

Otimização do Posicionamento de Power Beacons em Sistemas WET baseada em GA

João Roberto Teixeira dos Santos, Elaine Cristina de Cássia Silva e Victoria Dala Pegorara Souto

Resumo— A otimização do posicionamento dos *Power Beacons* (PB) desempenha um papel fundamental na quantidade de energia coletada pelos dispositivos de Internet das Coisas (IoT, do inglês *Internet of Things*) em sistemas de transferência de energia sem fio (WET, do inglês *Wireless Energy Transfer*). Portanto, neste artigo, é proposta uma nova solução baseada em Algoritmos Genéticos (GA, do inglês *Genetic Algorithm*) para maximizar a energia total coletada pelos dispositivos IoT através da otimização da posição de múltiplos PBs considerando apenas o conhecimento estatístico do estado do canal (SCSI, do inglês, *Statistical Channel State Information*) nos PBs. Os resultados obtidos demonstram que mesmo considerando apenas o conhecimento do SCSI no PB, a solução proposta obtém um aumento superior a 95% na energia total coletada pelos dispositivos IoT. Além disso, verificou-se que a solução proposta atinge um desempenho próximo ao caso com conhecimento perfeito do CSI (PCSI, do inglês *Perfect CSI*) no PB.

Palavras-Chave— Algoritmos Genéticos, WET, Beamforming.

Abstract— Optimizing the positioning of *Power Beacons* (PB) plays a fundamental role in the amount of energy harvested by Internet of Things (IoT) devices in wireless energy transfer (WET) systems. Therefore, in this work, a novel solution based on Genetic Algorithms (GA) is proposed to maximize the total energy harvested by the IoT devices by optimizing the position of multiple PBs considering only the statistical channel state (SCSI) knowledge at the PBs. The results obtained demonstrate that even considering only SCSI knowledge at the PB, the proposed solution achieves an increase of more than 95% in the total energy harvested by IoT devices. Furthermore, it was verified that the proposed solution achieves a performance close to the case with perfect knowledge of the CSI (PCSI, *Perfect CSI*) at the PB.

Keywords— Genetic Algorithm, WET, Beamforming.

I. INTRODUÇÃO

No cenário atual das comunicações sem fio, o uso massivo de dispositivos de Internet das Coisas (IoT, do inglês *Internet of Things*) conectados à Internet está se tornando cada vez mais difundido. No entanto, esses dispositivos demandam uma quantidade significativa de energia para operar de forma eficiente em suas diversas aplicações. Diante dessa demanda crescente, a busca por soluções eficazes para transmitir sinais de forma confiável em uma variedade de ambientes torna-se indispensável [1]. Portanto, o desenvolvimento de sistemas sustentáveis e eficientes para a transmissão de energia torna-se de suma relevância para o avanço contínuo das futuras gerações de sistemas de comunicações sem fio e Redes IoT.

Soluções que não dependam de baterias e que se sejam economicamente viáveis têm sido cada vez mais utilizadas

em aplicações IoT. Um exemplo notável é a Transferência de Energia Sem Fio (WET, do inglês *Wireless Energy Transfer*), a qual utiliza-se de ondas de radiofrequência (RF, do inglês *Radio Frequency*) para transmitir energia sem fio, reduzindo a utilização de baterias e a manutenção de dispositivos IoT em locais remotos ou de difícil acesso [2]. No entanto, sistemas WET apresentam baixo alcance, o que limita a sua aplicabilidade em sistemas práticos [1]. Para solucionar este problema, tecnologias como o *energy beamforming* têm sido desenvolvidas para aumentar a área de cobertura de sistemas WET [3], [4], [1].

Visto que o *Power Beacon* (PB) pode ser equipado com múltiplas antenas, a técnica de *Energy Beamforming* torna-se essencial em sistemas WET, permitindo a maximização da energia transmitida em direções específicas e, consequentemente, o aumento da energia coletada pelos dispositivos de IoT [5]. Portanto, o projeto eficiente do *beamforming* no PB pode melhorar consideravelmente a energia coletada por dispositivos IoT. Entretanto, um obstáculo é a obtenção do conhecimento do estado do canal (CSI, do inglês *Channel State Information*) no PB, dado o alto custo de energia nos dispositivos IoT para a aquisição do CSI, o que pode resultar em uma perda significativa nos ganhos proporcionados pelo *beamforming* [6]. Para superar essas limitações, a utilização do conhecimento estatístico do canal (S-CSI, do inglês *Statistical Channel State Information*) torna-se uma solução viável [1].

