do Mato Grosso, Cuiabá, Mato Grosso, Brasil, tadeugross@politec.mt.gov.br.

Esses incluem Detecção de Falha, Isolamento e Restauração (FDIR, do inglês *Fault Detection, Isolation, and Restoration*).

Uma falha qualquer, que ocorre na maioria das vezes devido ao clima e acidentes [4], pode ocasionar a interrupção de energia a vários consumidores a jusante da região defeituosa, piorando indicadores como o SAIDI [5]. Consequentemente, diferentes métodos são aplicados com a finalidade de localização da falha. Dentre eles é possível salientar a medição da impedância aparente [6], análise de circuito trifásico [7], inteligência artificial integrada à análise de qualidade da energia [8] e estimação de parâmetros como a distância e resistência de falta por redes neurais artificiais [9], incluindo o envio de equipes de manutenção para inspeção e recomposição dos trechos são de um setor [10]. Neste último caso, há duas formas de se efetuar a operação: inspeção de todos os setores e a recomposição total, se a razão da falha não for encontrada; e a inspeção e recomposição sequencial dos trechos são de cada um dos setores. Essa abordagem é definida como recomposição trecho-a-trecho ou método da recomposição parcial [11].

Ao ocorrer uma indisponibilidade no fornecimento de energia, decorre a realocação dos consumidores para os alimentadores são interconectados, quando possível. Bem como, a redução da região de falha por chaves manual ou remotamente controladas. Logo após, as concessionárias enviam as equipes dispostas em veículos para identificar o local de falha e efetuar o reparo [12]. Essa operação, cujo custo pode vir a superar ao do próprio reparo, pode levar de horas a dias [13]. Em decorrência, como as equipes são despachadas arbitrária e empiricamente, a solução escolhida raramente é otimizada e os recursos são empregados de forma ineficiente. Desse modo, faz-se necessário otimizar o roteamento das equipes para um FDIR eficaz.

Diversos problemas de decisão envolvem o roteamento, despacho e gerenciamento das equipes de reparo para a restauração de sistemas de distribuição de energia [11]. Uma abordagem foi proposta por [14] para o roteamento de uma equipe em chamadas de emergência visando a menor distância percorrida. Dispondo-se desse mesmo objetivo para o roteamento das equipes de manutenção, um método híbrido e discreto da otimização por enxame de partículas foi introduzido por [15]. Em [16], há uma avaliação de meta-heurísticas para o planejamento de inspeções emergenciais de infraestrutura. Além disso, existem heurísticas que se baseiam em uma lista de priorização de serviços, como no recente trabalho [17]. Este visa reduzir um objetivo fundamentado em uma métrica

própria associada à importância de cada localidade em falha, porém desconsidera o tempo gasto nos deslocamentos.

Além dos métodos supracitados que tem como propósito a redução de um único objetivo, existem métodos multi-objetivo agregativos. Como em [18], que apresenta uma heurística para o roteamento de veículos de reparo de uma concessionária de energia. Uma abordagem foi sugerida em [19] para lidar com o roteamento em situações de emergência em tempo real. Já em [20], um método baseado na árvore de decisão de Monte Carlo foi aplicado ao planejamento do despacho de uma equipe de manutenção contemplando a duração da falta de energia para cada unidade consumidora e o custo operacional da equipe. Recentemente [21] apresentou uma heurística de priorização de localidades em falha considerando os graus de importância da carga e do consumidor para o sistema.

Típicamente, em um problema de otimização combinatória como o roteamento das equipes de inspeção e recomposição [22], dois tipos de objetivos são considerados: a soma e o objetivo de gargalo [23]. Ambos os tipos são englobados ao se direcionar a otimização para deslocamento total das equipes, objetivo do tipo soma, e o tempo gasto na inspeção e restauração, gargalo. Embora os dois tipos de objetivos sejam conflitantes [24], é possível conciliá-los e obter um conjunto de soluções satisfatórias com a abordagem baseada em Pareto, diferentemente de abordagens agregativas, em que geralmente existem soluções ótimas não contempladas pela soma ponderada dos objetivos [23]. Portanto, visando a redução de ambos os objetivos no presente trabalho, a otimização multi-objetivo discreta por enxame de partículas (MODPSO, do inglês *Multi-Objective Discrete Particle Swarm Optimization*) baseada em Pareto é aplicada ao roteamento de equipes de campo para restauração de sistemas de distribuição de energia, considerando-se o método da recomposição parcial.

O MODPSO é uma abordagem multi-objetivo discreta da Otimização por Enxame de Partículas clássica (PSO, do inglês *Particle Swarm Optimization*) [25], meta-heurística que mantém como atrativa a capacidade de escape de ótimos locais através de mecanismos estocásticos, sem negligenciar a convergência. Por este ser um método baseado em população é natural que seja estendido para otimizar diversos objetivos conflitantes [26]. Como não há uma única solução satisfatória para um problema multi-objetivo, o conjunto almejado de soluções deve manter o melhor compromisso entre os objetivos. Esse denomina-se conjunto de Pareto ou fronteira de Pareto [27]. Esse conjunto compreende os líderes do enxame, armazenado em um arquivo externo [26], cuja atualização utiliza-se do conceito de ϵ -dominância, que restringe o tamanho do arquivo, mantém o espalhamento das soluções, possui baixo custo computacional e convergência [28]. Além disso, o enxame deve explorar uniformemente toda a fronteira de Pareto, o que pode ser melhorado através da métrica de seleção de líderes como a *Square Root Distance* (SRD) [29].

Esse artigo é organizado da seguinte forma: há uma explicação do método de recomposição parcial na Subseção II-A. A Subseção II-B contém a formulação do MODPSO. Os parâmetros de teste são descritos na Subseção III-A e os resultados e discussão apresentados na Seção III. A conclusão, na Seção IV.

II. METODOLOGIA

A. O Problema de Múltiplos Caixeiros Viajantes e o Roteamento das Equipes de Restauração de Energia

Para uma determinada rede de distribuição de energia, um setor é definido como um trecho entre chaves, seguindo a representação *Node-Depth Encoding* (NDE) [30], como na Figura 1, em que o *setor 1* é compreendido entre as chaves *GM* e *SU₁*. Adotando-se a recomposição parcial, por exemplo, considera-se dois tipos de equipe operando simultaneamente: uma para inspeção e abertura das chaves limítrofes, que isolam o setor; outra para o fechamento da chave estratégica, que energiza o setor mencionado. Esse método, ilustrado pelo fluxograma da Figura 2, é repetido sequencialmente até que todos os setores da região em falha tenham sido inspecionados e recompostos [11].




Fig. 1. *Setor 1* definido pelo trecho entre as chaves *GM* e *SU₁*, em que os B_i 's são os postes de energia e T_i 's, os transformadores.

