

Definição do *Layout* de uma rede de sensores via algoritmo de evolução diferencial multiobjetivo

Jean N. R. Araujo¹, Leticia M. Pereira¹, Lucas S. Batista²

- ¹ Operations Research and Complex Systems Laboratory (ORCS-Lab)
Programa de Pós-Graduação em Engenharia Elétrica
Universidade Federal de Minas Gerais - UFMG
Av. Antônio Carlos 6627, 31270-901
Belo Horizonte, Minas Gerais, Brasil
- ² Operations Research and Complex Systems Laboratory (ORCS-Lab)
Departamento de Engenharia Elétrica
Universidade Federal de Minas Gerais - UFMG
jeannra@ufmg.br, leticiamayra@ufmg.br, lusoba@ufmg.br

Resumo Quando as redes de sensores sem fio são projetadas para realizar monitoramento, é essencial determinar a adequada posição dos sensores de modo que a área coberta possa ser maximizada. Além disso, é fundamental garantir confiabilidade na entrega dos dados à estação base. O presente trabalho lida com estes dois objetivos simultaneamente, apresentando uma formulação multiobjetivo e propondo um algoritmo Evolução Diferencial Multiobjetivo dedicado ao problema. A finalidade é, além de garantir conectividade, obter um conjunto de soluções de compromisso entre cobertura e confiabilidade e, a partir disto, direcionar a busca por soluções pertencentes a uma região de interesse por meio de uma estratégia alternativa de dominância. Esta proposta obteve uma boa representação da fronteira *Pareto* em todos os cenários analisados e foi capaz de alcançar soluções promissoras na região de interesse.

Keywords: Redes de sensores, Cobertura, Confiabilidade, Evolução Diferencial, Otimização Multiobjetivo

Abstract. When the wireless sensor networks are designed to perform monitoring, it is essential to determine the proper sensors positioning so that the covered area can be maximized. Besides that, it is fundamental to guarantee data delivery reliability to the base station. This paper deals with these two objectives simultaneously, presenting a multiobjective formulation and proposing a Multiobjective Differential Evolution algorithm dedicated to the problem. The goal is, in addition to ensuring connectivity, to obtain a trade-off between coverage and reliability and, from this, to guide the search for solutions belonging to a region of interest through an alternative dominance strategy. This proposal reached a good representation of the Pareto front in all scenarios analyzed and it was able to arrive at promising solutions in the region of interest.

Keywords: Sensor Networks, Coverage, Reliability, Differential Evolution, Multiobjective Optimization

1 Introdução

As redes de sensores sem fio (*Wireless Sensor Networks - WSNs*) são, atualmente, uma das mais proeminentes tecnologias de rede de comunicação. Dentre as várias aplicações que têm emergido, pode-se destacar redes de sensores projetadas para detectar e monitorar fatores de risco ambientais, industriais e estruturais [3], [7], [12]. Uma vez implantados, normalmente espera-se que os sensores realizem duas tarefas: i) monitoramento e ii) transmissão dos dados coletados para alguma estação base. Sobre a primeira função, existe uma diversidade de tipos de sensores, tais como sensores acústicos, ópticos, sísmicos, climáticos, etc. Sobre a segunda função, é importante destacar que, em muitos casos, os sensores não têm capacidade de armazenamento ou autonomia energética para transmitir seus dados diretamente para uma estação base. Por isso, é comum projetar a rede de modo que os dados sejam transmitidos para um nó estrategicamente posicionado e com autonomia de energia (*sink*), a fim de que este possa encaminhar as coletas para a estação base [17]. Além disso, é interessante permitir que os sensores possam encaminhar os dados para o nó *sink* através de sensores intermediários. Isto permite que a área de sensoriamento seja estendida.

Em [11] é apresentada uma revisão a respeito da multiplicidade de objetivos que podem ser tratados ao implantar uma rede de sensores. Considerando o problema específico de projetar o *layout* da rede, é possível identificar alguns importantes requerimentos, tais como: maximizar a área coberta pelo sensoriamento, minimizar o consumo de energia, maximizar o tempo de vida da rede, minimizar o número de nós sensores, maximizar a conectividade, etc. Diversos trabalhos, como em [4], [14] e [16], lidam com a necessidade de maximizar a área coberta e o tempo de vida da rede. Isto sugere um caráter multiobjetivo ao problema, uma vez que o aumento da área de sensoriamento representa maior necessidade de rotas com nós intermediários, o que pode gerar mais perdas e retransmissões, reduzindo assim a autonomia energética dos nós e o tempo de vida da rede. A fim de modelar este problema multicritério, os dois objetivos a seguir são tratados aqui: i) maximizar a área coberta pelo sensoriamento e ii) maximizar a Taxa de Recepção de Pacotes (TRP) média na rede. Esta modelagem foi realizada de tal modo que é possível garantir a conectividade entre todos os nós sensores e o nó *sink*.

