

Alocação Espacial de Power Beacons em Sistemas WET

Gabriel Cerantola Rigatto Moras, Richard Demo Souza e Victoria Dala Pegorara Souto

Resumo— Este artigo investiga a otimização conjunta do posicionamento de *Power Beacons* (PBs) e do *beamforming* de energia em sistemas de Transferência de Energia Sem Fio (WET, do inglês *Wireless Energy Transfer*) para redes IoT, com o objetivo de minimizar o tempo total de carregamento e a probabilidade de *outage*. Considera-se um cenário com PBs multiantena, *beamforming* analógico, informação estatística do canal (SCSI, do inglês *Statistical Channel State Information*) e modelo não linear de coleta de energia. Para esse fim, diferentes técnicas de clusterização são empregadas no posicionamento dos PBs. Os resultados mostram que o posicionamento inteligente dos PBs melhora significativamente a eficiência e a confiabilidade do sistema em comparação com estratégias aleatórias.

Palavras-Chave— Transferência de Energia Sem Fio, IoT, Clusterização.

Abstract— This article investigates the joint optimization of *Power Beacon* (PB) placement and energy *beamforming* in Wireless Energy Transfer (WET) systems for IoT networks, aiming to minimize the total charging time and the devices' *outage* probability. A scenario with multi-antenna PBs, analog *beamforming*, statistical channel state information (SCSI), and a non-linear energy harvesting model is considered. To this end, different clustering techniques are employed for PB placement. The results show that intelligent PB placement significantly improves system efficiency and reliability when compared with random strategies.

Keywords— Wireless Energy Transfer, IoT, Clustering.

I. Introdução

A Transferência de Energia Sem Fio (WET, do inglês *Wireless Energy Transfer*) baseada em radiofrequência (RF) tem se destacado como uma alternativa promissora para redes IoT, sobretudo em cenários nos quais o fornecimento convencional de energia é limitado ou inviável. Esse paradigma é particularmente relevante em aplicações como agricultura inteligente e sensoriamento remoto, que demandam suprimento energético contínuo e confiável [1]. Nesse contexto, o desempenho do sistema depende fortemente do posicionamento dos *Power Beacons* (PBs), cuja implantação deve ser

cuidadosamente planejada para ampliar a cobertura e mitigar perdas de propagação [1].

Diversos estudos têm abordado esse problema sob distintas perspectivas. Em [1], investigou-se a alocação de PBs omnidirecionais sem conhecimento prévio das posições dos dispositivos nem das informações do estado do canal (CSI, do inglês *Channel State Information*). Em [2], foi proposto um método baseado em *wavelets* de Daubechies para redes de sensores recarregáveis. Já em [3], o problema de implantação e orientação de PBs direcionais foi tratado por meio de um algoritmo guloso, enquanto [4] formulou um problema conjunto de posicionamento e adaptação de potência em redes sem bateria. Abordagens mais abrangentes também foram exploradas sob métricas como custo, tempo de vida da rede, utilidade, aprendizado por reforço e operação *online* [5], [6], [7], [8]. Mais recentemente, [9] propôs uma solução para a otimização conjunta do posicionamento dos PBs e do *beamforming* de energia com base apenas nas informações estatísticas do estado do canal (SCSI, do inglês *Statistical Channel State Information*), empregando mapas auto-organizáveis (SOM, do inglês *Self-Organizing Maps*) para definir posições dos PBs.

Motivado por esse cenário, este artigo investiga a otimização conjunta do posicionamento dos PBs e do *beamforming* de energia, com o objetivo de minimizar simultaneamente o tempo de carregamento e o impacto desse processo na probabilidade de *outage* dos dispositivos. Para isso, são avaliadas diferentes técnicas de clusterização em um cenário com SCSI, PBs multiantena, *beamforming* analógico e modelo não linear de coleta de energia. Em contraste com a literatura, que adota formulações mais restritas, este artigo utiliza uma modelagem alinhada à de [9], incorporando explicitamente a interação entre o posicionamento dos PBs e o *beamforming*. Adicionalmente, diferentemente de [9], são analisadas distintas técnicas de clusterização também sob a métrica de probabilidade de *outage*, bem como um modelo de consumo energético mais realista para os dispositivos IoT, no qual estes continuam consumindo energia durante o período de carregamento para executar atividades básicas. Com isso, busca-se identificar a estratégia de posicionamento mais adequada em termos de eficiência temporal, confiabilidade energética e viabilidade prática.