O roteamento das equipes de manutenção dos sistemas de distribuição de energia é um problema de otimização combinatória. Esse é similar ao problema de múltiplos caixeiros viajantes (mTSP, do inglês *multiple Traveling Salesmen Problem*) [22], com algumas ressalvas: diferentemente dos caixeiros-viajantes, as equipes não precisam retornar ao ponto de início; o mapa não consiste em um grafo completo; e os pontos não possuem restrição quanto ao número de visitas [31].

Considerado-se as possíveis transferências de carga para outros alimentadores já realizadas e que a inspeção será em um setor já isolado. O tempo total para restauração de energia pode ser calculado adotando-se (1) e (2).

$$t_{io} = \left(\max_{j \in \{1, \dots, M\}} \frac{\Delta_{i_j}}{v_{i_j}} \right) + \frac{n_{bs}}{M} (t_{po} + t_{oo}) \quad (1)$$

$$t_{dc} = \frac{\Delta_d}{v_d} + t_{pc} + t_w + t_{oc} \quad (2)$$

Em (1), as variáveis relativas à equipe que realiza a inspeção e a abertura das chaves limítrofes são:

t_{io} : tempo total de inspeção e abertura das chaves limítrofes (em horas);

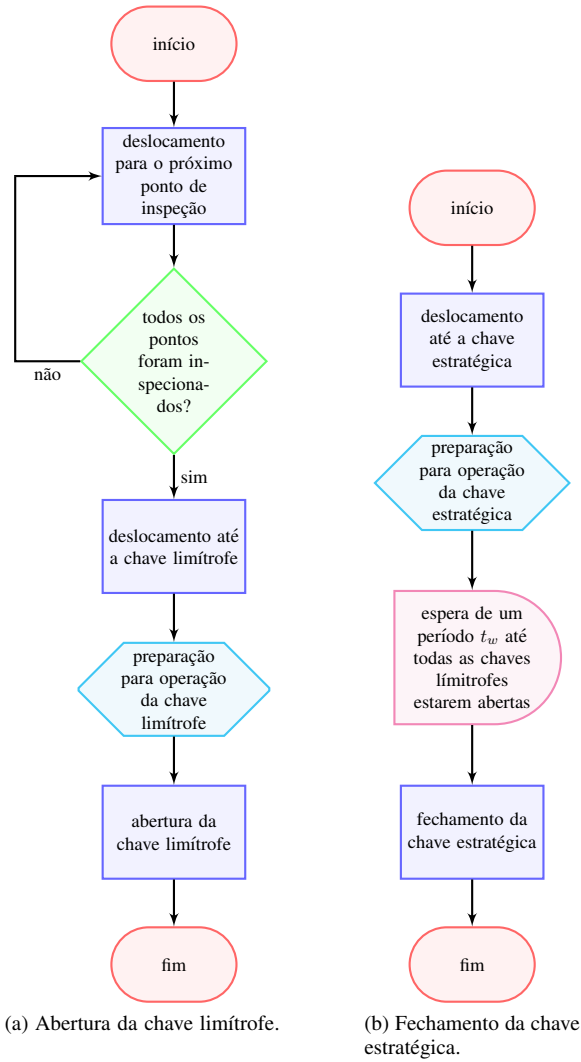


Fig. 2. Fluxograma do método da recomposição parcial para os dois tipos de equipe em operação simultânea: uma para a inspeção dos pontos e abertura da chave limítrofe; outra para o fechamento da chave estratégica.

Δ_{i_j} : distância Δ_i percorrida pela j -ésima equipe na inspeção de um setor (em km);

\bar{v}_{i_j} : velocidade média \bar{v}_i do veículo da j -ésima equipe na inspeção de um setor (em km/h);

t_{p_o} : tempo de preparação para a operação da chave de manobra (em horas);

t_{o_o} : tempo de operação da chave limítrofe (em horas);

n_{b_s} : número de chaves limítrofes a serem manobradas;

M : número de equipes simultaneamente disponíveis para manobra das chaves limítrofes. O número de equipes é considerado menor ou igual ao número de chaves.

Em (2), as variáveis relacionadas à equipe responsável pelo fechamento da chave estratégica, energizando o setor são:

t_{d_c} : tempo total de deslocamento e fechamento da chave estratégica (em horas);

Δ_d : distância percorrida até a chave estratégica (em km);

\bar{v}_d : velocidade média do veículo até a chave (em km/h);

t_{p_c} : tempo de preparação para operação da chave (em horas);

t_w : tempo de espera entre o fim da preparação e a liberação para o fechamento da chave (em horas), definido por (3);

t_{o_c} : tempo de operação da chave estratégica (em horas).

$$t_w = \begin{cases} 0 & , \text{ se } t_{i_o} \leq \frac{\Delta_d}{\bar{v}_d} + t_{p_c} \\ t_{i_o} - \left(\frac{\Delta_d}{\bar{v}_d} + t_{p_c} \right) & , \text{ caso contrário} \end{cases} \quad (3)$$

B. Otimização Multi-objetivo Discreta por Enxame de Partículas

O PSO é um algoritmo inspirado em padrões comportamentais de um bando de pássaros. De maneira similar ao bando a procura de matrizes alimentícias, o enxame de partículas tende a focar a busca em áreas de interesse dependendo de parâmetros como a coesão social. Destarte, dotadas de posição e velocidade, as partículas trafegam pelo espaço de busca constituído pelas soluções factíveis do sistema acelerando em direção às melhores soluções. Em suma, um dos grandes atrativos do PSO é a capacidade de escapar de ótimos locais através de seus componentes estocásticos mantendo a convergência [25]. Porém, por tratar-se de um otimizador de funções contínuas, o PSO oferece soluções inválidas para casos discretos como o mTSP, de forma que as operações básicas foram redefinidas [32].

Em um problema de otimização com objetivos conflitantes, como no caso do roteamento de equipes, não há uma única solução satisfatória [27]. Alternadamente, é desejável encontrar um conjunto com diferentes soluções não dominadas, o conjunto de Pareto, que provê rotas alternativas para suportar o planejamento da inspeção. Desse modo, dada a natureza baseada em população do MODPSO é natural que produza soluções não-dominadas diferentes em uma única execução de otimização [26]. Ademais, associando-se às vantagens do PSO, como a convergência e a capacidade de escape dos ótimos locais, a abordagem multi-objetivo baseada em Pareto engendra soluções não-dominadas, que não são disponíveis para uma soma ponderada dos objetivos, como no caso de abordagens agregativas [23]. O MODPSO, descrito no Algoritmo 1, foi desenvolvido na linguagem *Python* 3.