Para resolver o problema descrito, este trabalho propõe uma versão dedicada do algoritmo Evolução Diferencial Multiobjetivo (*Differential Evolution for Multiobjective Optimization - DEMO*) [15]. A fim de lidar com o problema de conectividade e roteamento, o algoritmo de *Dijkstra* foi empregado. Também é proposta uma estratégia de dominância adicional para direcionar a busca evolutiva para uma região mais atrativa da fronteira *Pareto*. Tanto o algoritmo para mapear a fronteira, quanto o algoritmo guiado por preferências apresentaram resultados promissores, considerando os dois objetivos tratados.

Este artigo está dividido da seguinte forma: a Seção 2 apresenta a formulação e a modelagem matemática do problema. Na Seção 3 os algoritmos propostos são detalhados. São descritos e discutidos na Seção 4 os procedimentos experimentais e o desempenho dos algoritmos. Na Seção 5 é feita a conclusão do trabalho.

2 Formulação do problema

Uma rede de sensores sem fio pode ser representada na forma de um grafo direcionado $G(V, E)$, onde os vértices $V = \{1, 2, \dots, n\}$ caracterizam um conjunto finito de nós, e as arestas $E = \{1, 2, \dots, m\}$ definem um conjunto finito de *links* entre os nós. Um subconjunto $N_{(i)} \subset V$ de vizinhos é definido dentro da área de cobertura τ_c de determinado nó i . No contexto de transmissão, há um nó destino $sink \in V$ e um nó de origem $SN \in V$. A finalidade é criar uma rota que conecte SN ao nó $sink$. No contexto apresentado aqui, todos os nós sensores precisam transmitir os dados de monitoramento para o mesmo destino. Logo, garantir conectividade significa que deve existir no mínimo um caminho entre cada sensor e o nó $sink$.

No entanto, o problema não se resume apenas em definir rotas. É necessário garantir que todos os dados, ou a maioria deles, sejam transmitidos com sucesso ao destino. Isso sugere a definição de algum critério de qualidade que permita incluir *links* na rota que possam assegurar o mínimo de confiabilidade na transmissão. Portanto, cada *link* ℓ , $\ell = [1, m]$, deve ter uma métrica de custo ou utilidade u_ℓ associada. Assim, se não for possível estabelecer uma conexão estável entre o sensor i e o nó $sink$, deve ser selecionado um nó retransmissor F_t do subconjunto de vizinhos $N_{(i)} \subset V$, tendo como critério de escolha a métrica pré-definida. O que se deseja neste caso é gerar uma rota $R = (SN, F_1, \dots, F_n, sink) \subset V$ que conecte SN ao nó $sink$.

Além de garantir conectividade e alta Taxa de Recepção de Pacotes (TRP), em redes de sensores sem fio é necessário assegurar que o máximo da área de interesse será sensoriada. A fim de modelar a cobertura da rede, a área de monitoramento pode ser discretizada em um conjunto de pontos de demanda que requerem sensoriamento. De maneira geral, toda a área é fragmentada na forma de k pequenos quadrados, onde o centro de cada quadrado é considerado como um ponto de demanda, gerando um conjunto $D = \{1, 2, \dots, k\}$ de pontos de demanda [16]. Cada nó sensor tem um raio de sensoriamento τ_s definido, sendo que, quaisquer pontos de demanda dentro desse raio são considerados cobertos por tal nó. Note, portanto, que existem duas áreas de cobertura que precisam ser consideradas para dado sensor i , a saber, o raio de sensoriamento τ_s e o raio de comunicação τ_c [13,16].

A finalidade do processo de otimização tratado nesse trabalho é encontrar as coordenadas dos nós sensores em um plano bi-dimensional. Portanto, as variáveis de decisão compõem um vetor $P = \{x_1, x_2, \dots, x_n, y_1, y_2, \dots, y_n\}$ que contém as posições dos nós no plano. Essas posições precisam ser definidas de uma forma que satisfaça os seguintes objetivos: i) maximizar a TRP da rede; ii) maximizar a área coberta pelo sensoriamento; iii) garantir conectividade entre todos os nós sensores e o nó $sink$.