Ademais, além do projeto do *beamforming* no PB, outro desafio crítico em sistemas WET é a definição do posicionamento dos PBs, uma vez que este influencia diretamente na quantidade de energia coletada nos dispositivos IoT e no tempo total de carregamento do sistema [4]. Assim, torna-se necessário otimizar o posicionamento adequado dos PBs. Visando solucionar este desafio, recentemente, algumas soluções foram propostas [7], [8], [9], [10], [4]. Mais especificamente, em [7] foi proposto um esquema de implantação não uniforme para PBs em sistemas WET, onde uma célula é dividida em áreas internas e externas, de modo que uma estação base (BS, do inglês *Base Station*) e múltiplos PBs colaboram para alimentar os usuários. Este artigo tem como objetivo minimizar o consumo médio total de energia e, ao mesmo tempo, satisfazer a restrição de potência média de transmissão da BS e o limite de probabilidade de cobertura do sistema. Ademais, em [8] os autores investigam analiticamente a influência de diferentes estratégias de implantação de PBs no desempenho de um sistema WET. Em [9], os autores consideram padrões de antenas direcionais visando maximizar uma função de utilidade de carga para todos os dispositivos IoT implantados através da otimização do posicionamento

dos PBs. Neste trabalho, são evidenciados os benefícios da diretividade sobre a radiação omnidirecional e um novo algoritmo é proposto visando posicionar dinamicamente os PBs à medida que a topologia da rede muda. Ademais, em [10] os autores propõem uma nova solução para otimizar as posições dos PBs considerando a presença de obstáculos. Mais especificamente, a energia coletada em toda a rede é maximizada. Por fim, em [4] uma estratégia de implantação ideal de PBs foi proposta. As posições ótimas para os PBs são determinadas maximizando a potência incidente média para a pior localização na área de serviço, uma vez que nenhuma informação sobre a implantação dos dispositivos de IoT é fornecida.

Como pode-se verificar o posicionamento adequado dos PBs é um problema complexo devido a diversos fatores como, a topologia do ambiente, características específicas dos dispositivos IoT e exigências de cobertura de sistemas WET [7], [8], [9], [10], [4]. Portanto, o uso de técnicas de Inteligência Artificial (IA) capazes de resolver problemas de otimização complexos torna-se essencial. Nesse contexto, Algoritmos Genéticos (GA, do inglês *Genetic Algorithms*) têm demonstrado um excelente desempenho na resolução de problemas emergentes em diferentes áreas como, engenharia, telecomunicações e eletromagnetismo [11], [4].

Portanto, motivados pelas vantagens dos sistemas WET para as futuras Redes IoT e dadas as vantagens dos GAs, este trabalho propõe uma nova solução baseada em GA para maximizar a energia total coletada pelos dispositivos de IoT através da otimização conjunta do posicionamento de múltiplos PBs e do projeto do vetor de *beamforming* no PB considerando apenas o conhecimento do S-CSI. Diferente de [7], [8], [9], [10], neste artigo não consideramos a estimativa explícita do CSI. Ademais, diferentemente de [4], neste trabalho, considera-se o conhecimento do SCSi no PB. Portanto, as principais contribuições deste trabalho são: (i) Propomos uma nova abordagem baseada em GA para maximizar a energia total coletada pelos dispositivos IoT a partir da otimização do posicionamento dos PBs sem considerar o conhecimento perfeito do CSI (PCSI, do inglês *Perfect CSI*) no PBs; (ii) Demonstramos que o posicionamento dos PBs em sistemas WET influencia consideravelmente na energia total coletada pelos dispositivos IoT, ou seja, foi verificado um aumento superior a 95% na energia total coletada pelos dispositivos IoT quando comparado ao posicionamento aleatórios dos PBs; e (iii) Demonstramos que a solução proposta atinge uma solução próxima ao desempenho do PCSI considerando apenas SCSi;

II. MODELO DO SISTEMA

Neste trabalho foi considerado o cenário ilustrado na Figura 1, onde têm-se L PBs equipados com um arranjo uniforme linear (ULA, do inglês *Uniform Linear Array*) cada um com N antenas o qual alimenta K dispositivos IoT equipados com uma antena. Cada PB está posicionado na posição (x_{PB_l}, y_{PB_l}) em que $l = 1, \dots, L$. Portanto, a potência de RF coletada no k -ésimo dispositivo é dada por [12]

$$P_k^{\text{rx}} = \sum_{l=1}^L g_{k,l} \left| \mathbf{w}_{k,l} \mathbf{h}_{k,l}^H \right|^2. \quad (1)$$