Dadas as entradas x_0 e k_{max} , que são, respectivamente, um vetor contendo uma posição inicial e o número máximo de iterações, o algoritmo inicia-se com a ativação do arquivo externo na Linha 1. Então, o laço entre as Linhas 2 e 6 corresponde ao estágio de inicialização do enxame e v_R , uma velocidade aleatória. O laço entre as Linhas 7 e 9 carrega o arquivo externo, um vetor contendo as soluções não ϵ -dominadas, através da função *atualizar*. O conceito da ϵ -dominância, utilizado para limitar o tamanho desse arquivo e gerir o espalhamento das soluções pela fronteira de Pareto, é descrito na Subseção II-B3. Uma execução de otimização é compreendida entre as linhas 10 e 22, cujo número de iterações é restringido pelo parâmetro k_{max} como critério de parada. Considerando-se um enxame de tamanho N e um problema com m objetivos a otimizar, temos Nm comparações para cada solução presente no arquivo A , de modo que o tempo decorrido de uma execução de otimização para cada iteração restringe-se a $\mathcal{O}(Nm\|A\|)$, em que $\|A\|$ é limitado conforme

Algoritmo 1 MODPSO**Entrada:** x_0, k_{max}

```

1:  $A := \{\}$ 
2: para  $particula \in enxame$  faça
3:    $x := embaralhar(x_0)$ 
4:    $v := v_R$ 
5:    $p_{best} := x$ 
6: fim para
7: para  $particula \in enxame$  faça
8:    $A := atualizar(A, p_{best})$ 
9: fim para
10: enquanto  $k < k_{max}$  faça
11:   para  $particula \in enxame$  faça
12:      $l_{best} := selecionar\_lider(A, x)$ 
13:      $v := wv + c_1(p_{best} - x) + c_2(l_{best} - x) + c_3v_{R_t}$ 
14:      $x := x + v$ 
15:     se  $x \prec p_{best}$  então
16:        $p_{best} := x$ 
17:     fim se
18:   fim para
19:   para  $particula \in enxame$  faça
20:      $A := atualizar(A, p_{best})$ 
21:   fim para
22: fim enquanto

```

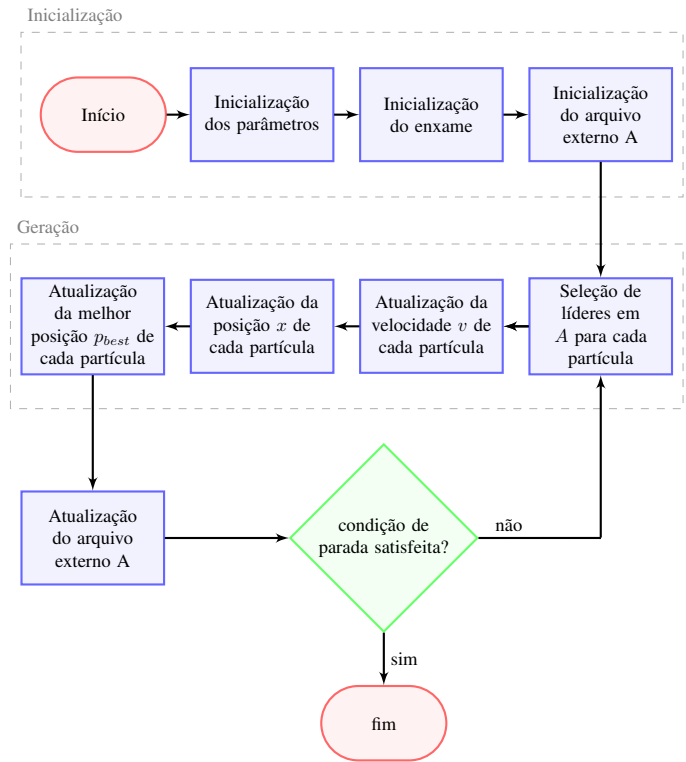
Saída: A 

Fig. 3. Fluxograma simplificado do MODPSO, contendo os estágios de inicialização, geração e atualização do arquivo externo.

o esclarecimento da Subseção II-B3. O laço entre as Linhas 11 e 18, chamado de geração, é responsável por engendrar novas soluções [28]. O laço entre as Linhas 19 e 21 atualiza o arquivo externo, um vetor que é a saída do algoritmo. Em resumo, na Figura 3 temos um fluxograma simplificado do MODPSO, em que estão destacados os estágios de inicialização, geração e atualização do arquivo externo.

As partículas do enxame trafegam pelo espaço de busca, contendo as soluções factíveis para o roteamento das equipes. Desta forma, o deslocamento das partículas, cuja velocidade v , para a k -ésima iteração, é conduzida por (4) e a posição x por (5). Como na versão clássica do PSO, o peso de inércia $w \in \mathbb{R}$ é uma constante e p_{best} é a melhor posição atingida pela partícula. Já l_{best} é a posição do líder local selecionada através da métrica SRD [29], em disparidade com as versões de objetivo único ou multi-objetivo agregativas que consideram apenas a melhor posição do enxame. Ademais, os coeficientes c_i são amostrados de uma distribuição uniforme, i.e. $c_i \sim U(0, C_i)$, $C_i \in \mathbb{R}$, $i = \{1, 2, 3\}$. Portanto, por definição, c_1 , c_2 e c_3 são, respectivamente, coeficiente de confiança cognitiva, coeficiente de confiança social e coeficiente de diversidade [33]. Ainda assim, uma velocidade aleatória, v_{R_t} , foi introduzida para prevenir convergências prematuras do algoritmo, algo que acontece no modelo clássico dependendo dos parâmetros utilizados [34].

$$v^{k+1} = wv^k + c_1(p_{best} - x^k) + c_2(l_{best} - x^k) + c_3v_{R_t} \quad (4)$$

$$x^{k+1} = x^k + v^{k+1} \quad (5)$$

1) *Operações discretas:* Seja $G = \{V, E\}$ um grafo, os nós em V representam pontos em um mapa e as arestas em

E , as vias conectando esses pontos. Portanto, para adequar-se à estrutura discreta do grafo de vias, as operações de deslocamento das partículas foram redesenhadas visando a mesma estrutura do PSO canônico [32]. Assim sendo, a posição x de cada partícula é definida pelos rótulos dos pontos de interesse a serem visitados sequencialmente e $M - 1$ caracteres *, que os dividem para M equipes. Além disso, definiu-se o *swap*, um operador discreto básico que atua na posição da partícula. Esse consiste em um par da forma (i, j) , que implica: trocar de posição os elementos indexados por i e j [35]. Consequentemente, a subtração de posições, como na Figura 4, resume-se em detectar todos os *swaps* necessários para mover a partícula de uma posição à outra, resultando em uma velocidade [32].




Fig. 4. A partícula na posição x_a , após os *swaps* $(0, 2)$ e $(1, 3)$, finaliza na posição x_b . A subtração de posições pode ser entendida como a velocidade v que move a partícula inicialmente na posição x_a para a posição x_b , i.e. $x_b = x_a + v \rightarrow v = x_b - x_a$.

A adição de velocidades, vetores de *swaps*, ocorre através da

concatenação dos mesmos mantendo a ordem dos operandos, i.e., essa operação não é comutativa [32]. Da mesma maneira, a multiplicação da velocidade $v = (v_1, \dots, v_k)$ pelo escalar c , i.e. $cv = (v_1, \dots, v_{\lfloor c\|v\| \rfloor})$ é dividida em três casos:

- 1) $c = 0$: o produto retorna $cv = \{\}$;
- 2) $0 < c \leq 1$: o número de pares *swap* no vetor velocidade é truncado pelo maior inteiro menor que o produto $c\|v\|$;
- 3) $c > 1$: c é escrito como um inteiro q mais um número real $r < 1$, em que $cv = \underbrace{v + \dots + v}_{q \text{ vezes}} + rv$.