A TRP pode ser estimada previamente analisando a qualidade do *link* nas camadas inferiores, a partir de uma abordagem *crosslayer* [18]. Portanto, a TRP entre os nós i e j é estimada como segue

$$TRP_{i,j} = \left(1 - \frac{1}{2} \exp \left(\frac{-SINR_{i,j} B_N}{2 N} \right) \right)^{8L} \quad (1)$$

em que L representa o tamanho do pacote a ser transmitido em *bytes*, B_N descreve a taxa de transmissão de dados disponível, N é o ruído introduzido na comunicação e SINR (*Signal-to-interference-plus-noise ratio*) é definido como a potência de um certo sinal de interesse dividido pela soma da força de interferência (de todos os outros sinais de interferência) e a potência de algum ruído de fundo [1]. A TRP do *link* com a pior taxa de recepção de pacotes pode ser definida como a TRP da rota, como segue

$$TRP_{i,sink} = \min(TRP_{(i,j)}) \quad (2)$$

Logo, a primeira função que será considerada no problema é dada a seguir

$$f_1 = \frac{1}{n} \times \sum_{(i,sink) \in R} TRP_{(i,sink)} \quad (3)$$

onde n é o número de nós sensores. O que se busca é maximizar a média de taxa de recepção de pacotes na rede. O segundo objetivo é maximizar a área coberta pela rede. Para tanto, a função abaixo foi derivada

$$f_2 = \frac{\sum_{i \in D} h_i}{k} \quad (4)$$

onde h_i assume o valor 1 (um) se o ponto de demanda i está coberto e 0 (zero) caso contrário, enquanto k é o número total de pontos de demanda. Portanto, a quantidade de pontos de demanda cobertos dividido pela quantidade de pontos de demanda descreve a taxa de cobertura da rede.

Por fim, o objetivo de garantir a conectividade pode ser alcançado adicionando as restrições a seguir [16]:

$$\sum_{(i,j) \in E} z_{i,j} - \sum_{(j,i) \in E} z_{j,i} = 0, \forall i \in V \setminus \{SN, sink\} \quad (5)$$

$$\sum_{(SN,j) \in E} z_{SN,j} = 1, \quad (6)$$

$$\sum_{(j,sink) \in E} z_{j,sink} = 1,$$

$$z_{i,j} \in \{0, 1\}, \forall (i, j) \in E \quad (7)$$

As restrições descritas em (5) e (6) asseguram fluxo e que existe no mínimo um caminho entre cada sensor e o *sink*, respectivamente. A variável $z_{i,j}$ assume o valor 1 (um) se o *link* (i, j) faz parte da rota de um dado sensor e 0 (zero), caso contrário. O arranjo do modelo fica portanto na forma vetorial como segue

$$\max \left(f_1 = 1/n \times \sum_{(i,sink) \in R} TRP_{(i,sink)}, f_2 = \sum_{i \in D} h_i/k \right) \quad (8)$$

com as Eqs. (5), (6) e (7) como restrições que visam garantir a conectividade. Em problemas de otimização multiobjetivo tem-se um vetor $\mathbf{f} : \mathbb{R}^n \rightarrow \mathbb{R}^{n_f}$ de funções objetivo. Supondo um problema de maximização tem-se, portanto [9]:

$$\begin{aligned} \max_{\mathbf{x}} \quad & [f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_{n_f}(\mathbf{x})] \\ \text{s.a.} \quad & \mathbf{x} \in S, \end{aligned} \tag{9}$$

onde n_f é o número de funções objetivo, S é a região viável no espaço de decisão, \mathbf{x} é o vetor de decisão e $f_i(\mathbf{x})$ representa a i -ésima função objetivo. Nesses problemas, o conceito de ótimo é usualmente definido por meio da ideia de dominância *Pareto*. Dada duas soluções, \mathbf{x}_1 e \mathbf{x}_2 , \mathbf{x}_1 *Pareto*-domina \mathbf{x}_2 se ambas as condições a seguir são satisfeitas:

1. $f_i(\mathbf{x}_1) \geq f_i(\mathbf{x}_2), \forall i \in \{1, 2, \dots, n_f\}$
2. $\exists i \in \{1, 2, \dots, n_f\} \mid f_i(\mathbf{x}_1) > f_i(\mathbf{x}_2)$

Em resumo, \mathbf{x}_1 não é pior que \mathbf{x}_2 em nenhum objetivo e \mathbf{x}_1 é melhor que \mathbf{x}_2 em no mínimo um dos objetivos [5,9]. Se \mathbf{x}_1 não *Pareto*-domina \mathbf{x}_2 e \mathbf{x}_2 não *Pareto*-domina \mathbf{x}_1 , essas soluções são ditas incomparáveis. No sentido *Pareto*, as soluções ótimas são aquelas que não são dominadas por nenhuma outra solução da região factível. Todas as soluções ótimas geram uma fronteira no espaço de objetivos que é chamada de fronteira *Pareto*.