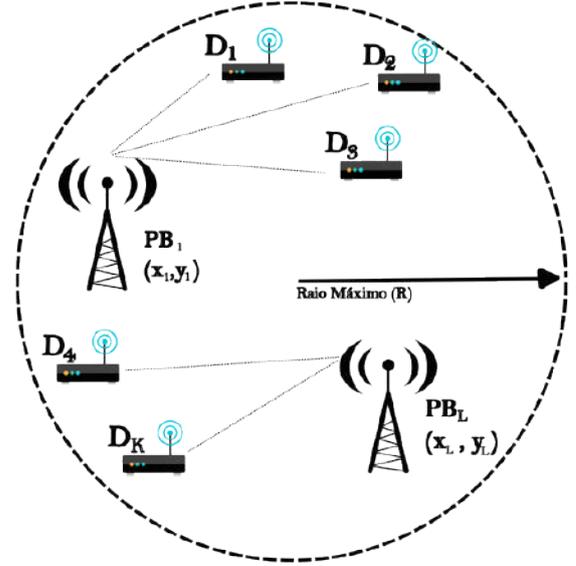


Fig. 1: Modelo do sistema, para K dispositivos e L PBs.

em que $\mathbf{w}_{k,l} \in \mathbb{C}^{1 \times N}$ é o vetor *beamforming* entre o l -ésimo PB e o k -ésimo dispositivo IoT para $k \in [1, \dots, K]$ e $l \in [1, \dots, L]$, $\|\mathbf{w}_{k,l}\|^2 = P_l^{\text{tx}}$ é a potência de transmissão do l -ésimo PB e $g_{k,l}$ é o ganho médio de potência do canal entre o l -ésimo PB e o k -ésimo dispositivo IoT dado por

$$g_{k,l} = d_{k,l}^{-\alpha} \left(\frac{c}{4\pi f_c} \right)^2, \quad (2)$$

em que f_c é frequência da portadora, $d_{k,l}$ é a distância entre o l -ésimo PB e o k -ésimo dispositivo IoT, α é expoente de perda de percurso dos links entre o PB e os dispositivos IoT¹ e, por fim, c denota a velocidade da luz. Ademais, $\mathbf{h}_{k,l} \in \mathbb{C}^{1 \times N}$ indica o vetor de canal entre o l -ésimo PB e o k -ésimo dispositivo IoT o qual é modelado pelo desvanecimento Rice e é definido como

$$\mathbf{h}_{k,l} = \sqrt{\frac{\kappa_{k,l}}{1 + \kappa_{k,l}}} \bar{\mathbf{h}}_{k,l} + \sqrt{\frac{1}{1 + \kappa_{k,l}}} \tilde{\mathbf{h}}_{k,l}, \quad (3)$$

em que $\tilde{\mathbf{h}}_{k,l} \in \mathbb{C}^{1 \times N}$ representa os componentes NLoS (do inglês, *Non Line of Sight*) do vetor de canal os quais são modeladas considerando distribuição Rayleigh. Além disso, $\bar{\mathbf{h}}_{k,l} \in \mathbb{C}^{1 \times N}$ denota as componentes LoS (do inglês, *Line of Sight*) do vetor de canal modeladas por uma variável aleatória complexa Gaussiana. Por fim, $\kappa_{k,l}$ representa o fator Rice do link entre o l -ésimo PB e o k -ésimo dispositivo IoT. Vale ressaltar que, neste trabalho, considera-se o mesmo fator Rice para todos os links, portanto, o índice k,l será omitido no restante do trabalho.

Para finalizar, a energia coletada pelo k -ésimo dispositivo de IoT é dada por [13]

$$E_k = \frac{\mu - \mu\Omega [1 + e^{-a(P_k^{\text{rx}} - b)}]}{1 - \Omega}, \quad (4)$$

¹Neste trabalho considera-se o mesmo expoente de perda de percurso para todos os canais.

em que $\Omega = \frac{1}{1+e^{ab}}$ é uma constante que garante uma resposta de entrada/saída zero para o circuito, a e b são constantes relacionadas às especificações do circuito [13], e μ é a potência máxima coletada pelo dispositivo quando o circuito do dispositivo está saturado. Vale ressaltar que, nesse trabalho, consideramos a energia coletada em um tempo de coerência $T_c = 1$ s, no qual o canal pode ser considerado estático.

