

ENERGY EFFICIENCY IN WIRELESS COMMUNICATION IN IOT SYSTEMS WITH K-MEANS CLUSTERING

EFICIÊNCIA ENERGÉTICA NA COMUNICAÇÃO SEM FIO EM SISTEMAS IOT COM AGRUPAMENTO K-MEANS

DOI: 10.51859/amplla.sset.4126-12

Maurício Brigato¹
André Alves Ferreira²
Afonso José do Prado³

¹Mestre em Engenharia Elétrica pela Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP). Faculdade de Engenharia, Campus de São João da Boa Vista-SP.

²Doutor em Engenharia Elétrica pela Escola Politécnica da USP. Professor Assistente da Faculdade de Engenharia da UNESP, Campus de São João da Boa Vista-SP.

³Doutor em Engenharia Elétrica pela Universidade Estadual de Campinas (UNICAMP). Professor Assistente da Faculdade de Engenharia da UNESP, Campus de São João da Boa Vista-SP.

ABSTRACT

This paper presents a method to achieve energy efficiency in a simulation environment for wireless IoT sensors by applying the K-Means Clustering Model, a Channel Model, and Friis' Law. Wireless sensor networks (WSNs) serve various applications, including smart devices, primarily utilizing low-cost and low-power wireless microprocessors. Each sensor node's energy consumption and wireless communication capabilities limit its effectiveness, and the energy consumed during data transmission and reception significantly affects sensor node battery life. The aim of this work is to improve the energy efficiency of sensor nodes within each cluster by mitigating energy consumption in network communication. To determine optimal data transmission strategies and cluster quantities, an algorithm based on Friis' Law and the K-Means method was developed. Energy efficiencies were simulated with 4, 8, 16, 32, 64 and 128 clusters. The simulation results indicate that energy efficiency improves as the number of clusters increases, with the method being most effective in reducing energy consumption when using groups of 64 IoT sensor clusters.

Keywords: Clustering. Machine Learning. Wireless Sensor Network. Energy Efficiency. Internet of Things (IoT).

RESUMO

Este artigo apresenta um método para alcançar eficiência energética em um ambiente de simulação para sensores IoT sem fio, aplicando o modelo de agrupamento K-Means, um modelo de canal e a Lei de Friis. As redes de sensores sem fio (WSNs) atendem a diversas aplicações, incluindo dispositivos inteligentes, utilizando principalmente microprocessadores de baixo custo e baixo consumo de energia. O consumo de energia e a capacidade de comunicação sem fio de cada nó sensor limitam sua efetividade, e a energia consumida durante a transmissão e a recepção de dados afeta significativamente a vida útil da bateria dos nós sensores. O objetivo deste trabalho é melhorar a eficiência energética dos nós sensores em cada agrupamento (cluster), mitigando o consumo de energia na comunicação da rede. Para determinar as estratégias ótimas de transmissão de dados e a quantidade de clusters, foi desenvolvido um algoritmo baseado na Lei de Friis e no método K-Means. Foram simuladas as eficiências energéticas com 4, 8, 16, 32, 64 e 128 clusters. Os resultados da simulação indicam que a eficiência energética melhora com o aumento do número de clusters, sendo o método mais eficaz na redução do consumo de energia quando utilizados grupos de 64 clusters de sensores IoT.

Palavras-chave: Agrupamento. Aprendizado de Máquina. Rede de Sensores Sem Fio. Eficiência Energética. Internet das Coisas (IoT).

1 INTRODUÇÃO

O rápido crescimento das técnicas de comunicação sem fio tem sido observado em decorrência dos avanços tecnológicos nos campos da eletrônica e das telecomunicações. Microssensores sem fio, de baixo custo e baixo consumo de energia, são projetados e amplamente utilizados em ambientes sem fio e móveis. Uma rede de sensores sem fio (Wireless Sensor Network – WSN) é composta por um grande número de nós sensores, cada um dotado de capacidade de sensoriamento, processamento e comunicação sem fio. Todos os sensores desempenham o papel de detectores de eventos e roteadores de dados, sendo implantados em uma área de sensoriamento para monitorar alvos específicos e coletar dados. Os nós enviam então os dados ao coletor por meio da técnica de transmissão sem fio. As redes de sensores sem fio têm se difundido em diversas aplicações, incluindo sistemas de saúde, vigilância em campos de batalha e monitoramento ambiental, entre outras (GULATI et al., 2021). Observa-se um aumento exponencial no número de dispositivos inteligentes, que no futuro poderá superar a própria população mundial. Há, no entanto, limitações relacionadas ao seu uso, como o consumo de energia na coleta, no processamento, na transmissão e na recepção de pacotes. Assim, o consumo de energia constitui a principal restrição em WSNs (MAKWANA; KODINARIYA; MAKWANA, 2013).

