

Otimização de Sistemas WET baseada na Clusterização de Dispositivos IoT

Marcelo V. S. de Oliveira¹Victoria D. P. Souto¹Samuel Montejo-Sánchez²Richard D. Souza³

Resumo—A tecnologia de Transferência de Energia Sem Fio (WET, do inglês *Wireless energy transfer*) é fundamental para as futuras redes sem fio, pois pode permitir a operação ininterrupta de dispositivos de Internet das Coisas. Portanto, neste trabalho, propusemos uma nova abordagem para minimizar o tempo total de carregamento de um sistema com vários dispositivos IoT, com base na técnica de aprendizado de máquina não supervisionado *K-means*. Além disso, como o conhecimento perfeito da informação do estado do canal (CSI, do inglês *Channel State Information*) é um desafio para sistemas WET e não estará disponível na maioria dos sistemas práticos, neste trabalho consideramos o projeto do *beamforming* no PB baseado apenas no CSI estatístico (SCSI, do inglês *Statistical CSI*). Por fim, verificamos que a clusterização pode reduzir o tempo total de recarga do sistema em até 75%. Além disso, demonstramos que a solução proposta atinge um desempenho próximo do ideal para diferentes cenários, demonstrando sua robustez.

Palavras-Chave—Transferência de Energia Sem Fio, *Beamforming*, Clusterização, Aprendizado de Máquina.

Abstract—Wireless energy transfer (WET) technology is fundamental to future wireless networks, as it can enable the uninterrupted operation of future Internet of Things (IoT) networks. Therefore, in this work, we proposed a novel approach to minimize the total recharge time based on the unsupervised machine learning technique *K-means*. Furthermore, since perfect knowledge of the channel state information (CSI) is a challenge for WET systems and is not available in most practical systems, in this work, we consider the design of the *beamforming* at the PB based only on the statistical CSI (SCSI) knowledge at the PB. Finally, we verified that the proposed approach based on a clustering strategy can reduce the total system recharge time by up to 75%. Furthermore, we demonstrate that the proposed solution achieves a close-to-optimal performance for different scenarios, demonstrating its robustness.

Keywords—Wireless Energy Transfer, *Beamforming*, Clustering, Machine Learning.

I. INTRODUÇÃO

As Redes de Internet das Coisas (IoT, do inglês *Internet of Things*) são compostas por um conjunto de dispositivos de baixo consumo de energia e custo, que operam de forma autônoma e interagem com o ambiente. Devido à sua popularidade, espera-se que a implementação das futuras Redes IoT sejam massivas, exigindo sistemas energeticamente eficientes para prolongar a vida útil dos dispositivos reduzindo, assim, a necessidade de troca de baterias [1]. Atualmente, a maioria

dos dispositivos IoT depende de cabos de energia ou de baterias para seu funcionamento, limitando a escalabilidade, sustentabilidade e mobilidade das Redes IoT. Ademais, o carregamento com fio e a substituição frequente de baterias torna-se impraticável para aplicações em locais de difícil acesso, eleva os custos de manutenção e representa um problema para o meio ambiente devido à necessidade de descarte de um grande número de baterias [1].

A tecnologia de Transferência de Energia Sem Fio (WET, do inglês *Wireless Energy Transfer*) surge como uma solução para superar os desafios previamente mencionados. Mais especificamente, WET é considerada uma tecnologia ambientalmente sustentável para alimentar dispositivos IoT com energia sem fio de forma contínua e estável [2]. Além disso, existem diversas técnicas de coleta de energia (EH, do inglês *Energy Harvesting*) para recarregar baterias de forma sem fio e evitar a sua substituição, dentre as quais podemos citar, técnicas de EH acústicas, solar, indutivas, capacitivas, magnéticas e por ondas de radiofrequência (RF) [3]. Dentre as fontes de EH, a WET baseada em RF apresenta características mais adequadas aos objetivos deste trabalho, tais como um menor fator de forma, hardware simplificado e facilidade de implementação para múltiplos usuários visto que o mesmo sinal de RF pode ser captado por diversos dispositivos. Portanto, o WET baseado em RF apresenta um maior potencial de escalabilidade e pode garantir a operação ininterrupta dos dispositivos de IoT, diferentemente das demais técnicas de EH que dependem de fatores ambientais (solar) ou que são limitadas em distância (indutivas, magnéticas e capacitivas) [3].