Gabriel Cerantola Rigatto Moras e Victoria Dala Pegorara Souto, Instituto Nacional de Telecomunicações, e-mail: {natalia.batista@gec.inatel.br; victoria.souto@inatel.br}; Richard Demo Souza, Universidade Federal de Santa Catarina, e-mail: {richard.demo@ufsc.br}.

II. Modelo de Sistema

Neste artigo, considera-se o modelo de sistema no qual um conjunto de K PBs, denotado por $\mathcal{P} = \{1, 2, \dots, K\}$, transmite energia sem fio para um conjunto de N dispositivos IoT, representado por $\mathcal{I} = \{1, 2, \dots, N\}$. Cada PB é equipado com um arranjo linear uniforme (ULA, do inglês *Uniform Linear Array*) composto por M antenas. Além disso, adota-se *beamforming* analógico em conjunto com a técnica de *beamsharing*, a qual possibilita a coleta de energia por dispositivos vizinhos mesmo quando o feixe principal está direcionado a outro nó [10]. Nesse contexto, seja $\mathbf{h}_{n,k} \in \mathbb{C}^{M \times 1}$ o vetor de canal entre o k -ésimo PB e o n -ésimo dispositivo IoT. Assume-se que esse canal segue um modelo de desvanecimento Rician, dado por $\mathbf{h}_{n,k} = \sqrt{\frac{\kappa_{n,k}}{1+\kappa_{n,k}}} \mathbf{h}_{n,k}^{\text{LoS}} + \sqrt{\frac{1}{1+\kappa_{n,k}}} \mathbf{h}_{n,k}^{\text{NLoS}}$, em que $\mathbf{h}_{n,k}^{\text{LoS}} \in \mathbb{C}^{M \times 1}$ representa a componente em linha de visada (LoS, do inglês *Line-of-Sight*) do canal, enquanto $\mathbf{h}_{n,k}^{\text{NLoS}} \in \mathbb{C}^{M \times 1}$ corresponde à componente sem linha de visada (NLoS, do inglês *Non-Line-of-Sight*), modelada segundo uma distribuição de desvanecimento Rayleigh e $\kappa_{n,k}$ denota o fator de Rician. Ademais, a perda de percurso em todos os enlaces é descrita por meio do modelo log-distância, dado por $\gamma_{n,k} = (\lambda/4\pi)^2 d_{n,k}^{-\alpha_{n,k}}$, em que λ representa o comprimento de onda, $d_{n,k}$ é a distância entre o k -ésimo PB e o n -ésimo dispositivo e $\alpha_{n,k}$ é o expoente de perda de percurso. Por fim, a energia total coletada pelo n -ésimo dispositivo IoT pode ser expressa como

$$E_n = \sum_{k \in \mathcal{P}} \frac{t_{n,k} \left[\mathcal{L}_n \left(\delta_{n,k} \gamma_{n,k} \left| \mathbf{w}_{n,k}^H \mathbf{h}_{n,k} \right|^2 \right) - \mu \Omega \right]}{1 - \Omega} \quad (1)$$

$$+ \sum_{\substack{j \in \mathcal{I} \\ j \neq n}} \sum_{k \in \mathcal{P}} \frac{t_{j,k} \left[\mathcal{L}_n \left(\delta_{j,k} \gamma_{n,k} \left| \mathbf{w}_{j,k}^H \mathbf{h}_{n,k} \right|^2 \right) - \mu \Omega \right]}{1 - \Omega},$$