No entanto, existem relações de dominância adicionais que podem ser exploradas em problemas específicos. Uma relação variante da dominância *Pareto* é a *cone*-dominância, que, posteriormente, será utilizada no contexto do problema tratado aqui. A ideia é manipular a região de dominância, que agora pode ser definida como um cone de abertura $C_\theta = \{\mathbf{y} \in \mathbb{R}^{n_f} : \Theta \mathbf{w} = \mathbf{y}, \text{ com } \mathbf{w} \geq 0\}$, onde, em \mathbb{R}^2 , $\Theta = \begin{pmatrix} 1 & \theta_1 \\ \theta_2 & 1 \end{pmatrix}$, e $\theta_i \in [0, 1]$. Logo, dada duas soluções, \mathbf{x}_1 e \mathbf{x}_2 , \mathbf{x}_1 *cone*-domina \mathbf{x}_2 se e somente se: $f(\mathbf{x}_2) - f(\mathbf{x}_1) \in C_\theta$ com $f(\mathbf{x}_1) \neq f(\mathbf{x}_2)$ [5]. Assim, θ controla a abertura, onde $\theta > 0$ abre o cone e $\theta < 0$ fecha o cone.

3 Algoritmos Propostos

Nesta seção são descritos os algoritmos empregados para resolver o problema. Inicialmente, vale ressaltar como a garantia de conectividade é assegurada por meio das restrições apresentadas anteriormente. Essencialmente, como a TRP de cada par de arestas é estimada a partir da distância entre os nós, uma matriz de adjacência é gerada, e estes valores irão representar o custo de cada *link*. A fim de garantir esta conectividade e a partir dos valores de TRP dos pares de sensores, o algoritmo de *Dijkstra* [8] foi aplicado para descobrir o caminho mínimo de cada sensor para o nó *sink*. Desta forma, com base na saída do algoritmo de *Dijkstra*, é possível obter a $TRP_{i,sink}$ da rota e a TRP média da rede (f_1).

3.1 DEMO

O Algoritmo 1 é uma implementação clássica da meta-heurística Evolução Diferencial para Otimização Multiobjetivo (*Differential Evolution for Multiobjective Optimization - DEMO*) [15].

Algoritmo 1 *DEMO*: Abordagem multiobjetivo utilizando DE

```
1:           ▷ Conecta e Avalia população de indivíduos gerados aleatoriamente
2:  $pop \leftarrow ConectaAvalia(pop)$ 
3: while condição de parada não é satisfeita do
4:   for  $i \leftarrow 1 : s$  do
5:           ▷ Cria solução candidata a partir do pai  $pop_i$ .
6:      $novo \leftarrow CriaCandidato(pop_i)$ 
7:      $novo \leftarrow ConectaAvalia(novo)$ 
8:     if  $novo$  Pareto-domina  $pop_i$  then
9:        $pop_i \leftarrow novo$            ▷ candidato substitui pai
10:    else if  $pop_i$  Pareto-domina  $novo$  then
11:       $novo \leftarrow \emptyset$            ▷ descarta solução
12:    else
13:       $pop_{(s+1)} \leftarrow novo$        ▷ adiciona candidato na população
14:    end if
15:  end for
16:   $pop \leftarrow Truncagem(pop)$ 
17:   $FP \leftarrow ObtemFronteiraPareto()$ 
18: end while
```

Na função *CriaCandidato*, um indivíduo mutado é gerado a partir de uma perturbação em algum indivíduo da população. Esta perturbação é um vetor-diferença obtido da operação descrita abaixo:

$$\mathbf{y}_i = \mathbf{x}_{n_1} + \beta \times (\mathbf{x}_{n_2} - \mathbf{x}_{n_3}), \quad n_1, n_2, n_3 \in \{1, \dots, s\} \text{ e } i \neq n_1 \neq n_2 \neq n_3 \quad (10)$$

em que \mathbf{y}_i representa a i -ésima solução perturbada e β é um fator de escala aplicado ao vetor-diferença. O vetor \mathbf{x}_{n_1} , ao qual é aplicado a mutação diferencial, é denominado de *vetor base*. A solução candidata é criada a partir de uma recombinação entre \mathbf{x}_i e \mathbf{y}_i . Aqui, é utilizada a recombinação discreta apresentada na versão clássica do algoritmo [10].

Observe que o critério de seleção é baseado no conceito de dominância *Pareto* anteriormente discutido. O indivíduo pai (pop_i) somente será substituído se a solução candidata ($novo$) dominá-lo. Caso as duas soluções sejam incomparáveis, ambas sobrevivem. A truncagem (linha 16) consiste em classificar os indivíduos com base na relação de dominância *Pareto* e na métrica de distância de aglomeração (crowding distance metric) [6]. O procedimento de truncagem mantém na população apenas os s melhores indivíduos.