Apesar das vantagens da tecnologia WET seu maior desafio é o projeto do “*Energy Beamforming*” no *Power Beacon* (PB), que consiste em direcionar o feixe de energia de forma precisa para um direção desejada no espaço. Isso é alcançado ajustando a amplitude e a fase de cada elemento irradiante, de modo que os sinais se sobreponham na direção do receptor [3]. No entanto, o projeto do *Energy Beamforming* no PB depende do conhecimento preciso sobre o estado do canal (CSI, do inglês *Channel State Information*), o que é desafiador em cenários práticos devido ao consumo de energia necessário para estimar o canal e a limitação de recursos de hardware nos dispositivos IoT [2]–[4]. Assim, a aquisição precisa do CSI torna-se um desafio e pode ser inviável em muitos casos. Além disso, a estimação do CSI torna-se ainda mais desafiadora em cenários com um número massivo de dispositivos IoT [5].

Motivados pelos desafios previamente expostos, foram propostas novas soluções para projeto do *beamforming* no PB sem qualquer conhecimento do CSI ou baseadas apenas no conhecimento estatístico do canal (S-CSI, do inglês *Statistical*

¹ Instituto Nacional de Telecomunicações, Santa Rita do Sapucaí, MG, Brasil.

² Instituto Universitario de Investigación y Desarrollo Tecnológico, Universidad Tecnológica Metropolitana, Santiago, Chile.

³ Universidade Federal de Santa Catarina, Florianópolis, SC, Brasil. marcelosatyro@mtel.inatel.br, victoria.souto@inatel.br, smontejo@utem.cl, richard.demo@ufsc.br

CSI) [3], [4], [6]–[9]. Mais especificamente, em [4] é proposto um esquema de projeto de *beamforming* baseado em estatísticas de primeira ordem do canal visando maximizar a energia coletada nos dispositivos IoT. Em [6], os autores propõem uma nova solução na qual o PB é equipado com múltiplas antenas e o projeto do *beamforming* no PB é realizado com base nas estatísticas de primeira e segunda ordem dos componentes do canal Rician. Além disso, em [7], os autores investigam estratégias do uso de múltiplas antenas sem o conhecimento do CSI no PB. Em [3], os autores propõem a técnica de Sistema de Antenas Distribuídas utilizando o algoritmo *K-means* para otimizar a posição das antenas. Em [8], investiga-se como o desvanecimento beneficia a eficiência de conversão de energia de ondas de RF em sistemas WET que empregam EH não linear. Em [9], os autores propõem um projeto de *beamforming* simples, porém eficaz, para que um PB com múltiplas antenas alimente de forma equitativa um conjunto de dispositivos IoT, baseando-se apenas nas estatísticas de primeira ordem dos canais. Por fim, em [10] foi proposta uma abordagem de projeto de *beamforming* no PB baseado apenas no S-CSI, a qual considera que os dispositivos IoT podem coletar energia enquanto os demais dispositivos estão sendo carregados.

Portanto, neste trabalho é proposta uma nova abordagem para sistemas WET visando minimizar o tempo total de carregamento dos dispositivos IoT através da otimização do *beamforming* no PB considerando apenas o conhecimento do S-CSI. Em linha com [10], consideramos a possibilidade de carregamento simultâneo dos dispositivos (*beamsharing*), isto é, os dispositivos IoT podem coletar energia enquanto seus vizinhos estão sendo coletados. Apesar de [10] considerar *beamsharing* para reduzir o tempo de carregamento do sistema, os autores consideram que os dispositivos são selecionados de forma aleatória para serem carregados. Portanto, visando reduzir o tempo de recarga do sistema, diferentemente de [3], [4], [6]–[10], este trabalho propõe o uso do algoritmo de clusterização *K-means* [11] e analisa a influência da clusterização em sistemas WET. Esse método oferece uma maneira inteligente de determinar a ordem de carregamento dos dispositivos com base na proximidade entre eles, reduzindo o tempo total de carregamento do sistema. Por fim, foi considerado *beamforming* analógico no PB devido a sua baixa complexidade e menor consumo de energia em comparação ao digital [12]. Portanto, as principais contribuições deste trabalho podem ser sumarizadas como: (i) Propomos uma nova abordagem para minimizar o tempo de recarga de cada dispositivo baseado na clusterização dos dispositivos considerando apenas o conhecimento do S-CSI no PB; (ii) Demonstramos que o tempo total de recarga do sistema pode ser consideravelmente reduzido através da clusterização; (iii) Demonstramos que deve-se escolher de forma cuidadosa a estratégia de clusterização utilizada, pois, caso contrário, pode-se obter desempenhos inferiores aos obtidos para dispositivos não clusterizados.