em que $\delta_{n,k} \in \{0, 1\}$ é uma variável indicadora aleatória que define o dispositivo do *cluster* atendido pelo k -ésimo PB. Especificamente, $\delta_{n,k} = 1$ indica que o PB k direciona seu feixe de energia ao dispositivo n . O vetor $\mathbf{w}_{n,k} \in \mathbb{C}^{M \times 1}$ representa o vetor de *beamforming* do k -ésimo PB para o n -ésimo dispositivo, com $\|\mathbf{w}_{n,k}\|^2 = P_T$, sendo P_T a potência máxima de transmissão dos PBs. Além disso, $t_{n,k}$ e $t_{j,k}$ denotam os tempos de apontamento do PB k para os dispositivos n e j , respectivamente. Define-se ainda $\Omega = \frac{1}{1+e^{ab}}$, em que a e b são parâmetros relacionados às limitações de *hardware* do circuito de coleta de energia. Finalmente, a não linearidade do processo de coleta de energia é modelada pela função logística $\mathcal{L}_n(x) = \mu \left[1 + e^{-a(P_n(x)-b)} \right]^{-1}$, em que μ corresponde ao valor máximo de energia coletável pelo n -ésimo dispositivo IoT.

A. Probabilidade de Outage dos Dispositivos IoT

Por fim, assume-se que cada dispositivo $n \in \mathcal{I}$ deve manter um nível mínimo de energia para assegurar sua operação. Ademais, os dispositivos continuam consumindo energia durante o intervalo de carregamento, mesmo enquanto coletam energia. Seja, então, P_n^c a potência média consumida pelo dispositivo n nesse intervalo. Se a duração total de carregamento é dada por $t_T = \sum_{n \in \mathcal{I}} \sum_{k \in \mathcal{P}} \delta_{n,k} t_{n,k}$, a energia disponível no dispositivo n ao final desse período pode ser escrita como $\tilde{E}_n = E_n - P_n^c t_T$. Dessa forma, o modelo considera simultaneamente os processos de coleta e consumo de energia, resultando em uma representação mais realista da operação dos dispositivos. Assumindo que cada dispositivo deva manter um nível mínimo de energia operacional $E_n^{\min}$, o evento de *outage* do dispositivo n é definido como

$$p_n^{\text{out}} \triangleq \Pr(\mathcal{O}_n) = \Pr(E_n < E_n^{\min} + P_n^c t_T). \quad (2)$$

B. Problema de Otimização Proposto

O objetivo deste artigo consiste em minimizar o tempo total de carregamento necessário para suprir energeticamente um grande número de dispositivos IoT, definido por $t_T = \sum_{n \in \mathcal{I}} \sum_{k \in \mathcal{P}} \delta_{n,k} t_{n,k}$, por meio da otimização conjunta do *beamforming* de energia e do posicionamento dos PBs. Nesse contexto, o problema de otimização pode ser formulado como

$$\begin{aligned} & \underset{\mathbf{w}_{n,k}, x_{\text{PB}_k}, y_{\text{PB}_k}, t_{n,k}}{\text{Minimizar}} & t_T &= \sum_{n \in \mathcal{I}} \sum_{k \in \mathcal{P}} \delta_{n,k} t_{n,k} \\ & \text{Sujeito a} & E_n &\geq E_n^{\min} \quad \forall n \in \{1, \dots, N\}, \\ & & x_{\text{PB}_k}, y_{\text{PB}_k} &\in [-R, R], \quad \forall k \in \{1, \dots, K\}, \\ & & |w_{n,k,m}|^2 &= \frac{P_T}{M}, \quad \forall n, k, m, \\ & & m &\in \{1, \dots, M\}, \end{aligned} \quad (3)$$

em que $E_n^{\min}$ representa o requisito mínimo de energia do n -ésimo dispositivo IoT, $|w_{n,k,m}|^2 = \frac{P_T}{M}$ corresponde à restrição do *beamforming* analógico, e $(x_{\text{PB}_k}, y_{\text{PB}_k}) \in [-R, R]$ estabelece a restrição de posicionamento dos PBs, sendo R o parâmetro que delimita a região de cobertura do sistema.