3.2 *DEMO*_{best}

Baseado no DEMO, propõe-se neste trabalho algumas alterações que visam melhorar a diversidade e o processo de convergência das soluções em direção à fronteira *Pareto* real. Na mutação do algoritmo clássico de evolução diferencial [10], o *vetor de base* \mathbf{x}_{n_1} da Eq. (10) é escolhido aleatoriamente da população. Uma estratégia que favorece a convergência é escolher este vetor aleatoriamente do

conjunto de soluções não dominadas. No entanto, apesar de apresentar maior velocidade no processo de convergência, esta estratégia pode reduzir rapidamente a diversidade. Ao otimizar funções multimodais, tal característica pode gerar um inconveniente, onde os indivíduos prematuramente convergem para mínimos locais. A fim de reduzir tal pressão seletiva, a equação a seguir é proposta:

$$\mathbf{y}_i = \mathbf{x}_i + \lambda(\mathbf{x}_{nao_dominado} - \mathbf{x}_i) + \beta \times (\mathbf{x}_{n_2} - \mathbf{x}_{n_3}) \quad (11)$$

em que $\lambda \in [0, 1]$. A expressão $\mathbf{x}_i + \lambda(\mathbf{x}_{nao_dominado} - \mathbf{x}_i)$ representa agora o *vetor de base* que foi gerado a partir de uma das soluções não dominadas. Ou seja, tem-se um ponto aleatoriamente construído sobre o segmento que interliga \mathbf{x}_i e $\mathbf{x}_{nao_dominado}$.

Outra modificação proposta foi variar o fator de escala β dentro de uma faixa contínua, ao invés de considerar um valor fixo. O autor em [10] argumenta que essa variação do fator de escala pode colaborar para o aumento da diversidade de vetores-diferença e de possíveis soluções que podem ser geradas a partir dessa operação, o que também contribui para a redução dos fatores que podem provocar estagnação do algoritmo. Assim, o valor de β é definido em cada iteração seguindo a equação abaixo:

$$\beta_i = \beta_0 + \mathcal{U}_{[-\alpha, \alpha]}, \quad i \in \{1, \dots, s\} \quad (12)$$

em que α é o fator que delimita os limites inferior ($-\alpha$) e superior (α) ao gerar um valor aleatório com distribuição uniforme (\mathcal{U}) que irá promover a variação. Observe que β será alterado em torno de um valor central β_0 , onde α será um parâmetro bem próximo de 0. O que se busca com estas duas modificações é permitir que o algoritmo seja mais efetivo no processo de convergência sem desprezar a exigência de diversidade, que certamente contribui para um espalhamento regular das soluções ao longo da fronteira *Pareto*.

4 Experimentos e Resultados

4.1 Configuração experimental

Neste experimento, uma área plana de $60m \times 60m$ foi considerada, onde os sensores precisam ser posicionados para fins de monitoramento. Como discutido anteriormente, a área é dividida em pequenos quadrados, em que o centro de cada quadrado representa um ponto de demanda que precisa ser monitorado. Aqui, a área dos quadrados foi definida como tendo $12m \times 12m$ cada, gerando 144 pontos de demanda. O *sink* é posicionado na coordenada central da área ($x = 30, y = 30$). O raio de sensoriamento é o mesmo para todos os sensores ($\tau_s = 15m$). A indicação se dois sensores podem se comunicar é estocasticamente calculada considerando a TRP descrita na Eq. (1). Desta forma, aspectos não controláveis, como interferências e colisões, são incluídas no modelo que descreve a qualidade do *link*. Por fim, a Tabela 1 sumariza os parâmetros empregados. Considerando o cenário com 08, 10, 12 e 14 sensores, foram realizadas 10 execuções de cada algoritmo para fornecer intervalos com nível de confiança de 95%.

Tabela 1: Parâmetros utilizados nos algoritmos.

Parâmetros	Valores	Notas
Parâmetros Gerais		
I	200	Número de Iterações
s	500	Tamanho da população
CR	0.9	Taxa de recombinação
β	0.2	Fator de escala do vetor-diferença
DEMO_{best}		
λ	0.5	Fator de escala do vetor de base
β_0	0.1	Valor central para variação do fator de escala
α	0.099	Intervalo de variação de β partindo de β_0 para + ou para -

4.2 Métricas de Desempenho

Neste trabalho deseja-se, além de obter uma representação adequada da fronteira *Pareto*, comparar o desempenho entre os algoritmos. Para tanto, duas métricas de qualidade são utilizadas. Para medir convergência, a métrica de cobertura entre fronteiras (*C-metric*) [5] compara diretamente dois conjuntos de soluções não dominadas, como descrito pela equação abaixo:

$$C(A, B) = \frac{|\{ b \in B; \exists a \in A : a \succeq b \}|}{|B|}, \quad (13)$$

Em um contexto de maximização, $C(A, B) = 1$ significa que todos os vetores de decisão em B são *Pareto*-dominados pelos vetores de decisão em A , enquanto $C(A, B) = 0$ significa que nenhum dos pontos em B é dominado por algum ponto em A . Cabe destacar que, ambas as operações, $C(A, B)$ e $C(B, A)$, precisam ser realizadas, uma vez que $C(A, B)$ não é necessariamente igual a $1 - C(B, A)$ [5].