II. MODELO DO SISTEMA

O modelo do sistema proposto é ilustrado na Figura 1 e consiste em um PB equipado com um arranjo linear uniforme

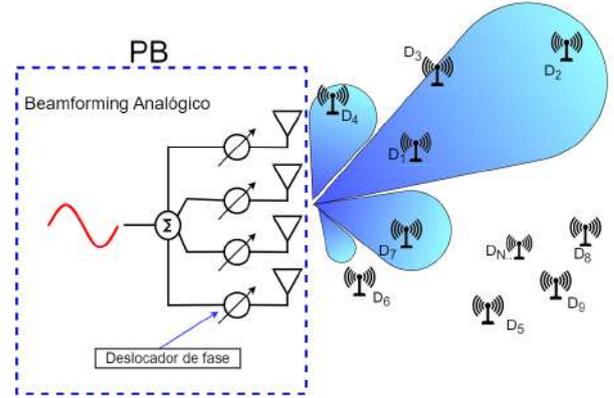


Fig. 1: Modelo do sistema.

(ULA, do inglês *Uniform Linear Array*) composto por L antenas o qual alimenta N dispositivos de IoT equipados com uma antena. Além disso, neste trabalho, considera-se *beamforming* analógico no PB, portanto, apenas um único feixe é gerado. Ademais, consideramos que os dispositivos de IoT podem coletar energia enquanto seus vizinhos estão sendo carregados, portanto o sinal recebido pelo n -ésimo dispositivo é dado por [10]

$$y_n = \sqrt{\beta_n} \mathbf{W}_j \mathbf{h}_n^H x, \quad (1)$$

onde, $\beta = \frac{c^2}{16\pi^2 f^2 d_n^\alpha}$ representa a perda de percurso do canal entre PB e o n -ésimo dispositivo de IoT, c denota a velocidade da luz, f a frequência da portadora, α o expoente de perda de percurso e $d_n > 1$ a distância entre o PB e o n -ésimo dispositivo. Ademais, $\mathbf{W}_j \in \mathbb{C}^{1 \times L}$ representa o vetor de *beamforming* analógico projetado para j -ésimo dispositivo, x o sinal transmitido que é modelado como $\mathcal{N}(0, \sigma^2)$. Por fim, \mathbf{h}_n^H descreve o vetor de canal entre o PB e o n -ésimo dispositivo de IoT e é dado por

$$\mathbf{h}_n = \sqrt{\frac{\kappa}{1+\kappa}} \mathbf{h}_n^{\text{LoS}} + \sqrt{\frac{1}{1+\kappa}} \mathbf{h}_n^{\text{NLoS}}, \quad (2)$$

onde κ é o fator Rice, e $\mathbf{h}_n^{\text{NLoS}}$ representa a componente sem linha de visada (NLoS, do inglês *Non Line of Sight*) do sinal modelada como *Rayleigh* e $\mathbf{h}_n^{\text{LoS}}$ denota a componente de linha de visada (LoS, do inglês *Line of Sight*) definida por $\mathbf{h}_n^{\text{LoS}} = e^{j\phi_0} [1 \ e^{j\xi_1} \ \dots \ e^{j\xi_{L-1}}]^T$, onde $e^{j\phi_0}$ denota a mudança de fase inicial, ξ_l a mudança de fase média do l -ésimo elemento da ULA em relação ao primeiro elemento e θ o ângulo de azimute.