Como evidenciado em (3), o problema de otimização é não convexo, devido ao acoplamento entre as variáveis de posicionamento, os vetores de *beamforming* e os tempos de carregamento, além da não linearidade do modelo de coleta de energia e do efeito de *beamsharing*. Em razão disso, não se obtém uma solução fechada, nem é possível aplicar diretamente métodos clássicos de otimização convexa. Assim, neste trabalho, adota-se uma estratégia iterativa para o projeto do *beamforming* e a otimização das posições dos PBs, conforme descrito na próxima seção.

III. Solução Proposta

Conforme discutido anteriormente, a solução proposta é obtida de forma iterativa. Inicialmente, os dispositivos IoT são agrupados por meio do método de clusterização adotado. Em seguida, define-se o posicionamento dos PBs com base na estrutura dos *clusters* formados. A cada iteração, determina-se o dispositivo atendido por cada PB, isto é, define-se o valor de $\delta_{n,k}$. Com base nessa associação, projeta-se o vetor de *beamforming* de cada PB segundo (4), o que permite calcular numericamente o tempo de carregamento e atualizar a energia acumulada em cada dispositivo. As principais etapas da solução proposta são descritas a seguir:

1. Inicializar o conjunto de dispositivos IoT não carregados, $\mathcal{N}_C = \{1, \dots, N\}$ e aplicar o método de clusterização selecionado sobre $\mathcal{N}_C$, particionando os dispositivos em K grupos;
2. Determinar a posição de cada PB a partir da representação de cada *cluster*, tal como seu centróide ou medoide, de acordo com o método adotado;
3. Enquanto $\mathcal{N}_C \neq \emptyset$:
 - 3.1. Para cada PB, selecionar o dispositivo IoT a ser atendido no respectivo *cluster*, definindo os valores de $\delta_{n,k}$;
 - 3.2. Projetar o vetor de *beamforming* $\mathbf{w}_{n,k}$ de cada PB para o dispositivo selecionado na etapa anterior, assumindo que apenas a SCSi está disponível. Nesse caso, o vetor de *beamforming* é definido por

$$\mathbf{w}_{n,k} = \sqrt{\frac{P_T}{M}} \left[\frac{h_{n,k,1}^{\text{LoS}}}{|h_{n,k,1}^{\text{LoS}}|}, \frac{h_{n,k,2}^{\text{LoS}}}{|h_{n,k,2}^{\text{LoS}}|}, \dots, \frac{h_{n,k,M}^{\text{LoS}}}{|h_{n,k,M}^{\text{LoS}}|} \right]^T.$$
 - 3.3. Determinar numericamente o tempo de carregamento $t_{n,k}$ dos dispositivos atendidos por cada PB, de modo a satisfazer a restrição mínima de energia;
 - 3.4. Atualizar a energia acumulada de cada dispositivo, com base em (4);
 - 3.5. Verificar quais dispositivos atingiram $E_n^{\min}$ e removê-los do conjunto $\mathcal{N}_C$;

Por fim, como se pode observar, a solução proposta depende da técnica de clusterização adotada para determinar o posicionamento dos PBs. Neste artigo, são consideradas as técnicas *K-means* e *K-Medoids*, cujas principais características e princípios de funcionamento são descritos a seguir.

A. K-Means

O algoritmo *K-Means* é um método de clusterização particional que divide um conjunto de dados em n grupos, minimizando a soma das distâncias quadráticas

entre cada ponto e o centróide do *cluster* ao qual está associado, métrica denominada *within-cluster sum of squares* (WCSS) [11]. Seu procedimento iterativo consiste em: (i) definir o número de *clusters* e inicializar os centróides; (ii) associar cada ponto ao centróide mais próximo, geralmente com base na distância Euclidiana; (iii) atualizar os centróides a partir da média dos pontos pertencentes a cada grupo; e (iv) repetir essas etapas até a convergência. A definição adequada do número de *clusters* n é um aspecto central do método, podendo ser auxiliada pelo método do cotovelo. Embora apresente baixa complexidade computacional e boa eficiência prática, o desempenho do *K-Means* é sensível tanto à escolha de n quanto à inicialização dos centróides, podendo levar a soluções subótimas.