A. Problema de Otimização

O principal objetivo deste trabalho é maximizar a energia total coletada pelos dispositivos IoT $[E_T = \sum_{k=1}^K E_k]$ enquanto atende as restrições de posicionamento dos PBs e de energia mínima coletada por cada dispositivo IoT. Para maximizar E_T considera-se a otimização conjunta do vetor de *beamforming* em cada PB e o vetor de posição de cada PB definidos, respectivamente, por

$$\mathbf{W} = \begin{bmatrix} \mathbf{w}_{1,1} & \mathbf{w}_{1,2} & \cdots & \mathbf{w}_{1,K} \\ \vdots & \dots & \dots & \vdots \\ \mathbf{w}_{L,1} & \mathbf{w}_{L,2} & \cdots & \mathbf{w}_{L,K} \end{bmatrix}.$$

e

$$\mathbf{P} = \begin{bmatrix} x_{PB_1} & x_{PB_2} & \cdots & x_{PB_L} \\ y_{PB_1} & y_{PB_2} & \cdots & y_{PB_L} \end{bmatrix}.$$

Portanto o problema de otimização proposto é dado por

$$\begin{aligned} & \underset{\{\mathbf{W}\}, \{\mathbf{P}\}}{\text{Maximize}} && E_T \\ & \text{Subject to} && E_k \geq E_{\min}, \\ & && 0 \leq x_{PB_l} \leq x_{\max}, \\ & && 0 \leq y_{PB_l} \leq y_{\max}, \\ & && |\mathbf{w}_{k,l,n}|^2 = \frac{P_l^{\text{tx}}}{N}, \\ & && k \in \{1, \dots, K\} \text{ e } n \in \{1, \dots, N\}, \\ & && l \in \{1, \dots, L\}. \end{aligned} \quad (5)$$

em que x_{\max} e y_{\max} representam a restrição de posicionamento dos PBs no eixo x e y , respectivamente, E_{\min} é a restrição de energia mínima coletada por cada dispositivo de IoT a qual é considerada a mesma para todos os dispositivos IoT e $|\mathbf{w}_{k,l,n}|^2 = \frac{P_l^{\text{tx}}}{N}$ denota a restrição de ganho constante no l -ésimo PB. Neste trabalho consideramos a mesma potência de transmissão para todos os PBs, portanto, o índice l será omitido para simplificar a representação do sistema.

Para encontrar a solução ótima de (5) é necessário o conhecimento perfeito do CSI no PB, o que torna-se um desafios para sistemas WET. Portanto, neste trabalho, considera-se o projeto do *beamforming* analógico no PB baseado apenas no conhecimento do S-CSI, ou seja, \mathbf{h}_k é conhecido no PB. Logo, considerando o método EGT (do inglês, *Equal Gain Transmitter*), $\bar{\mathbf{w}}_{k,l}$ é dado por

$$\bar{\mathbf{w}}_{k,l} = \sqrt{\frac{P_l^{\text{tx}}}{N}} \begin{bmatrix} \bar{h}_{k,l,1} & \bar{h}_{k,l,2} & \cdots & \bar{h}_{k,l,N} \\ |\bar{h}_{k,l,1}| & |\bar{h}_{k,l,2}| & \cdots & |\bar{h}_{k,l,N}| \end{bmatrix}^T \quad (6)$$

Por fim, substituindo (6) em (5), o problema de otimização proposto pode ser reescrito como

$$\begin{aligned} & \underset{\{\mathbf{P}\}}{\text{Maximize}} && E_T \\ & \text{Subject to} && E_k \geq E_{\min}, \\ & && 0 \leq x_{PB_l} \leq x_{\max}, \\ & && 0 \leq y_{PB_l} \leq y_{\max}, \\ & && k \in \{1, \dots, K\}. \end{aligned} \quad (7)$$

A partir da análise das restrições do problema proposto, verifica-se que este problema de otimização é não convexo, logo, não existe um método padrão para resolvê-lo. Portanto, neste artigo, propomos uma nova solução baseada em GA para obter um solução sub-ótima para o problema proposto.