Portanto, a energia coletada pelo n -ésimo dispositivo de IoT considerando *beamsharing*¹ é dada por

$$Q_n = \frac{1}{1-\Omega} \left\{ \underbrace{\left[\sum_{j=1, j \neq n}^{n-1} t_j (\Gamma_{j,n} - \gamma\Omega) \right]}_{Q_{\text{SEC}}} + \underbrace{[t_n (\Gamma_{n,n} - \gamma\Omega)]}_{Q_{\text{PRIM}}} \right\}, \quad (3)$$

em que

$$\Gamma_{j,n} = \frac{\mu}{1 + e^{-a(\beta_n |\mathbf{W}_j \mathbf{h}_n^H| - b)}}, \quad (4)$$

¹*Beamsharing* é definida como a capacidade de um dispositivo coletar energia enquanto outro dispositivo está sendo carregado.

e t_n e t_j denotam o tempo em que o PB está apontando para o n -ésimo ou para o j -ésimo dispositivo, respectivamente. $\Gamma_{j,n}$ representa a função logística tradicional, amplamente utilizada [13] para modelar o comportamento não linear da potência coletada pelo n -ésimo dispositivo de IoT quando o vetor de beamforming está sendo projetado para o j -ésimo dispositivo. γ é uma constante que denota a potência máxima coletada no dispositivo quando o circuito de EH está saturado e Ω é uma constante que garante uma resposta zero-entrada/zero-saída, a e b denotam constantes do circuito [13]. Aqui é importante verificar que a primeira parte de (3) denota a energia coletada pelo n -ésimo dispositivo quando os demais dispositivos estão sendo carregados (Q_{SEC}) a qual é calculada pela soma das contribuições de ($j = 1, \dots, n-1$) e a segunda parte de (3) denota a energia coletada pelo n -ésimo dispositivo quando o vetor de *beamforming* é projetado para apontar para este dispositivo (Q_{PRIM}), ou seja, $j = n$.

A. Problema de Otimização Proposto

O principal objetivo deste trabalho é minimizar o tempo total de carregamento do sistema $T_{\text{total}} = \sum_{n=1}^N t_n$ enquanto satisfaz as restrições de ganho constante no PB ($|W_{n,l}|^2 = \frac{P_T}{L}$) e de energia mínima necessária para todos os dispositivos IoT ($Q_n \geq E_{\text{min}}$) sem o conhecimento perfeito do CSI (PCSI, do inglês *Perfect CSI*). Para minimizar o tempo total de carregamento do sistema WET considera-se a otimização conjunta do vetor de *beamforming* no PB (\mathbf{W}_n) e a alocação de tempo de apontamento para cada dispositivo IoT (t_n). Portanto, o problema de otimização proposto é dado por

$$\begin{aligned} & \underset{\mathbf{W}_n, t_n}{\text{Minimize}} && T_{\text{total}} \\ & \text{Subject to} && Q_n \geq E_{\text{min}}, \\ & && |W_{n,l}|^2 = \frac{P_T}{L}, \\ & && n \in \{1, \dots, N\}, \quad l \in \{1, \dots, L\}, \end{aligned} \quad (5)$$

em que P_T denota a potência total no PB e E_{min} a restrição de energia mínima nos dispositivos IoT. Vale ressaltar que, considera-se a mesma restrição de energia para todos os dispositivos do sistema. A partir de (5), pode-se verificar que para obter T_{total} ótimo é necessário conhecimento do PCSI no PB, o que não é viável em cenários práticos. Portanto, baseado em [10], considera-se o projeto do *beamforming* no PB baseado apenas no S-CSI o qual é dada por

$$\mathbf{W}_n^* = \sqrt{\frac{P_T}{L}} \begin{bmatrix} \frac{h_{n,1}^{\text{LoS}}}{|h_{n,1}^{\text{LoS}}|}, \frac{h_{n,2}^{\text{LoS}}}{|h_{n,2}^{\text{LoS}}|}, \dots, \frac{h_{n,L}^{\text{LoS}}}{|h_{n,L}^{\text{LoS}}|} \end{bmatrix}^T. \quad (6)$$