B. K-Medoids

O algoritmo *K-Medoids* é um método de clusterização particional que, em comparação ao *K-Means*, apresenta maior robustez à presença de ruídos e *outliers*. Diferentemente do *K-Means*, que representa cada grupo por meio do centróide, o *K-Medoids* utiliza como representante um elemento do próprio conjunto de dados, denominado medoide, escolhido de modo a minimizar a soma das dissimilaridades no respectivo *cluster*. Assim, o método particiona os dados em n grupos, minimizando a soma das distâncias entre cada ponto e o medoide associado [11]. Seu procedimento iterativo envolve [11]: (i) a definição do número de *clusters* e a seleção inicial dos medoides; (ii) a associação de cada ponto ao medoide mais próximo; (iii) a atualização dos medoides por meio da avaliação de substituições que reduzam o custo total; e (iv) a repetição dessas etapas até a convergência. Uma implementação amplamente empregada é o algoritmo PAM (*Partitioning Around Medoids*), que, embora apresente maior custo computacional que o *K-Means*, tende a oferecer maior estabilidade em conjuntos de dados com ruídos ou distribuições não esféricas.

IV. Resultados e Discussões

Nesta seção, apresentam-se os resultados obtidos para os métodos descritos na Seção III. Considera-se um cenário em que os dispositivos IoT estão uniformemente distribuídos em um plano bidimensional, com posições dadas por (x_n, y_n) . Salvo indicação em contrário, os resultados foram obtidos adotando-se $\alpha_{n,k} = 2,7$ para todos os enlaces, $\mu = 10,73$ mW, $a = 5,365$, $b = 0,2308$, $f = 915$ MHz, $P_T = 3$ W, $M = 4$, $\kappa_{n,k} = 1,0$, $E_{\min} = 1$ mJ, $P_n^C = 0,1$ μ J para todos os dispositivos IoT, $K = 4$, $R = 30$ m e $N = 20$. Os resultados foram obtidos por meio de simulações de Monte Carlo, considerando 10^3 realizações independentes em 10 diferentes cenários de implantação.

Para avaliar o desempenho das estratégias consideradas, adotam-se dois *benchmarks*: (i) Assume-se conhecimento do PCSI nos PBs, de modo que o vetor de *beamforming* e o tempo de carregamento são determinados com base no PCSI, enquanto o posicionamento dos PBs é obtido pelos algoritmos *K-means*, *K-medoids*, SOM [9] ou *Random*, correspondente ao posicionamento aleatório dos PBs; (ii) Considera-se apenas o conhecimento da SCSi para o projeto do vetor de *beamforming*, mantendo-se o posicionamento dos PBs baseado nas técnicas de clusterização.

As Figuras 1 e 2 mostram o impacto do número de dispositivos IoT, N , sobre o tempo total de carregamento, t_T , e a probabilidade de *outage*, nos cenários com PCSI e SCSi, respectivamente. Em ambos os casos, o aumento de N eleva o tempo total de carregamento para todas as estratégias avaliadas, como esperado, em razão do acréscimo da demanda energética e da maior competição pelos recursos de transferência de energia. Entre os métodos analisados, *K-means* e *K-medoids* apresentam, de forma consistente, os menores tempos de carregamento, enquanto a SOM exibe desempenho intermediário. Como esperado, o posicionamento aleatório (*Random*) resulta nos maiores valores de t_T , evidenciando sua menor eficiência na organização espacial dos PBs.




Fig. 1: Influência de N considerando PCSI.