Outra medida bastante empregada é um indicador que calcula o hipervolume de uma região multidimensional formada pela imagem do conjunto de soluções A e um ponto de referência [5], que neste trabalho será o vetor $[1,1]$. Para cada solução $i \in A$, constitui-se um hipercubo v_i em relação ao ponto de referência definido. A união de todos os hipercubos encontrados é o resultado da Eq. (14).

$$HV(A) = \bigcup_{i \in A} v_i \quad (14)$$

Quanto menor for este hipervolume, melhor o conjunto de soluções, considerando tanto convergência quanto diversidade (espalhamento).

4.3 Avaliação de Desempenho

A Tabela 2a mostra a comparação da métrica de cobertura (*C-metric*), enquanto a Tabela 2b demonstra a comparação do indicador de hipervolume considerando os dois algoritmos aplicados. Observe que ambas as métricas e a fronteira *Pareto*

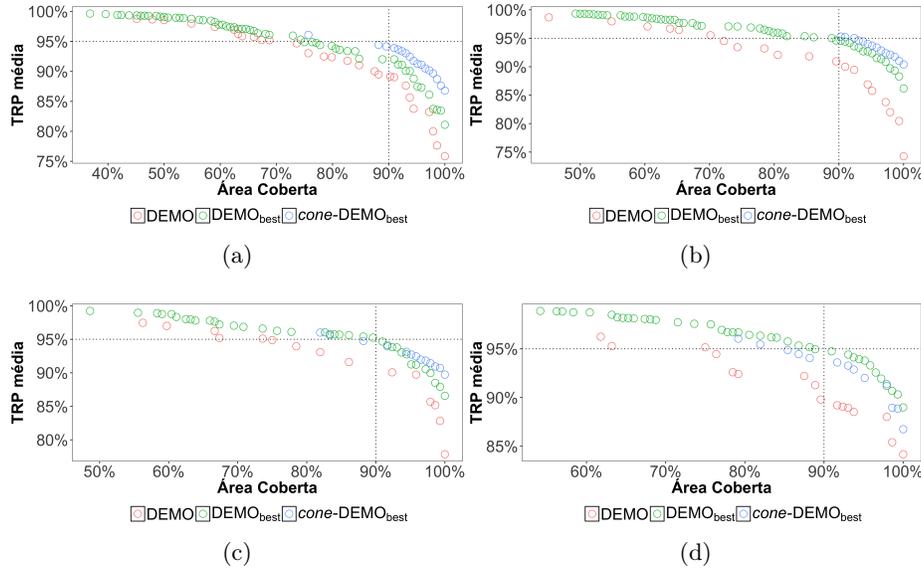


Fig. 1: Fronteira *Pareto* aproximada para (a) 08, (b) 10, (c) 12 e (d) 14 nós.

estimada em uma das execuções (Figura 1) atestam que o algoritmo $DEMO_{best}$ supera o $DEMO$ clássico em todos os casos. Estes resultados demonstram que as estratégias aplicadas no $DEMO_{best}$, que visam aprimorar o processo de convergência e a preservação de diversidade, são muito promissoras para o problema em questão.

Considerando a métrica de cobertura (*C-metric*), as representações das fronteiras obtidas pelo $DEMO_{best}$ cobrem completamente aquelas obtidas pelo algoritmo $DEMO$ clássico, ou seja, todos os pontos alcançados pelo $DEMO_{best}$ *Pareto*-dominam os pontos atingidos pelo $DEMO$. O indicador de hipervolume é capaz de medir tanto convergência quanto espalhamento. Novamente, o algoritmo $DEMO_{best}$ supera o $DEMO$ clássico e com intervalos de confiança que não se sobrepõem.

4.4 Refinando a busca

Através da fronteira *Pareto* estimada é possível ver o *trade-off* associado ao problema. Observe na Figura 1 que, para obter taxas médias de recepção de pacotes superiores a 95%, as perdas da área de cobertura são mais expressivas. Neste sentido, torna-se pertinente refinar a busca por soluções de *trade-off* que garantam no mínimo 90% de área coberta. Como alternativa para aperfeiçoar a otimização, aqui é proposto utilizar o conceito de *cone*-dominância apresentado anteriormente, a fim de forçar uma busca direcionada para a região de interesse.

Observando os *trade-offs*, deseja-se eliminar soluções que ofereçam poucos ganhos de TRP às custas de muitas perdas de área coberta. Portanto, por meio

Tabela 2: Métricas de cobertura e hipervolume.

(a) Média da métrica de cobertura: $DEMO_{best}$ (A) e $DEMO$ (B).

Nº de nós	C(A,B)	C(B,A)
08	0.997	0.002
10	1	0
12	0.992	0.003
14	0.992	0.004

(b) Indicador de hipervolume para $DEMO_{best}$ e $DEMO$.