Por fim, de acordo com [10], substituindo (6) em (5), têm-se o tempo de apontamento sub-ótimo para cada dispositivo de IoT, o qual é dado por [10]

$$\begin{aligned} t_1^* &= \left[\frac{E_{\text{min}}(1 - \Omega)}{\Gamma_1 - \mu\Omega} \right] \quad \text{para } n = 1, \\ t_n^* &= \left[\frac{(E_{\text{min}} - \sum_{j=1}^{n-1} Q_{\text{SEC}_j})(1 - \Omega)}{\Gamma_n - \mu\Omega} \right] \quad \text{para } n > 1. \end{aligned} \quad (7)$$

Portanto, a partir de (7) e (8) pode-se verificar que a ordem de carregamento pode influenciar em T_{total} . Portanto, a seguir

é proposta uma nova abordagem para definição da ordem de carregamento dos dispositivos IoT. Por fim, vale ressaltar que, visto que o PB não possui conhecimento do CSI, torna-se necessário informar quando o dispositivo está totalmente carregado. Logo, a solução encontrada para essa questão foi o envio de uma mensagem pelo n -ésimo dispositivo através do canal de controle sempre que estiver completamente carregado.

III. SOLUÇÃO PROPOSTA

Com o objetivo de minimizar o tempo de carregamento total dos dispositivos IoT, ou seja, resolver (5), foi proposta uma nova solução baseada na técnica de clusterização *K-means* a qual oferece uma maneira inteligente de determinar a ordem de carregamento dos dispositivos com base na proximidade entre eles [11]. Ademais, *K-means* é uma técnica amplamente utilizada devido a sua simplicidade e eficácia em problemas de clusterização [11]. A seguir, são descritos os principais passos do *K-means* aplicado na clusterização de dispositivos.

1. Determinar a posição de N dispositivos IoT;
2. Inicializar a posição de n_c centróides aleatoriamente;
3. Atribuir cada dispositivo ao centróide mais próximo considerando a distância Euclidiana;
4. Atualizar a posição dos centróides de acordo com a média da posição dos dispositivos atribuídos no cluster;
5. Verificar o critério de parada, ou seja, caso os centróides não se movam significativamente entre as iterações retorne os clusters gerados. Caso contrário, retorne ao Passo 2.

Para resolver (5), após realizada a clusterização dos dispositivos de IoT, é determinada a ordem de seleção dos dispositivos a serem carregados através da seleção dos clusters com a menor distância entre o centróide e o PB (Estratégia “**Próximo**”). Ademais, os dispositivos de cada cluster são selecionados de forma aleatória para serem carregados. Por fim, após determinada a ordem de carregamento dos dispositivos, o vetor de *beamforming* no PB para cada dispositivo IoT é determinado com base em (6) e o tempo de apontamento de cada dispositivo é definido com base em (7). Finalmente o Algoritmo refalgoritmo sumariza os passos da solução proposta.

IV. 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: $L = 10$, $R = 20$ m, $N = 20$, $f = 915$ MHz, $\kappa = 1, 5$, $\gamma = 10, 73$ mW, $a = 0.2308$, $b = 5, 365$, $E_{\text{min}} = 1$ μ J e $\alpha = 2, 7$. 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, os resultados obtidos pela solução proposta descrita na Seção III [“**SCSI (Beamsharing/Cluster) - Próximo**”], foram comparados com os seguintes *benchmarks*:

- **PCSI (Beamsharing/Sem Cluster)** no qual considera-se que os dispositivos coletam energia enquanto os demais dispositivos estão sendo carregados (*beamsharing*). Além

Algoritmo 1: Método proposto baseado em *K-means*.