III. ALGORITIMOS GENÉTICOS

Os GAs são baseados na teoria da Seleção Natural de Charles Darwin [11], a qual afirma que indivíduos mais aptos tem maior probabilidade de se reproduzir, gerando assim mais descendentes nas próximas gerações [11]. Os GAs têm sido amplamente aplicados nos mais diversos problemas de otimização, devido à sua simplicidade de implementação, baixos custos operacionais e fácil paralelização [14]. Para compreender o funcionamento de um GA, torna-se necessário definir o significado de alguns conceitos e terminologias da Biologia. Os principais termos utilizados são: Gene, cromossomo, indivíduo, pais, filhos e função de aptidão. Um “gene” é definido como uma variável de otimização. Um “cromossomo” representa um número finito de genes que caracterizam um indivíduo, o qual representa uma possível solução para o problema de otimização. Os “pais” são os indivíduos selecionados pelo processo de seleção natural para participar do processo de reprodução. Os “filhos” são os indivíduos resultantes do processo de reprodução, e o valor da função de aptidão representa o grau de adequação de cada indivíduo ao ambiente, ou seja, define a qualidade de uma solução para o problema de otimização considerado [11], [14].

Resumidamente, na primeira primeira geração os indivíduos da primeira população são gerados aleatoriamente. Cada indivíduo é avaliado com base em uma função aptidão e, com base em sua aptidão, são selecionados (“pais”) ou não para participarem do processo de reprodução. A etapa de reprodução dos GAs é composta por dois operadores: Cruzamento e Mutação. Mais especificamente, os indivíduos selecionados (“pais”) são submetidos ao operador de cruzamento e novos indivíduos (“filhos”) são gerados a partir da permutação dos genes desses indivíduos. Os “filhos” gerados são submetidos ao operador de cruzamento com uma dada probabilidade de mutação p_{mut} . Finalmente, uma nova população é gerada e o processo continua até que o critério de parada seja satisfeito [11], [14].

IV. SOLUÇÃO PROPOSTA

Neste trabalho, é proposta uma nova abordagem baseada em GA para resolver de forma sub-ótima o problema de otimização dado por (7). Mais especificamente, os principais passos da solução proposta são descritos abaixo e sumarizados no Algoritmo 1.

- 1) Inicialize aleatoriamente a primeira população formada por N_{pop} indivíduos definidos como $[\mathbf{P}_1, \dots, \mathbf{P}_{N_{\text{pop}}}]$;
- 2) Determine a aptidão de cada indivíduo dada por E_T ;
- 3) Selecciona os N_{elite} indivíduos mais aptos através do processo de Elitismo;
- 4) Selecciona $N_{\text{pop}} - N_{\text{elite}}$ indivíduos através do Método do Torneio para participar do processo de reprodução.
- 5) Gere $N_{\text{filhos}} = N_{\text{pop}} - N_{\text{elite}}$ filhos através do operador de Cruzamento Uniforme com probabilidade p_c .
- 6) Os filhos gerados no passo anterior são submetidas ao operador de mutação real com probabilidade p_{mut} ;
- 7) Gera a nova População, a qual é formada pelos N_{filhos} indivíduos gerados pós mutação e os N_{elite} indivíduos selecionados pelo processo de Elitismo;
- 8) Verifica se o critério de parada (número de iterações N_{it}) foi satisfeito. Se satisfeito, retorna o melhor indivíduo encontrado, caso contrário, retorne ao Passo 2.

Algoritmo 1: Método de otimização proposto.

Entrada: Parâmetros do Sistema: N, K, R, L

 Parâmetros do GA: $N_{\text{pop}}, N_{\text{it}}, p_{\text{mut}}, p_c, N_{\text{elite}}$
Saída : \mathbf{X}_{best}

```

1 Inicialize a primeira população aleatoriamente  $\mathbf{X} = [\mathbf{P}_1, \dots, \mathbf{P}_{N_{\text{pop}}}]$ ;
2 for  $t = 1 : N_{\text{it}}$  do
3     Determine a aptidão de cada indivíduo de acordo com (7).
4     Determine os  $N_{\text{elite}}$  indivíduos mais aptos definidos como  $\mathbf{X}_{\text{elite}}$ .
5     Determine  $(N_{\text{pop}} - N_{\text{elite}})/2$  pais pelo Método de Torneio.
6     for  $pop = 1 : (N_{\text{pop}} - N_{\text{elite}})/2$  do
7         if  $p_c < \text{rand}()$  then
8             Gere dois novos filhos pelo Operador de Cruzamento
              Uniforme definidos como  $\mathbf{X}_{\text{filhos}}$ .
9         else
10            Os pais selecionados pelo Método Torneio são
              mantidos para a próxima geração e são definidos
              como  $\mathbf{X}_{\text{filhos}}$ .
11        end
12    end
13    for  $pop = 1 : (N_{\text{pop}} - N_{\text{elite}})/2$  do
14        if  $p_{\text{mut}} < \text{rand}()$  then
15            Os filhos são submetidos ao processo de mutação e
              são definidos como  $\mathbf{X}_{\text{Mut}}$ .
16        else
17            end
18        Atualiza a população:  $\mathbf{X} = [\mathbf{X}_{\text{elite}}, \mathbf{X}_{\text{Mut}}]$ 
19    end
20 return  $\mathbf{X}_{\text{best}}$ 
    
```