Fig. 2: Influência de N considerando SCSi.

Em relação à probabilidade de *outage*, observa-se também crescimento com N em ambos os cenários,

refletindo a maior dificuldade de atender energeticamente todos os dispositivos à medida que a rede se torna mais densa. O *K-means* apresenta o melhor desempenho global, mantendo as menores taxas de *outage* ao longo de toda a faixa de N . Ademais, a comparação entre os cenários PCSI e SCSi evidencia um compromisso entre eficiência temporal e confiabilidade energética. No cenário com SCSi, todas as estratégias apresentam redução significativa na probabilidade de *outage* em relação ao caso com PCSI, ao custo de um aumento no tempo total de carregamento. No contexto considerado, esse comportamento sugere que o uso de SCSi conduz a uma transferência de energia menos concentrada espacialmente, favorecendo o atendimento de um maior número de dispositivos por efeito de *beamsharing*, porém com menor eficiência no carregamento do dispositivo alvo. Em contrapartida, o PCSI permite direcionamento mais preciso da energia e, conseqüentemente, menor tempo de carregamento, mas tende a concentrar mais potência nos dispositivos selecionados, reduzindo a energia incidental recebida pelos demais e elevando a probabilidade de *outage*. Em síntese, os resultados indicam que o *K-means* oferece o melhor compromisso entre escalabilidade temporal e confiabilidade energética em ambos os cenários.

A Figura 3 mostra o impacto do número de antenas M sobre o tempo total de carregamento e a probabilidade de *outage* no cenário com SCSi. Observa-se que o aumento de M reduz o tempo total de carregamento para todas as estratégias avaliadas. Esse comportamento decorre do maior ganho de arranjo e da maior diretividade do feixe, que permitem concentrar mais energia nos dispositivos efetivamente atendidos, acelerando o processo de carregamento. Por outro lado, verifica-se também aumento da probabilidade de *outage* com o crescimento de M . Embora feixes mais diretos favoreçam a transferência de energia para os dispositivos selecionados, eles reduzem a energia incidental recebida pelos demais por efeito de *beamsharing*. Como, no modelo adotado, os dispositivos continuam consumindo energia durante o intervalo de carregamento, essa menor distribuição espacial de energia tende a elevar o número de nós que não atingem o nível mínimo requerido, aumentando a taxa de *outage*. Esses resultados indicam que, embora o aumento de M beneficie a eficiência temporal do carregamento, ele intensifica o compromisso entre concentração de energia e confiabilidade energética, sendo o *K-means* a alternativa mais equilibrada nesse cenário.

A Figura 4 apresenta o impacto da variação de $\kappa_{n,k}$ sobre o tempo total de carregamento e a probabilidade de *outage* dos dispositivos IoT, considerando apenas o conhecimento da SCSi. Observa-se que, para todas as estratégias avaliadas, o aumento de $\kappa_{n,k}$ reduz ligeiramente o tempo de carregamento, o que é com-


 Fig. 3: Influência da variação de M .

 Fig. 4: Influência da variação de κ .

patível com o fortalecimento da componente LoS e, consequentemente, com condições de propagação mais previsíveis para a transferência de energia. Em contrapartida, a probabilidade de *outage* aumenta com $\kappa_{n,k}$, indicando que a melhora na eficiência de carregamento não se traduz, necessariamente, em maior uniformidade no atendimento energético dos dispositivos, o que pode ser atribuído à redução da energia secundária coletada por efeito de *beamsharing*. Entre os métodos analisados, novamente o *K-means* apresenta o melhor compromisso entre tempo de carregamento e probabilidade de *outage*, mantendo consistentemente os menores níveis de *outage* e, simultaneamente, um dos menores tempos de carregamento ao longo de toda a faixa de $\kappa_{n,k}$. Esses resultados evidenciam que a solução baseada em *K-means* oferece a estratégia mais adequada de posicionamento dos PBs em termos de eficiência temporal e confiabilidade energética.