Entrada: Parâmetros do Sistema: L , N , N_{set}

```

1 for  $i = 1 : N_{set}$  do
2   for  $i = 1 : N_{it}$  do
3     Distribua uniformemente  $N$  dispositivos de IoT.
4     Realize a clusterização dos  $N$  dispositivos de IoT.
5     Calcule a distância entre os centróides e o PB.
6     Defina a estratégia de seleção de dispositivos. (Aleatório/Próximo/Distante).
7     Defina  $W_n$  de acordo com (6).
8     Determine o  $t_n$  de acordo com (7).
9     Determine  $T_{total}$  de acordo com (5).
10  end
11 end
12 end
13 Determine  $T_{total}$  médio para  $N_{set}$  conjunto de dispositivos IoT e  $N_{it}$  realizações de canal.
14 return  $T_{total}$ 
    
```

disso, o projeto do *beamforming* no PB é realizado considerando conhecimento do PCSI no PB, no entanto, considera-se que o dispositivos IoT são selecionados de forma aleatória, ou seja, não é considerada a clusterização dos dispositivos;

- **PCSI (Sem Beamsharing/Cluster) - Próximo** no qual não é considerado *beamsharing* durante o carregamento dos dispositivos, mas os dispositivos são clusterizados e selecionados para serem carregados de acordo com a menor distância entre o centróide dos clusters e o PB;
- **PCSI (Beamsharing/Cluster) - Próximo** em que considera-se a clusterização dos dispositivos IoT e o projeto ótimo do *beamforming* no PB, isto é, este *benchmark* é considerado como *lower-bound* do sistema avaliado.

Vale ressaltar que para todos os *benchmarks* foi considerado o número de clusters ótimo.

A. Análise da Influência do Número de Dispositivos de IoT

A Figura 2 ilustra a influência da clusterização de dispositivos em T_{total} para diferentes valores de K . Inicialmente são apresentados os resultados obtidos considerando diferentes estratégias de seleção dos clusters, isto é, “*Aleatório*” no qual os clusters são selecionados aleatoriamente; “*Distante*” em que os clusters são selecionados de acordo com a maior distância entre o centróide e o PB; e “*Próximo*” em que os clusters são selecionados de acordo com a menor distância entre o centróide e o PB. Para ambas as abordagens, após selecionado o clusters, os dispositivos de cada cluster são selecionados de forma aleatória para serem carregados. Através dos resultados obtidos é possível observar que deve-se escolher cuidadosamente a estratégia de seleção de dispositivos a ser utilizada, pois, caso contrário, o T_{total} obtido é inferior ao valor obtido para o caso onde não é considerada a clusterização de usuários (“PCSI (Beamsharing/Sem Cluster)”). Ademais, verifica-se que é possível reduzir em até 75% T_{total} , para $K = 35$, quando considera-se estratégia de seleção onde os usuários clusterizados são selecionados de acordo com o

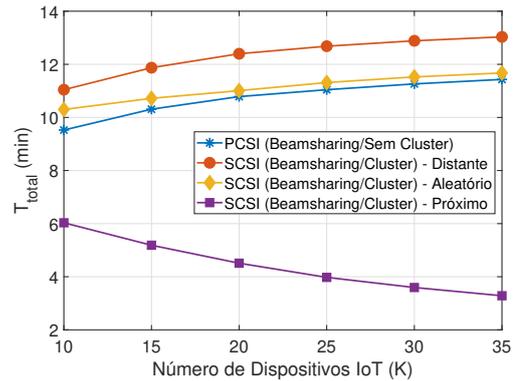


Fig. 2: Influência da clusterização de dispositivos em T_{total} .