2) *Funções objetivo*: Considerando-se um conjunto de arestas E , que representam as vias em um mapa aproximado pelo grafo $G = \{V, E\}$. De forma que para toda aresta $e \in E$, $\ell \geq 0$ é o comprimento, denotado por ℓ_e . Além disso, entende-se por caminho uma sequência consecutiva de arestas. Destarte, o comprimento do caminho $Q \subseteq E$ é definido como $\ell(Q) = \sum_{e \in Q} \ell_e$. Enfim, sejam os nós $u, w \in V$ exemplos de pontos de inspeção, em um mapa, da rota de uma equipe: o caminho mais curto de u para w é definido por $\delta(u, w)$, que pode ser encontrado pelo algoritmo de Dijkstra [36].

Os pontos de início e fim da rota de cada equipe são, respectivamente, os lugares em que as equipes estavam no começo da inspeção e geralmente uma chave a ser manobrada. Desse modo, esses pontos são incluídos no vetor de decisão x apenas para o cálculo das funções objetivo. Para então, ao final serem removidos para assegurar que não sejam alterados pelas permutações executadas pelo Algoritmo 1.

Em (6) computa-se a distância percorrida por uma das M equipes ao inspecionar n pontos em $P \subseteq V | P = \{p_1, \dots, p_n\}$ e em (7), o deslocamento total. Em síntese, considerando-se a abordagem minsum [37]: ao minimizar a função f_1 , minimiza-se também o deslocamento de cada equipe.

$$l = \sum_{j=1}^{n-1} \ell(\delta(p_j, p_{j+1})) \quad (6)$$

$$f_1 = \sum_{j=1}^M l_j \quad (7)$$

Em virtude da velocidade de inspeção ser menor que a velocidade de deslocamento, as arestas são separadas em dois grupos, para o cálculo do tempo decorrido: o que contém os pontos de inspeção, em que as equipes trafegam com a velocidade de inspeção v_i e o tempo de inspeção t_i , definido por (8); e aquele que não contém os pontos de inspeção, apenas usado para deslocamento com uma velocidade de deslocamento v_d , em que o tempo t_d é calculado por (9).

$$t_i = \sum_{j=1}^{n-1} \frac{\ell_e}{v_i}, \quad \forall e = (u, w) \in \delta(p_j, p_{j+1}), \quad (8)$$

$$u, w \in V | u \in P \vee w \in P$$

$$t_d = \sum_{j=1}^{n-1} \frac{\ell_e}{v_d}, \quad \forall e = (u, w) \in \delta(p_j, p_{j+1}), \quad (9)$$

$$u, w \in V \setminus P$$

O tempo gasto por cada equipe na inspeção e deslocamento é dado por (10) e o tempo máximo gasto entre todas as equipes por (11). Como há simultaneidade na operação, minimizando-se f_2 , como na abordagem minmax [37], igualmente minimiza-se o tempo total gasto na inspeção de um setor, caracterizando-se como um objetivo de gargalo [23].

$$t = t_d + t_i \quad (10)$$

$$f_2 = \max\{t_j\}, \quad j = \{1, \dots, M\} \quad (11)$$

Na generalidade, as funções objetivo f_1 e f_2 são conflitantes sob a ótica de um mTSP [24]. Em um panorama com várias equipes, de número variável na inspeção, a soma dos deslocamentos de todas as equipes tende a aumentar com o número de equipes destinadas à inspeção. Já a duração da inspeção, sob os mesmos parâmetros, tende a diminuir, devido à simultaneidade da operação. Porém, existem casos em que ambos os objetivos estão em consonância, em virtude do posicionamento inicial das equipes e da dispersão dos pontos de inspeção. Todas essas situações são previstas pela abordagem da fronteira de Pareto através do próprio conceito de ϵ -dominância descrito na Subseção II-B3. Desta forma, a seleção das soluções candidatas ao conjunto não exclui a possibilidade de conciliação dos objetivos, a única premissa é ser não ϵ -dominada, desse modo apenas o formato da fronteira de Pareto seria alterado.

3) *Atualização do arquivo externo*: Seja $\min\{f_1(x), \dots, f_m(x)\}$ um caso em que é necessário minimizar m funções objetivo conflitantes $f_i : \mathbb{R}^n \rightarrow \mathbb{R}, i \in \{1, \dots, m\}$, simultaneamente. Os vetores decisão $x = (x_1, \dots, x_n)$, que são as posições das partículas, pertencem à região factível S , i.e. $x \in S \subset \mathbb{R}^n$. A região factível objetiva $Z \subset \mathbb{R}^m$ é a imagem da região factível. Por conseguinte, os vetores objetivo são os elementos de Z e consistem em $f(x) = (f_1(x), \dots, f_m(x))$ [28]. Por fim, o conceito de ϵ -dominância, empregado na atualização do arquivo externo [38], é estabelecido pelas Definições (1), (2), (3) e (4).

Definição 1: (Dominância) Dados $x_1, x_2 \in S$. Então x_1 domina x_2 , i.e. $x_1 \prec x_2 \iff \forall i \in \{1, \dots, m\} : f_i(x_1) \leq f_i(x_2) \wedge \exists j \in \{1, \dots, m\} : f_j(x_1) < f_j(x_2)$.

Definição 2: (Conjunto de Pareto) Seja $F \subseteq \mathbb{R}^m$ um conjunto de vetores. O conjunto de Pareto $F^* \subseteq F | F^* := \{x_1 \in F | \neg \exists x_2 \in F : x_2 \prec x_1\}$.

Definição 3: (ϵ -dominância) Dados $x_1, x_2 \in S$. Então x_1 ϵ -domina x_2 para algum $\epsilon > 0$, i.e. $x_1 \prec_\epsilon x_2 \iff \forall i \in \{1, \dots, m\} : f_i(x_1)(1 + \epsilon)^{-1} \leq f_i(x_2) \wedge \exists j \in \{1, \dots, m\} : f_j(x_1)(1 + \epsilon)^{-1} < f_j(x_2)$.

Definição 4: (Conjunto ϵ -Pareto) Seja F^* o conjunto de Pareto, $F \subseteq \mathbb{R}^m$ um conjunto de vetores e $\epsilon > 0$. O conjunto ϵ -Pareto, ou fronteira ϵ -Pareto, $F_\epsilon^* \subseteq F^* | F_\epsilon^* := \{\forall x_2 \in F | \exists x_1 \in F : x_1 \prec_\epsilon x_2\}$.