V. RESULTADOS E DISCUSSÕES

Nesta seção são apresentados os resultados obtidos considerando o cenário descrito na Figura 1. Adicionalmente, os resultados apresentados nesta seção consideram, caso não especificado, os seguintes parâmetros de simulação: $R = 20$ m, $N = 4$, $f = 915$ MHz, $\kappa = 1$, $\mu = 10,73$ mW, $a = 0.2308$, $b = 5,365$, $E_{\text{min}} = 1 \mu\text{J}$ e $\alpha = 2,7$, $P^{\text{tx}} = 2$ W. Todas as curvas representam a média de 10^3 realizações independentes de canal e 10^2 configurações para o posicionamento dos dispositivos de IoT. Além disso, nesta seção são apresentados resultados considerando as seguintes abordagens: (i) *PBs Aleatórios*, em que os PBs são posicionados de forma aleatória; (ii) *GA - PCSI*, em que o posicionamento dos PBs é otimizado

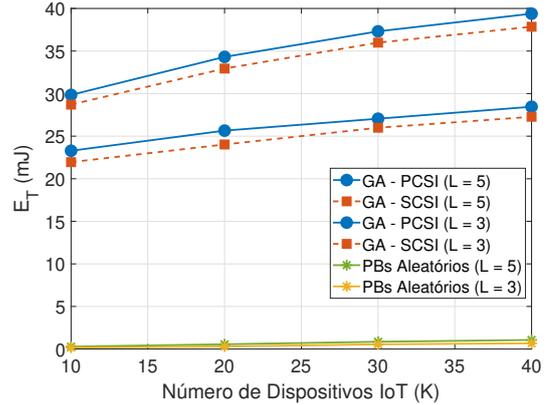


Fig. 2: Energia total coletada pelos dispositivos IoT (E_T) versus o número de dispositivos de IoT (K).

considerando a solução proposta descrita de Seção IV e o vetor de beamforming nos PBs é projetado considerando o conhecimento perfeito do CSI; e (iii) *GA - SCSi*, em que o posicionamento dos PBs é otimizado considerando a solução proposta descrita de Seção IV e o vetor de beamforming nos PBs é projetado considerando apenas o conhecimento do SCSi.

Inicialmente, foi avaliada a influência do número de dispositivos IoT (K) em E_T considerando $L \in \{3, 5\}$ (Figura 2). Através dos resultados obtidos pode-se verificar que a solução proposta mesmo considerando apenas o conhecimento do SCSi no PB (*GA - SCSi*) permite aumentar em mais de 95% a energia total coletada pelos dispositivos IoT quando compara ao *benchmark PBs - Aleatórios*. Isso demonstra a importância do posicionamento dos dispositivos em sistemas WET, o qual é constantemente negligenciado nos trabalhos presentes na literatura [15], [16]. Ademais, pode-se verificar que a solução proposta (*GA - SCSi*) atinge um desempenho próximo ao *benchmark* com PCSI, o que demonstra que é possível maximizar a energia total coletada nos dispositivos considerando apenas o SCSi, o qual é viável de ser obtido em cenários práticos [1].

Além disso, a Figura 3 apresenta uma análise da influência do número de PBs (L) na energia total coletada pelos dispositivos IoT (E_T). A partir dos resultados obtidos, pode-se concluir que, como esperado, aumentar o número de PBs resulta em um aumento em E_T . No entanto, esse ganho é reduzido quando os PBs são posicionados de forma aleatória (*PBs Aleatórios*), evidenciando, novamente, a importância de determinar um posicionamento adequado para os PBs. Ademais, a Figura 4 avalia a influência do número de antenas no PB (N) em E_T para $L \in \{3, 5\}$. A partir dos resultados pode-se verificar que, aumentar N não resulta em um aumento significativo em E_T , isto pode ser explicado pelo fato de que quando N aumenta, a diretividade do arranjo de antenas aumenta, ou seja, largura do feixe é reduzida e, conseqüentemente, torna-se desafiador realizar o posicionamento dos PBs de forma a garantir que todos os dispositivos IoT sejam atendidos devido a menor faixa de cobertura do feixe. Portanto, o número de antenas no PB deve ser definido de forma cuidadosa, visando aumentar o alcance do PB ao mesmo tempo que garante a restrição de energia mínima nos dispositivos IoT.