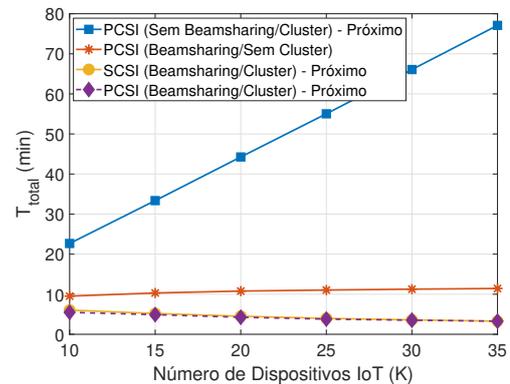


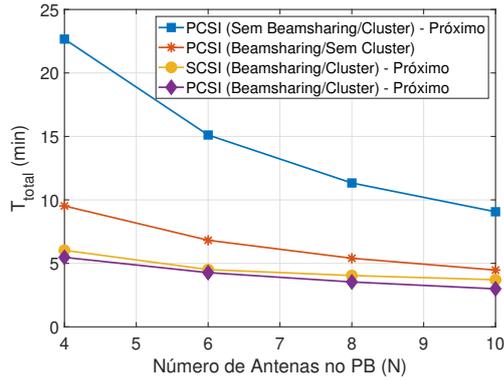
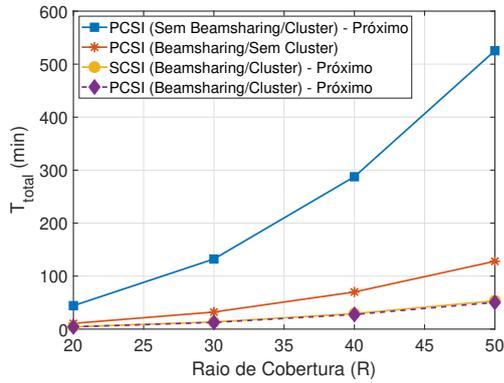
Fig. 3: Análise de T_{total} vs K .

centróide mais próximo do PB (“PCSI (Beamsharing/Cluster) - Próximo”). Tendo em vista o desempenho da solução proposta “PCSI (Beamsharing/Cluster) - Próximo”, os próximos resultados irão considerar apenas essa estratégia de seleção de dispositivos.

Por fim, a Figura 3 evidencia a importância da clusterização na redução de T_{total} e também demonstra que é possível obter um resultado sub-ótimo considerando apenas o conhecimento do SCSI no PB (“SCSI (Beamsharing/Cluster) - Próximo” *versus* “PCSI (Beamsharing/Cluster) - Próximo”). Ademais, a partir dos resultados obtidos observa-se a importância de considerar *beamsharing*, ou seja, considerar que os dispositivos vizinhos podem coletar energia enquanto os demais dispositivos estão sendo carregados (“PCSI - (Sem Beamsharing/Cluster) - Próximo”).

B. Análise da Influência do Número de Antenas no PB

A Figura 4 ilustra a influência do número de antenas no PB (L) em T_{total} . Através dos resultados obtidos verificou-se que a solução proposta “SCSI (Beamsharing/Cluster) - Próximo” reduz T_{total} em até 37%, 34%, 26% e 17% para $N = 4, 6, 8, 10$, respectivamente. Ademais, a partir da Figura 4, pode-se observar que T_{total} não decai linearmente quando N aumenta. Isso pode ser explicado devido ao fato de que, se N aumenta, aumenta a diretividade do arranjo de antenas no PB e, conseqüentemente, reduz a influência do *beamsharing* em T_{total} . Por fim, pode-se verificar que a solução proposta atinge um resultado próximo ao ótimo para qualquer N sem


 Fig. 4: Análise de T_{total} vs N .

 Fig. 5: Análise de T_{total} vs R .

CSI perfeito no PB (“SCSI (Bamsharing/Cluster) - Próximo” versus “PCSI (Bamsharing/Cluster) - Próximo”).

C. Análise da Influência do Raio do Sistema

A Figura 5 ilustra a influência de R em T_{total} . Conforme o esperado, T_{total} aumenta quando R aumenta. Isso pode ser explicado devido ao fato de que os dispositivos de IoT são uniformemente distribuídos em uma maior área, resultando em um aumento na perda de percurso, ou seja, com o aumento da distância entre o PB e alguns dispositivos de IoT, há uma redução na potência coletada nos dispositivos de IoT e, conseqüentemente, torna-se necessário uma maior tempo de apontamento para cada dispositivo. Novamente, pode-se verificar que a solução proposta atinge um resultado próximo ao ótimo para qualquer R sem CSI perfeito no PB (“SCSI (Bamsharing/Cluster) - Próximo” versus “PCSI (Bamsharing/Cluster) - Próximo”). Portanto, os resultados obtidos demonstram a robustez da solução proposta e a importância de clusterizar os dispositivos de IoT visando minimizar T_{total} .