Para qualquer problema multi-objetivo de otimização, com m objetivos, e um $\epsilon > 0$, há uma fronteira ϵ -Pareto F_ϵ^* , armazenada no arquivo externo ou vetor A , na qual o número de soluções é limitado [39]. Desta forma, seja $1 \leq f_i \leq K, \forall i \in \{1, \dots, m\}$, existe um conjunto F_ϵ^* contendo $\|A\| =$

$\|F_\epsilon^*\| \leq \left[\frac{\log K}{\log(1+\epsilon)} \right]^{(m-1)}$ soluções, o que limita o tamanho do arquivo [40].

III. RESULTADOS E DISCUSSÃO

A. Testes

Os testes foram realizados em uma rede de distribuição hipotética no mapa da Figura 5, um trecho da cidade de Chandler (Arizona, EUA) cujas coordenadas centrais são $33^\circ 17' 59.6''N$ $111^\circ 49' 53.9''W$, gerado pelas bibliotecas OSMnx [41] e Networkx [42], para extrair o grafo das vias de *Open Street Maps* [43] e a modelagem do grafo, respectivamente. Embora seja possível a otimização dos parâmetros, inclusive através do próprio PSO [44], foram escolhidos alguns valores padrão e outros arbitrários. Também foi suprimida a discussão sobre a variação dos parâmetros ao longo das iterações, conforme os casos ilustrados em [34]. Já que o propósito do artigo é apresentar uma proposta multi-objetivo baseada em Pareto para a otimização do roteamento de equipes de inspeção e manutenção da rede elétrica. Desta forma, o exame de tamanho $N = 100$ possibilita a geração de 100 novas soluções a cada iteração. Além disso, os parâmetros $w = 0,5$, $C_1 = C_2 = 1$ foram estabelecidos de acordo com [32]. Já C_3 foi ajustado em 0,7 para impedir a convergência prematura e melhorar a exploração das partículas pelo espaço da busca [34]. Por fim, o número máximo de iterações, utilizado como critério de parada, $k_{max} = 75000$ e $\epsilon = 0,05$ [38]. Para cada equipe, a velocidade de inspeção considerada $v_i = 20[km/h]$ e a velocidade de deslocamento $v_d = 40[km/h]$. Além disso, o número de equipes de inspeção $M = 2$ e uma equipe extra para o fechamento da chave estratégica. Ademais, o tempo de preparação das equipes para a operação das chaves $t_{p_o} = t_{p_c} = t_p = 0,1[h]$ e o tempo de operação das chaves $t_{o_o} = t_{o_c} = t_o = 0,025[h]$.

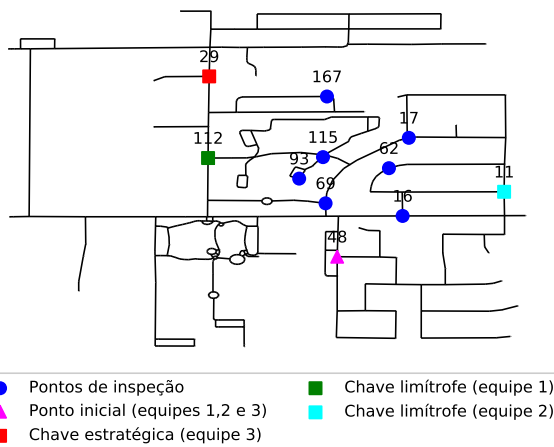
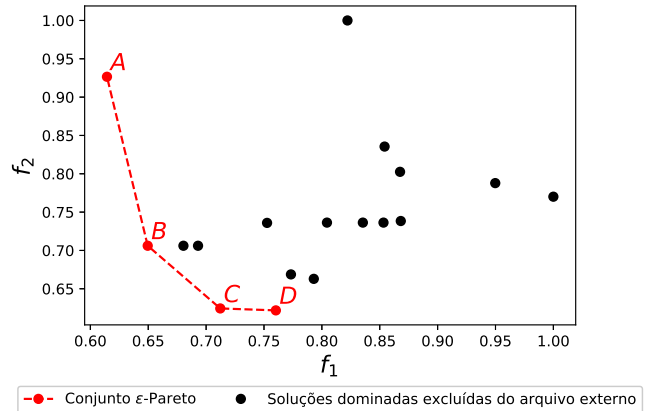


Fig. 5. Mapa usado para o teste, em que os nós 16, 17, 62, 69, 93, 115 e 167 representam os pontos de inspeção; a chave estratégica, nó 29, quando fechada restaura a energia do setor; os nós 11 e 112 são chaves limítrofes, que isolam o setor. Por simplicidade, nos testes, todas as equipes iniciam suas rotas no mesmo nó 48, embora o algoritmo possibilite múltiplos pontos de início, como em situações reais.

B. Resultados

O conjunto ϵ -Pareto, na Figura 6a, resultante do Algoritmo 1 é constituído por soluções não-dominadas que se resumem nas opções de rota da Figura 6b. Dentre as opções, o ponto A possui menor distância percorrida que B, por outro lado, B possui menor tempo de operação. É importante notar, nesse caso, que de acordo com a função objetivo f_1 , a distância total, é vantajoso ter apenas uma equipe inspecionando todos os pontos. De outra forma, para se reduzir o tempo de inspeção, função objetivo f_2 , a opção D mostrou o melhor resultado.



(a) Os pontos em preto foram sistematicamente deletados do arquivo externo e substituídos por soluções melhores até atingir o conjunto ϵ -Pareto, tracejado em linha vermelha.

| | 0 | 1 | 2 | 3 | 4 | 5 | 6 | 7 |
|---|-----|-----|-----|-----|-----|----|-----|----|
| A | 69 | 16 | 62 | 17 | 115 | 93 | 167 | * |
| B | 69 | 17 | 115 | 93 | 167 | * | 16 | 62 |
| C | 69 | 115 | 93 | 167 | * | 16 | 62 | 17 |
| D | 167 | * | 69 | 93 | 115 | 17 | 62 | 16 |

(b) As quatro soluções igualmente boas que permaneceram no arquivo.

Fig. 6. Soluções que permaneceram no arquivo após a execução do Algoritmo 1.

As soluções obtidas nos testes foram discriminadas na Tabela I. Na qual, considerando-se a opção A: as três equipes começam no nó 48. Sequencialmente, a equipe 3 se desloca até a chave estratégica, nó 29, faz as preparações e espera o comando para o fechamento da chave que energiza o setor. Enquanto isso, a equipe 1 realiza a inspeção nos pontos 69, 16, 62, 17, 115, 93 e 167 e termina a jornada na chave limítrofe, nó 112, finalizando a missão com a abertura da mesma. Simultaneamente, a equipe 2 se desloca até a chave limítrofe, nó 11, e finaliza com a sua abertura. O tempo total de recomposição do setor foi de 0,240[h], considerando-se o

deslocamento, inspeção, a abertura das chaves limítrofes e o fechamento da chave estratégica.