Nº de nós	$DEMO_{best}$				$DEMO$			
	min.	média	máx.	IC	min.	média	máx.	IC
08	0.027	0.030	0.032	0.029 ↔ 0.031	0.044	0.049	0.0512	0.047 ↔ 0.050
10	0.019	0.025	0.029	0.024 ↔ 0.027	0.042	0.045	0.0484	0.044 ↔ 0.046
12	0.022	0.026	0.020	0.024 ↔ 0.027	0.046	0.049	0.0534	0.047 ↔ 0.051
14	0.023	0.027	0.032	0.026 ↔ 0.029	0.050	0.056	0.0652	0.054 ↔ 0.059

de um ajuste, relaxando o cone somente em relação ao objetivo f_1 (i.e., média de recepção de pacotes), o tamanho da região dominada aumenta, o que permite que as soluções evoluam para a faixa mais conveniente da fronteira. Para tanto, com base em diversas execuções e observações empíricas, o vetor que define o cone foi configurado com os valores $\theta = [0.13, 0]$. A definição destes valores não é uma tarefa trivial, uma vez que é necessário ter uma visão clara do formato da fronteira, que geralmente varia de acordo com o problema [2].

A Figura 1 também apresenta as soluções alcançadas por esta proposta em comparação com os algoritmos que utilizam *Pareto*-dominância. Note que os pontos gerados, além de apresentarem uma convergência mais atrativa, foram direcionados à região da fronteira que oferece um *trade-off* mais adequado, o que pode, de certa forma, colaborar para uma tomada de decisão mais assertiva.

4.5 Suporte à tomada de decisão

A partir das soluções obtidas pelo algoritmo $coneDEMO_{best}$ pode ser necessário aplicar alguma política que auxilia na tomada de decisão. Uma alternativa interessante é utilizar a Programação de Compromisso. Dessa forma, uma solução prática final foi escolhida a partir de uma referência considerada ideal [5]. Seja a formulação $PC(r, \mathbf{w})$ a seguir

$$\min_{\mathbf{x}} \left[\sum_{i=1}^{n_f} w_i |f_i(\mathbf{x}) - f_i^*|^r \right]^{1/r} \quad (15)$$

s.a. $\mathbf{x} \in S$,

Geralmente, adota-se $r = 2$, resultando assim no cálculo da distância Euclidiana em relação ao valor de referência de cada $f_i(\mathbf{x})$. O vetor de pesos \mathbf{w} é composto

por valores não negativos atribuídos a cada função objetivo $f_i(\mathbf{x})$ e representa as preferências do decisor. Em nossa abordagem, os pesos são iguais para os dois objetivos ($\mathbf{w} = [0.5, 0.5]$) e a referência utilizada foi o ponto $\mathbf{f}^* = [0.95, 1]$. O que se deseja é escolher uma solução que garanta valores próximos de 95% de taxa de entrega de pacotes e 100% de área coberta.

As soluções selecionadas por meio desta abordagem são destacadas na Figura 2, onde o nó central em azul representa o nó *sink*, enquanto os demais são os nós sensores. Considerando a ordem $\mathbf{f} = [TRP, AreaCoberta]$, as figuras representam as seguintes soluções: 08 sensores: $\mathbf{f} \simeq [92\%, 96\%]$, 10 sensores: $\mathbf{f} \simeq [92\%, 97\%]$, 12 sensores: $\mathbf{f} \simeq [92\%, 97\%]$ e 14 sensores: $\mathbf{f} \simeq [94\%, 99\%]$. Observe que, com 10 sensores, é possível obter uma solução de *layout* tão boa quanto no cenário com 12 sensores, enquanto que, com 14 sensores, os valores dos objetivos chegam ainda mais próximos do ponto de referência [95%, 100%].

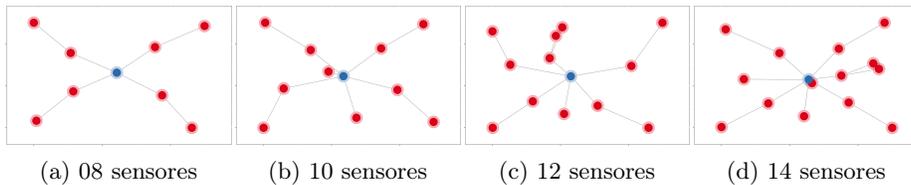


Fig. 2: Soluções obtidas pela programação de compromisso.