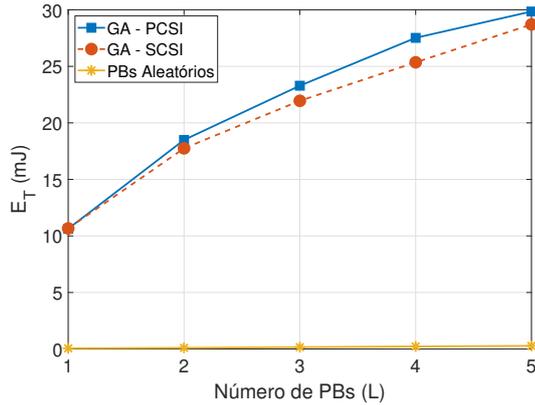


Fig. 3: Energia total coletada pelos dispositivos IoT (E_T) versus o número de PBs (L).

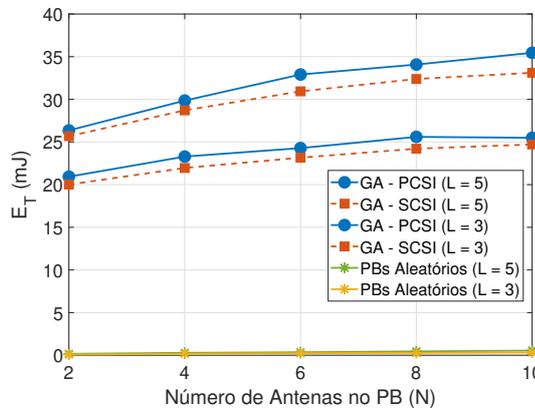


Fig. 4: Energia total coletada pelos dispositivos IoT (E_T) versus o número de antenas nos PBs (N).

Por fim, vale ressaltar que a solução proposta (GA - SCSi) atinge uma performance superior ao caso onde os PBs são dispostos de forma aleatório com $N_{it} \sim 200$ para $L \in \{3, 5\}$, $N = 4$ e $K = 10$.

VI. CONCLUSÕES

Neste trabalho, propomos uma nova abordagem para maximizar a energia total coletada pelos dispositivos de IoT baseada em GA, atendendo à restrição mínima de energia coletada em cada dispositivo IoT. Ademais, realizamos o projeto do *beamforming* no PB considerando apenas o conhecimento do SCSi. Por fim, os resultados numéricos demonstram que a solução proposta pode aumentar consideravelmente a energia total coletada pelos dispositivos de IoT evidenciando a importância do posicionamento dos PBs em sistemas WET. Ademais, a solução proposta atinge uma solução próxima a solução com PCSI para diferentes cenários, demonstrando a sua robustez. Para trabalhos futuros pretende-se desenvolver novas soluções para posicionamento dos PBs móveis baseadas em técnicas de Aprendizado de Máquina considerando a técnica de *beamsharing*.

AGRADECIMENTOS

Este trabalho foi parcialmente financiado pelo projeto XGM-AFCCT-2024-4-1-1, apoiado pelo

xGMobile-EMBRAPII-Inatel Centro de Competências em Redes 5G e 6G, com recursos do programa PPI IoT/Manufatura 4.0 do MCTI número 052/2023, assinado com a EMBRAPII. Ademais, foi parcialmente financiado pela RNP, com recursos do MCTIC, nº 01245.020548/2021-07, através do projeto Brasil 6G do Centro de Referência em Radiocomunicações do Inatel, e pela FAPEMIG no âmbito dos projetos nº APQ-05305-23, APQ-04523-23 e RED-00194-23