Inicialmente, visou-se uma validação da capacidade do algoritmo de resultar soluções vantajosas para o problema do roteamento de equipes, considerando-se os dois objetivos simultaneamente, com essência na abordagem baseada em Pareto. Consequentemente, não houve foco na otimização dos parâmetros ou um estudo aprofundado na quantidade de iterações necessárias para o algoritmo convergir. Desta forma, a Figura 7 demonstra que apesar do número máximo de iterações considerado para simulação ser elevado, não houve alteração no arquivo após a iteração 604. É possível concluir que a partir desse ponto, o algoritmo já havia convergido para o conjunto de soluções desejadas. Além disso, não houve preocupação em relação à capacidade do algoritmo de ser executado em tempo real, esse assunto deve ser abordado de forma mais aprofundada.




Fig. 7. O número de alterações no arquivo contempla a inserção de uma nova solução não ϵ -dominada ou a substituição de um conjunto já existente, contendo uma ou mais soluções, por uma que o ϵ -domine. Adicionalmente, após a iteração de número 604 não houve mais alterações no arquivo.

C. Discussão

Em contraste com as abordagens com foco na otimização em um único objetivo, como a redução da distância percorrida em [14], [15] e [16] e o grau de importância em [17], o roteamento das equipes de inspeção, sob uma ótica multi-objetivo, visou tanto o menor tempo quanto o menor deslocamento total. O paradigma multi-objetivo obteve pontos intermediários conciliatórios de ambos os objetivos, como os pontos *B* e *C* da Figura 6, que dificilmente seriam obtidos com abordagens de objetivo único. Estas geralmente produzem soluções que se assemelham a opção *A*, por se tratarem de instâncias ou casos degenerados de um problema multi-objetivo [45]. Desta forma, o algoritmo utilizado produziu uma gama de soluções bem diversificadas para suportar o planejamento.

As abordagens agregativas como as propostas por [18], [19], [20] e [21], que geraram uma única solução em uma execução de otimização através de uma combinação linear dos objetivos, não abrangem a totalidade das soluções otimizadas [23]. Distintivamente, o algoritmo utilizado foi capaz de gerar um conjunto composto de diversas soluções factíveis, sem relação de

ϵ -dominância entre si. Portanto, a grande vantagem da meta-heurística utilizada em relação aos algoritmos agregativos é a gestão das soluções na fronteira da Pareto, considerando-se o espalhamento e o controle do tamanho do conjunto. Além disso, há a manutenção da diversidade das soluções sem perder a convergência, um dos grandes propósitos de um problema multi-objetivo [26]. Outra particularidade é que não há necessidade de se conhecer previamente a ordem de grandeza dos pesos a se utilizar em uma ponderação dos objetivos para se ter o direcionamento desejado das soluções.

O emprego do conceito de ϵ -dominância, cumpriu seu propósito já que o tamanho do arquivo foi controlado através da discretização da região factível objetiva e não por fatores específicos de restrição. Além disso, obteve-se um bom espalhamento das soluções. A posição das partículas mostrou uma codificação significativamente eficiente, na qual associada às operações discretas sempre manteve as soluções geradas na região factível, impedindo execuções descartáveis do algoritmo. Esse fator se mostra importante em comparação com outras heurísticas, como em [15], em que é possível gerar soluções irrealizáveis e também utiliza-se de uma quantidade maior de memória computacional.

Trabalhos futuros devem incorporar o tráfego no objetivo de redução do tempo para um modelo mais realista. Também aconselha-se realizar simulações para determinar as possíveis localizações de falha, o tipo apropriado de equipe (manutenção ou inspeção) em conjunto com sua alocação (entrepasto ou em campo) e priorização de serviços. Adicionalmente, o número ótimo de equipes deve ser investigado, considerando-se o custo operacional. Finalmente, hiper-heurísticas e métodos para otimização de parâmetros devem ser testados para o aumento da eficiência, redução do custo computacional e convergência. Neste último caso, é recomendável avaliar as métricas de convergência multi-objetivo para otimizar o número de iterações necessárias. Ademais, é preciso investigar a possibilidade do algoritmo ser executado em tempo real.

IV. CONCLUSÃO

A meta-heurística MODPSO aplicada ao roteamento de equipes de inspeção e reparo da rede de distribuição de energia elétrica gerou um conjunto de soluções factíveis, que se ajustam a dois objetivos concorrentes: redução da distância total percorrida e a redução do tempo de inspeção. O algoritmo, aliado ao conceito da ϵ -dominância, realizou uma gestão eficiente do tamanho do conjunto de Pareto e garantiu o espalhamento das soluções através do mesmo. Isso permite uma gama de soluções bem diversificadas para suportar o planejamento de inspeção de um bom FDIR, em confluência com a redução do custo operacional, relativo à distância percorrida, bem como do tempo de falha.

Durante a simulação em uma situação hipotética, três equipes foram consideradas para o método da recomposição parcial, em que a uma delas foi designado o fechamento da chave estratégica para energizar o setor, enquanto às outras a inspeção dos pontos intermediários e a abertura das chaves limítrofes para isolamento do setor. Decorrem desta simulação diversas opções de rota, que reduziram o tempo de inspeção

TABELA I

DISTÂNCIA TOTAL PERCORRIDA PELAS EQUIPES DE INSPEÇÃO E OS TEMPOS GASTOS NA INSPEÇÃO, DESLOCAMENTO, PREPARAÇÃO, ESPERA E OPERAÇÃO DAS CHAVES PARA AS TRÊS EQUIPES DISPONÍVEIS DURANTE A RECOMPOSIÇÃO PARCIAL DE UM SETOR PARA TODAS AS SITUAÇÕES NO CONJUNTO ϵ -PARETO

| Equipe | Δ_i | $\frac{\Delta_i}{v_i}$ | $\frac{\Delta_d}{v_d}$ | t_p | t_w | t_o | t_{total} | |
|--------|------------|------------------------|------------------------|-------|-------|-------|-------------|-------|
| A | 1 | 2,478 | 0,090 | - | 0,100 | - | 0,025 | 0,215 |
| | 2 | 0,511 | 0,026 | - | 0,100 | - | 0,025 | 0,151 |
| | 3 | - | - | 0,025 | 0,100 | 0,090 | 0,025 | 0,240 |
| B | 1 | 1,854 | 0,069 | - | 0,100 | - | 0,025 | 0,194 |
| | 2 | 0,765 | 0,030 | - | 0,100 | - | 0,025 | 0,155 |
| | 3 | - | - | 0,025 | 0,100 | 0,069 | 0,025 | 0,219 |
| C | 1 | 1,575 | 0,061 | - | 0,100 | - | 0,025 | 0,186 |
| | 2 | 1,297 | 0,044 | - | 0,100 | - | 0,025 | 0,169 |
| | 3 | - | - | 0,025 | 0,100 | 0,061 | 0,025 | 0,211 |
| D | 1 | 1,353 | 0,054 | - | 0,100 | - | 0,025 | 0,179 |
| | 2 | 1,714 | 0,060 | - | 0,100 | - | 0,025 | 0,185 |
| | 3 | - | - | 0,025 | 0,100 | 0,060 | 0,025 | 0,210 |

das equipes. Tal redução se reflete na duração de falhas e, consequentemente, na melhoria de indicadores como o SAIDI. Além disso, afeta de maneira atenuante na utilização dos recursos durante as atividades de inspeção.