5 Conclusão

Este trabalho apresentou uma modelagem matemática multiobjetivo para lidar com o problema de *layout* em uma rede de sensores. O modelo contempla a otimização de dois objetivos conflitantes, a saber, maximização de área de sensoriamente e maximização da confiabilidade de entrega de pacotes. Além da concepção do modelo, um algoritmo de Evolução Diferencial Multiobjetivo foi proposto para resolver instâncias do problema, considerando redes com 08, 10, 12 e 14 sensores. Por meio da estratégia de resolução implementada, obteve-se boa convergência e diversidade nas soluções. Desta forma, foi possível ter uma nítida percepção do compromisso entre os dois objetivos.

As estratégias apresentadas foram suficientes para representar bem o problema e para fornecer boas soluções práticas. Naturalmente, este problema pode ser estendido para lidar com novos objetivos, como minimizar o atraso de transmissão, maximizar o tempo de vida da rede e customizar a qualidade de serviço para cada categoria de tráfego. Problemas combinatórios podem também ser investigados a fim de melhorar a eficiência da rede, como, por exemplo, definir *clusters* que possam explorar de forma mais inteligente os recursos dos nós.

6 Agradecimentos

O presente trabalho foi realizado com o apoio financeiro da CAPES - Brasil.

Referências

1. Baccour, N., Koubaa, A., Jamâa, M.B., Do Rosario, D., Youssef, H., Alves, M., Becker, L.B.: Radiale: A framework for designing and assessing link quality estimators in wireless sensor networks. *Ad Hoc Networks* 9(7), 1165–1185 (2011)
2. Batista, L.S., Campelo, F., Guimarães, F.G., Ramírez, J.A.: A comparison of dominance criteria in many-objective optimization problems. In: *Evolutionary Computation (CEC), 2011 IEEE Congress on*. pp. 2359–2366. IEEE (2011)
3. Bottero, M., Dalla Chiara, B., Deflorio, F.P.: Wireless sensor networks for traffic monitoring in a logistic centre. *Transportation Research Part C: Emerging Technologies* 26, 99–124 (2013)
4. Chaudhry, S.B., Hung, V.C., Guha, R.K., Stanley, K.O.: Pareto-based evolutionary computational approach for wireless sensor placement. *Engineering Applications of Artificial Intelligence* 24(3), 409–425 (2011)
5. Collette, Y., Siarry, P.: *Multiobjective optimization: principles and case studies*. Springer Science & Business Media (2013)
6. Deb, K., Pratap, A., Agarwal, S., Meyarivan, T.: A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE transactions on evolutionary computation* 6(2), 182–197 (2002)
7. Derr, K., Manic, M.: Wireless sensor networks: Node localization for various industry problems. *IEEE Transactions on Industrial Informatics* 11(3), 752–762 (2015)
8. Dijkstra, E.W.: A note on two problems in connexion with graphs. *Numerische mathematik* 1(1), 269–271 (1959)
9. Goulart, F., Campelo, F.: Preference-guided evolutionary algorithms for many-objective optimization. *Information Sciences* 329, 236–255 (2016)
10. Guimarães, F.G.: Evolução diferencial. <http://hdl.handle.net/10316.2/5655> pp. 141–161 (2012)
11. Iqbal, M., Naeem, M., Anpalagan, A., Ahmed, A., Azam, M.: Wireless sensor network optimization: multi-objective paradigm. *Sensors* 15(7), 17572–17620 (2015)
12. Jalsan, K.E., Soman, R.N., Flouri, K., Kyriakides, M.A., Feltrin, G., Onoufriou, T.: Layout optimization of wireless sensor networks for structural health monitoring. *Smart Structures and Systems* 14(1), 39–54 (2014)
13. Jourdan, D.B., de Weck, O.L.: Layout optimization for a wireless sensor network using a multi-objective genetic algorithm. In: *Vehicular technology conference*. vol. 5, pp. 2466–2470. IEEE (2004)
14. Pradhan, P.M., Panda, G.: Connectivity constrained wireless sensor deployment using multiobjective evolutionary algorithms and fuzzy decision making. *Ad Hoc Networks* 10(6), 1134–1145 (2012)
15. Robič, T., Filipič, B.: Differential evolution for multiobjective optimization. In: *Evolutionary multi-criterion optimization*. pp. 520–533. Springer (2005)
16. Sengupta, S., Das, S., Nasir, M., Panigrahi, B.K.: Multi-objective node deployment in WSNs: In search of an optimal trade-off among coverage, lifetime, energy consumption, and connectivity. *Engineering Applications of Artificial Intelligence* 26(1), 405–416 (2013)
17. Yoon, Y., Kim, Y.H.: An efficient genetic algorithm for maximum coverage deployment in wireless sensor networks. *IEEE Transactions on Cybernetics* 43(5), 1473–1483 (2013)
18. Zhao, Z., Rosário, D., Braun, T., Cerqueira, E.: Context-aware opportunistic routing in mobile ad-hoc networks incorporating node mobility. In: *IEEE Wireless Communications and Networking Conference (WCNC)*. pp. 2138–2143. IEEE (2014)