V. CONCLUSÕES

Neste trabalho, propomos uma nova abordagem para minimizar o tempo de recarga dos dispositivos através da aplicação da técnica de aprendizado de máquina não supervisionado K -means, atendendo à restrição mínima de energia coletada em cada dispositivo. Ademais, realizamos o projeto do *beamforming* no PB baseado no conhecimento do SCSi e consideramos a técnica de *beamsharing*. Por fim, os resultados numéricos

demonstram que a clusterização de dispositivos pode reduzir em até 75% o tempo de recarga total e que a solução proposta atinge uma solução próxima ao ideal para diferentes cenários, demonstrando a sua robustez. Para trabalhos futuros pretende-se desenvolver novas soluções para posicionamento dos PBs em cenários com um número massivo de dispositivos IoT e múltiplos PBs visando minimizar o tempo total de carregamento dos dispositivos.

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, pela FAPEMIG no âmbito dos projetos nº APQ-05305-23, APQ-04523-23 e RED-00194-23, e pelo CNPq (402378/2021-0, 305021/2021-4) e no Chile pelo projeto ANID FONDECYT Regular No. 1241977.

REFERÊNCIAS

- [1] O. M. Rosabal, O. L. A. López, H. Alves, R. D. Souza, and S. Montejo-Sánchez, “Massive Wireless Energy Transfer with Multiple Power Beacons for very large Internet of Things,” 2021.
- [2] H. Elahi, K. Munir, M. Eugeni, S. Atek, and P. Gaudenzi, “Energy Harvesting towards Self-Powered IoT Devices,” *Energies*, vol. 13, 2020. [Online]. Available: <https://www.mdpi.com/1996-1073/13/21/5528>
- [3] O. L. Lopez, H. Alves, R. D. Souza, S. Montejo-Sanchez, E. M. G. Fernandez, and M. Latva-Aho, “Massive Wireless Energy Transfer: Enabling Sustainable IoT Toward 6G Era,” *IEEE Internet of Things Journal*, vol. 8, pp. 8816–8835, 6 2021.
- [4] O. L. Lopez, H. Alves, S. Montejo-Sanchez, R. D. Souza, and M. Latva-Aho, “CSI-Free Rotary Antenna Beamforming for Massive RF Wireless Energy Transfer,” *IEEE Internet of Things Journal*, vol. 9, pp. 7375–7387, 5 2022.
- [5] S. Bi, Y. Zeng, and R. Zhang, “Wireless powered communication networks: an overview,” *IEEE Wireless Communications*, vol. 23, no. 2, pp. 10–18, 2016.
- [6] F. A. Monteiro, O. L. A. López, and H. Alves, “Massive Wireless Energy Transfer With Statistical CSI Beamforming,” *IEEE Journal of Selected Topics in Signal Processing*, vol. 15, no. 5, pp. 1169–1184, 2021.
- [7] O. L. López, H. Alves, R. D. Souza, and S. Montejo-Sánchez, “Statistical Analysis of Multiple Antenna Strategies for Wireless Energy Transfer,” *IEEE Trans. on Communications*, vol. 67, pp. 7245–7262, 10 2019.
- [8] B. Clerckx and J. Kim, “On the Beneficial Roles of Fading and Transmit Diversity in Wireless Power Transfer with Nonlinear Energy Harvesting,” *IEEE Transactions on Wireless Communications*, vol. 17, pp. 7731–7743, 11 2018.
- [9] O. L. Lopez, 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, pp. 58–62, 1 2021.
- [10] V. Dala, P. Souto, M. Rosabal, S. Montejo-Sánchez, O. Luis, 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,” in *XLI Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*, 2023.
- [11] K. P. Sinaga and M.-S. Yang, “Unsupervised K-Means Clustering Algorithm,” *IEEE Access*, vol. 8, pp. 80716–80727, 2020.
- [12] S. Zhang, C. Guo, T. Wang, and W. Zhang, “ON-OFF Analog Beamforming for Massive MIMO,” *IEEE Transactions on Vehicular Technology*, vol. 67, no. 5, pp. 4113–4123, 2018.
- [13] E. Boshkovska, D. W. K. Ng, N. Zlatanov, and R. Schober, “Practical Non-linear Energy Harvesting Model and Resource Allocation for SWIPT Systems,” 9 2015. [Online]. Available: <http://arxiv.org/abs/1509.02956http://dx.doi.org/10.1109/LCOMM.2015.2478460>