REFERÊNCIAS

- [1] A. Baggingi, *Handbook of power quality*. John Wiley & Sons, 2008.
- [2] P. Zailani, A. Lomi, and E. Nurcahyo, "Reliability analysis of distribution network based on reliability index assessment method, a case study," *International Journal of Smart Grid and Sustainable Energy Technologies*, vol. 1, no. 1, pp. 24–27, 2017.
- [3] Y. K. Bichpuriya, P. V. Navalkar, and S. A. Soman, "Benchmarking of reliability indices for electricity distribution utilities: approach and discussion," in *IET Conference on Reliability of Transmission and Distribution Networks (RTDN 2011)*. IET, 2011, pp. 14–19.
- [4] A. Kavousi-Fard and T. Niknam, "Optimal distribution feeder reconfiguration for reliability improvement considering uncertainty," *IEEE Transactions on Power Delivery*, vol. 29, no. 3, pp. 1344–1353, 2014.
- [5] A. Coelho, A. B. Rodrigues, and M. G. Silva, "Distribution network reconfiguration with reliability constraints," in *Power System Technology, 2004. PowerCon 2004. 2004 International Conference on*, vol. 2. IEEE, 2004, pp. 1600–1606.
- [6] M. Kezunovic, "Smart fault location for smart grids," *IEEE transactions on smart grid*, vol. 2, no. 1, pp. 11–22, 2011.
- [7] M. S. Choi, S. J. Lee, S. I. Lim, D. S. Lee, and X. Yang, "A direct three-phase circuit analysis-based fault location for line-to-line fault," *IEEE Transactions on Power Delivery*, vol. 22, no. 4, pp. 2541–2547, 2007.
- [8] J. C. S. Souza, M. A. P. Rodrigues, M. T. Schilling, and M. B. Coutto Filho, "Fault location in electrical power systems using intelligent systems techniques," *IEEE Transactions on power delivery*, vol. 16, no. 1, pp. 59–67, 2001.
- [9] P. E. Farias, A. P. Morais, G. C. Junior, and J. P. Rossini, "Fault location in distribution systems: A method considering the parameter estimation using a rna online," *IEEE Latin America Transactions*, vol. 14, no. 12, pp. 4741–4749, 2016.
- [10] J. Vasco, R. Ramlachan, J. Wong, and L. Wang, "An automated fault location system as a decision support tool for system operators," in *Protective Relay Engineers, 2008 61st Annual Conference for*. IEEE, 2008, pp. 556–572.
- [11] N. Perrier, B. Agard, P. Baptiste, J. M. Frayret, A. Langevin, R. Pellerin, D. Riopel, and M. Trépanier, "A survey of models and algorithms for emergency response logistics in electric distribution systems. part ii: Contingency planning level," *Computers & Operations Research*, vol. 40, no. 7, pp. 1907–1922, 2013.
- [12] D. Cheng, A. Onen, D. Zhu, D. Kleppinger, R. Arghandeh, R. P. Broadwater, and C. Scirbona, "Automation effects on reliability and operation costs in storm restoration," *Electric Power Components and Systems*, vol. 43, no. 6, pp. 656–664, 2015.
- [13] M. Freund and J. Mosher, "Autonomous inspections of utility networks," Technical Disclosure Commons, Tech. Rep., November 2016, "https://www.tdcommons.org/dpubs_series/317".
- [14] S. Johns, "Heuristics to schedule service engineers within time windows," *Journal of the Operational Research Society*, vol. 46, no. 3, pp. 339–346, 1995.
- [15] A. Chen, G. Yang, and Z. Wu, "Hybrid discrete particle swarm optimization algorithm for capacitated vehicle routing problem," *Journal of Zhejiang University-Science A*, vol. 7, no. 4, pp. 607–614, 2006.
- [16] N. D. Lagaros and M. G. Karlaftis, "A critical assessment of meta-heuristics for scheduling emergency infrastructure inspections," *Swarm and Evolutionary Computation*, vol. 1, no. 3, pp. 147–163, 2011.
- [17] Y. Tan, F. Qiu, A. K. Das, D. S. Kirschen, P. Arabshahi, and J. Wang, "Scheduling post-disaster repairs in electricity distribution networks," *IEEE Transactions on Power Systems*, 2019.
- [18] A. Weintraub, J. Aboud, C. Fernandez, G. Laporte, and E. Ramirez, "An emergency vehicle dispatching system for an electric utility in Chile," *Journal of the Operational Research Society*, vol. 50, no. 7, pp. 690–696, 1999.
- [19] V. J. Garcia, D. Bernardon, I. Guimarães, and J. Fonini, "Multi-objective real-time dispatching problem in electric utilities: An application to emergency service routing," in *Real-time Systems*, K. Jian, Ed. Rijeka: IntechOpen, 2016, ch. 5. [Online]. Available: https://doi.org/10.5772/62849
- [20] L. Al-Kanj, W. B. Powell, and B. Bouzaïene-Ayari, "The information-collecting vehicle routing problem: Stochastic optimization for emergency storm response," *arXiv preprint arXiv:1605.05711*, 2016.
- [21] M. Schmitz, V. J. Garcia, and D. P. Bernardon, "Matheuristic for emergency response in the electric distribution system with unforeseen islanding," *Electric Power Systems Research*, vol. 169, pp. 1–17, 2019.
- [22] T. Bektas, "The multiple traveling salesman problem: an overview of formulations and solution procedures," *Omega*, vol. 34, no. 3, pp. 209–219, 2006.
- [23] M. Ehrgott and X. Gandibleux, "Multiobjective combinatorial optimization—theory, methodology, and applications," in *Multiple criteria optimization: State of the art annotated bibliographic surveys*. Springer, 2003, pp. 369–444.
- [24] Y. Wang, Y. Chen, and Y. Lin, "Memetic algorithm based on sequential variable neighborhood descent for the minmax multiple traveling salesman problem," *Computers & Industrial Engineering*, vol. 106, pp. 105–122, 2017.
- [25] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Neural Networks, 1995. Proceedings., IEEE International Conference on*, vol. 4, 1995, pp. 1941–1948.
- [26] A. K. Shukla, P. Singh, and M. Vardhan, "An empirical study on multi-objective swarm algorithm for standard multi-objective benchmark problems," *Proceedings of 3rd International Conference on Internet of Things and Connected Technologies (ICIoTCT)*, 2018.
- [27] E. Zitzler, K. Deb, and L. Thiele, "Comparison of multiobjective evolutionary algorithms: Empirical results," *Evolutionary computation*, vol. 8, no. 2, pp. 173–195, 2000.
- [28] A. A. El-Sawy, M. A. Hussein, E.-S. M. Zaki, and A. A. A. Mousa, "Local search-inspired rough sets for improving multiobjective evolutionary algorithm," *Applied Mathematics*, vol. 5, no. 13, p. 1993, 2014.
- [29] M. F. Leung, S. C. Ng, C. C. Cheung, and A. K. Lui, "A new strategy for finding good local guides in mopso," in *Evolutionary Computation (CEC), 2014 IEEE Congress on*. IEEE, 2014, pp. 1990–1997.
- [30] A. C. Santos, A. C. B. Delbem, J. B. A. London, and N. G. Bretas, "Node-depth encoding and multiobjective evolutionary algorithm applied to large-scale distribution system reconfiguration," *IEEE Transactions on Power Systems*, vol. 25, no. 3, pp. 1254–1265, 2010.
- [31] J. K. Lenstra and A. H. G. R. Kan, "Complexity of vehicle routing and scheduling problems," *Networks*, vol. 11, no. 2, pp. 221–227, 1981.
- [32] M. Clerc, "Discrete particle swarm optimization, illustrated by the traveling salesman problem," in *New optimization techniques in engineering*. Springer, 2004, pp. 219–239.
- [33] J. E. Fieldsend and S. Singh, "A multi-objective algorithm based upon particle swarm optimisation, an efficient data structure and turbulence," in *Proceedings of the 2002 U.K. Workshop on Computational Intelligence*, 2002, pp. 37–44.