REFERÊNCIAS

- [1] O. L. A. López, H. Alves, R. D. Souza, S. Montejo-Sánchez, E. M. G. Fernández, and M. Latva-Aho, "Massive Wireless Energy Transfer: Enabling Sustainable IoT Toward 6G Era," *IEEE Internet of Things Journal*, vol. 8, no. 11, pp. 8816–8835, 2021.
- [2] S. Zhou, H. Dai, H. Sun, G. Tan, and B. Ye, "On the Deployment of Clustered Power Beacons in Random Wireless Powered Communication," *IEEE Transactions on Vehicular Technology*, vol. 72, no. 2, pp. 2424–2438, 2023.
- [3] Y. Alsaba, S. K. A. Rahim, and C. Y. Leow, "Beamforming in Wireless Energy Harvesting Communications Systems: A Survey," *IEEE Communications Surveys Tutorials*, vol. 20, no. 2, pp. 1329–1360, 2018.
- [4] O. M. Rosabal, O. L. A. López, H. Alves, S. Montejo-Sánchez, and M. Latva-Aho, "On the Optimal Deployment of Power Beacons for Massive Wireless Energy Transfer," *IEEE Internet of Things Journal*, vol. 8, no. 13, pp. 10531–10542, 2021.
- [5] J. Guo, X. Zhou, and S. Durrani, "Wireless Power Transfer via mmWave Power Beacons With Directional Beamforming," *IEEE Wireless Communications Letters*, vol. 8, no. 1, pp. 17–20, 2019.
- [6] V. D. P. Souto, O. M. Rosabal, S. Montejo-Sánchez, O. L. A. López, R. D. Souza, and H. Alves, "Otimização do Tempo de Recarga com Transmissão de Energia sem Fio Usando Beamforming Analógico Baseado nas Estatísticas do Canal," *XLI Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*, 2023.
- [7] K. Liang, L. Zhao, G. Zheng, and H.-H. Chen, "Non-Uniform Deployment of Power Beacons in Wireless Powered Communication Networks," *IEEE Transactions on Wireless Communications*, vol. 18, no. 3, pp. 1887–1899, 2019.
- [8] S. Zhou, H. Dai, H. Sun, G. Tan, and B. Ye, "On the Deployment of Clustered Power Beacons in Random Wireless Powered Communication," *IEEE Transactions on Vehicular Technology*, vol. 72, no. 2, pp. 2424–2438, 2023.
- [9] H. Dai, X. Wang, A. X. Liu, H. Ma, G. Chen, and W. Dou, "Wireless Charger Placement for Directional Charging," *IEEE/ACM Transactions on Networking*, vol. 26, no. 4, pp. 1865–1878, 2018.
- [10] X. Wang, H. Dai, W. Wang, J. Zheng, N. Yu, G. Chen, W. Dou, and X. Wu, "Practical Heterogeneous Wireless Charger Placement with Obstacles," *IEEE Transactions on Mobile Computing*, vol. 19, no. 8, pp. 1910–1927, 2020.
- [11] J. Chen and Z. Xiao, "Research on adaptive genetic algorithm based on multi-population elite selection strategy," in *2017 2nd IEEE International Conference on Computational Intelligence and Applications (ICCI)*, 2017, pp. 108–112.
- [12] O. L. A. López, F. A. Monteiro, H. Alves, R. Zhang, and M. Latva-Aho, "A Low-Complexity Beamforming Design for Multiuser Wireless Energy Transfer," *IEEE Wireless Communications Letters*, vol. 10, no. 1, pp. 58–62, 2021.
- [13] E. Boshkovska, D. W. K. Ng, N. Zlatanov, and R. Schober, "Practical Non-Linear Energy Harvesting Model and Resource Allocation for SWIPT Systems," *IEEE Communications Letters*, vol. 19, no. 12, pp. 2082–2085, 2015.
- [14] Y. Tominaga, Y. Okamoto, S. Wakao, and S. Sato, "Binary-Based Topology Optimization of Magnetostatic Shielding by a Hybrid Evolutionary Algorithm Combining Genetic Algorithm and Extended Compact Genetic Algorithm," *IEEE Transactions on Magnetics*, vol. 49, no. 5, pp. 2093–2096, 2013.
- [15] O. L. A. López, S. Montejo-Sánchez, R. D. Souza, C. B. Papadias, and H. Alves, "On CSI-Free Multiantenna Schemes for Massive RF Wireless Energy Transfer," *IEEE Internet of Things Journal*, vol. 8, no. 1, pp. 278–296, 2021.
- [16] K. Lin, O. L. A. López, H. Alves, and T. Hao, "On CSI-Free Multiantenna Schemes for Massive Wireless-Powered Underground Sensor Networks," *IEEE Internet of Things Journal*, vol. 10, no. 19, pp. 17557–17570, 2023.