V. Conclusão

Este trabalho investigou a otimização conjunta do posicionamento de PBs e do *beamforming* de energia em sistemas WET para redes IoT, visando minimizar o tempo total de carregamento e a probabilidade de *outage*. Os resultados mostraram que o posicionamento inteligente dos PBs melhora significativamente a eficiência e a confiabilidade do sistema em relação ao posicionamento aleatório. Entre os métodos avaliados, o K-means apresentou, em geral, o melhor compromisso entre desempenho e simplicidade computacional, enquanto o K-medoids também obteve resultados

competitivos. Esses resultados evidenciam a relevância da otimização conjunta entre posicionamento e *beamforming* no projeto de infraestruturas WET mais eficientes e robustas.

Agradecimentos

Os seguintes projetos de pesquisa financiaram este trabalho: Projeto Brasil 6G com apoio da RNP/MCTI (01245.020548/2021-07), Projetos xGMobile código XGM-AFCCT-2024-4-1-1 e XGM-AFCCT-2026-4-1-1 com recursos da EMBRAPII/MCTI (Processo 052/2023 PPI IoT/Manufatura 4.0 e FAPEMIG PPE-00124-23); FAPEMIG (APQ-04523-23, BIS-00529-25, APQ-05305-23, APQ-01558-24, RED-00194-23); CNPq (305021/2021-4, 443974/2024-1, INCT STREAM 409179/2024-8); e Centro de Competência em Redes 5G e 6G Ref. Finep nº 1060/2 contrato nº 0-1-25-0883-00.

Referências

- [1] O. M. Rosabal, O. L. A. Lopez, H. Alves, S. Montejo-Sanchez, 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, p. 10531–10542, Jul. 2021.
- [2] D. Arivudainambi and S. Balaji, "Optimal Placement of Wireless Chargers in Rechargeable Sensor Networks," *IEEE Sensors Journal*, vol. 18, no. 10, pp. 4212–4222, 2018.
- [3] 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.
- [4] A. Kumar and J. Singh, "Optimizing Location and Power of Chargers to Reduce Interference in Battery-Less WSNs," *IEEE Sensors Journal*, vol. 24, no. 16, pp. 26 552–26 563, 2024.
- [5] X. Ding, Y. Wang, G. Sun, C. Luo, D. Li, W. Chen, and Q. Hu, "Optimal charger placement for wireless power transfer," *Computer Networks*, vol. 170, p. 107123, 2020. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1389128619307947>
- [6] D. Zorbas, P. Raveneau, Y. Ghamri-Doudane, and C. Douligeris, "The charger positioning problem in clustered RF-power harvesting wireless sensor networks," *Ad Hoc Networks*, vol. 78, pp. 42–53, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1570870518302440>
- [7] X. Ding, J. Guo, Y. Wang, D. Li, and W. Wu, "Task-driven charger placement and power allocation for wireless sensor networks," *Ad Hoc Networks*, vol. 119, p. 102556, 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1570870521001037>
- [8] H. Dai, Y. Zhang, X. Wang, A. X. Liu, and G. Chen, "Omni-directional Chargability With Directional Antennas," *IEEE Transactions on Mobile Computing*, vol. 23, no. 5, pp. 4483–4500, 2024.
- [9] G. C. Morás, M. V. S. de Oliveira, V. D. Souto, and R. D. Souza, "Optimizing power beacon placement in wet systems via self-organizing maps."
- [10] V. D. P. Souto, O. M. Rosabal, S. Montejo-Sánchez, O. L. A. López, H. Alves, and R. D. Souza, "An Analog Beamforming Strategy Based on Statistical Channel Information for Recharging Wireless Powered Sensor Networks," *IEEE Sensors Journal*, vol. 24, no. 14, pp. 23 025–23 033, 2024.
- [11] X. Jin and J. Han, *K-Medoids Clustering*. Boston, MA: Springer US, 2010, pp. 564–565. [Online]. Available: https://doi.org/10.1007/978-0-387-30164-8_426