- [34] A. García-Villoria and R. Pastor, "Introducing dynamic diversity into a discrete particle swarm optimization," *Computers & Operations Research*, vol. 36, no. 3, pp. 951–966, 2009.
- [35] K. P. Wang, L. Huang, C. G. Zhou, and W. Pang, "Particle swarm optimization for traveling salesman problem," in *Machine Learning and Cybernetics, 2003 International Conference on*, vol. 3. IEEE, 2003, pp. 1583–1585.
- [36] E. W. Dijkstra, "A note on two problems in connexion with graphs," *Numerische mathematik*, vol. 1, no. 1, pp. 269–271, 1959.
- [37] B. Mor and G. Mosheiov, "Scheduling problems with two competing agents to minimize minmax and minsum earliness measures," *European Journal of Operational Research*, vol. 206, no. 3, pp. 540–546, 2010.
- [38] M. Laumanns, L. Thiele, K. Deb, and E. Zitzler, "Combining convergence and diversity in evolutionary multiobjective optimization," *Evolutionary computation*, vol. 10, no. 3, pp. 263–282, 2002.
- [39] C. H. Papadimitriou and M. Yannakakis, "On the approximability of trade-offs and optimal access of web sources," in *Foundations of Computer Science, 2000. Proceedings. 41st Annual Symposium on*. IEEE, 2000, pp. 86–92.
- [40] M. Laumanns, L. Thiele, E. Zitzler, and K. Deb, "Archiving with guaranteed convergence and diversity in multi-objective optimization," in *Proceedings of the 4th Annual Conference on Genetic and Evolutionary Computation*. Morgan Kaufmann Publishers Inc., 2002, pp. 439–447.
- [41] G. Boeing, "Osmnx: New methods for acquiring, constructing, analyzing, and visualizing complex street networks," *Computers, Environment and Urban Systems*, vol. 65, pp. 126–139, 2017.
- [42] A. A. Hagberg, D. A. Schult, and P. J. Swart, "Exploring network structure, dynamics, and function using networkx," in *Proceedings of the 7th Python in Science Conference*, G. Varoquaux, T. Vaught, and J. Millman, Eds., Pasadena, CA USA, 2008, pp. 11–15.
- [43] OpenStreetMap contributors, "Planet dump retrieved from <https://planet.osm.org>," <https://www.openstreetmap.org>, 2017.
- [44] G. S. Tewolde, D. M. Hanna, and R. E. Haskell, "Enhancing performance of pso with automatic parameter tuning technique," in *2009 IEEE Swarm Intelligence Symposium*. IEEE, 2009, pp. 67–73.
- [45] K. Deb, "Multi-objective optimization," in *Search methodologies*. Springer, 2014, pp. 403–449.

Carlos Dias Maciel possui graduação em Eletrônica pelo IME Brasil (1989) e Ph.D. em Engenharia Biomédica pela COPPE / UFRJ Brasil (2000). Atualmente é professor associado da USP (Universidade de São Paulo) Brasil e tem experiência na área de Engenharia Biomédica, com ênfase em processamento de sinais e instrumentação biomédica. Atua principalmente nos seguintes temas: processamento de sinais biomédicos, modelos probabilísticos (Redes Bayesianas Dinâmicas) e algoritmos computacionalmente intensos. Ensina Sinais e Sistemas e Processamento Digital de Sinais para estudantes de graduação e Reconhecimento de Padrões e Processamento Estatístico de Sinais para o programa de pós-graduação.

Luiz Desuó Neto possui graduação em Engenharia Elétrica - Ênfase em Eletrônica pela Universidade de São Paulo (2016). Possui interesse nos temas de resiliência e confiabilidade de sistemas, sistemas inteligentes, algoritmos bioinspirados e otimização.

Michel Bessani possui graduação (2012), mestrado (2015) e doutorado (2018) em Engenharia Elétrica pela Escola de Engenharia de São Carlos, da Universidade de São Paulo (EESC-USP). Atualmente é Professor no Departamento de Engenharia Elétrica na Escola de Engenharia da Universidade Federal de Minas Gerais (DEE-UFMG). Suas áreas de interesse são: confiabilidade e resiliência de sistemas, modelagem estatística e inteligência computacional.

Rodrigo Zempulski Fanucchi possui graduação em Engenharia Elétrica pela Universidade Estadual de Londrina (2004) e mestrado pela Universidade de São Paulo na Escola de Engenharia de São Carlos (2014) na área de Sistemas Elétricos de Potência. Atua ainda como gerente do Departamento de Procedimentos de Operação e Manutenção da Distribuição da Companhia Paranaense de Energia, tendo atuado ainda nas áreas de projetos e obras e controle de qualidade. Tem experiência na área de sistemas elétricos de potência, atuando nas subáreas de proteção digital de sistemas elétricos de potência com utilização de técnicas inteligentes e extração de dados por Transformadas Wavelets e de reconfiguração de sistemas de distribuição de energia com ênfase em algoritmos evolutivos.

Tadeu Junior Gross Possui graduação em Engenharia Elétrica pela Universidade Estadual de Londrina (UEL-PR), mestrado em Engenharia Elétrica pela Escola Politécnica da Universidade de São Paulo (Poli-USP) e doutorado em Engenharia Elétrica pela Escola de Engenharia de São Carlos (EESC-USP), obtendo os títulos em 2002, 2005 e 2018. Desde 2011 é Perito Criminal Oficial da Polícia Científica (POLITEC-MT), onde atualmente trabalha na área de Processamento Forense de Sinais Analógicos e Digitais de Áudio, Imagem e Vídeo. Suas área de interesse são: Processamento Digital de Sinais, Redes Bayesianas, Aprendizagem de Modelos Probabilísticos e Reconhecimento de Padrões.