O controle e a restrição dos recursos energéticos da Internet das Coisas (IoT) é um dos temas mais investigados nessa área, assim como as limitações, o alto custo de transmissão e a capacidade de processamento limitada (BHUSHAN; ANTOSHCHUK, 2018) de dispositivos como os sensores. Um nó sensor consome sua energia principalmente na transmissão e recepção de pacotes ao se comunicar com outros sensores da WSN (BHUSHAN; ANTOSHCHUK, 2018).


Considerando o referencial acadêmico voltado ao tema da eficiência energética de sensores sem fio, foi desenvolvida pesquisa baseada em um algoritmo otimizado que pudesse resultar em eficiência energética e explorar abordagens diferenciadas (TAMANDANI; BOKHARI; KORD, 2017).

Neste estudo, empregou-se o algoritmo não supervisionado de agrupamento K-Means (MAKWANA; KODINARIYA; MAKWANA, 2013) para determinar o número ótimo de clusters de nós sensores, com o objetivo de aumentar a eficiência energética nas comunicações entre os sensores e seus respectivos Cluster Heads (CHs, ou

cabeças de cluster). Essa abordagem considera o número de nós, a posição do sink (coletor) e outras características da rede de sensores sem fio (WSN). Diferentemente de metodologias anteriores, a estratégia aqui proposta integra a Lei de Friis (FRIIS, 1946) ao agrupamento K-Means. Cada CH agrega os dados dos nós sensores de seu cluster e transmite as informações compiladas à estação-base. Calcula-se o alcance máximo de sinal de cada Cluster Head determinando os requisitos mínimos de potência e validando a recepção para cada nó dentro do cluster, estabelecendo assim o raio máximo efetivo do cluster. Para avaliar a eficiência energética, foram realizadas simulações com diferentes quantidades de clusters — 3, 4, 8, 16, 32, 64 e 128 — comparando o consumo de energia por cluster e para toda a WSN. Os resultados demonstram que a aplicação do algoritmo K-Means, em conjunto com a Lei de Friis, reduz efetivamente o consumo de energia da bateria de cada sensor, aumentando assim a eficiência energética de WSNs baseadas em IoT.

Com base em pesquisas anteriores que estabeleceram o K-Means (NA; LIU; GU, 2010) como uma ferramenta eficaz para a otimização do consumo de energia em WSNs, este estudo analisa de forma abrangente a eficiência energética em uma rede IoT sem fio simulada. Ao aplicar o método K-Means em conjunto com a Lei de Friis, oferece-se um arcabouço robusto para melhorar a eficiência da comunicação e estender a vida útil operacional das WSNs. O restante deste artigo está organizado da seguinte forma: a Seção 2 apresenta o método K-Means proposto; a Seção 3 apresenta os métodos experimentais e de simulação para minimizar o custo energético da transmissão e recepção de sinais com base na Lei de Friis; a Seção 4 apresenta e discute os resultados das simulações; e a Seção 5 traz as considerações finais do trabalho.

Figura 1 – Arquitetura do modelo de sistema de sensores IoT proposto.



Fonte: Adaptado de Brigato, Ferreira e Prado (2025).

2 MÉTODO K-MEANS

O agrupamento K-Means é um dos métodos de aprendizado de máquina não supervisionado mais simples e populares (NA; LIU; GU, 2010). A tarefa de agrupamento (clustering) consiste no processo em que, dados pontos de dados não rotulados, o objetivo é agrupá-los de forma que pontos pertencentes ao mesmo grupo (ou cluster) sejam mais similares entre si do que pontos pertencentes a outros grupos, conforme exemplificado na Figura 2.

O agrupamento é uma forma de classificar dados brutos de maneira razoável e buscar padrões ocultos que possam existir nos conjuntos de dados. Trata-se de um processo de agrupar objetos de dados em clusters separados, de modo que os dados dentro de um mesmo cluster sejam similares, enquanto dados pertencentes a clusters diferentes sejam distintos. O K-Means é um método numérico não supervisionado, não determinístico e iterativo. É simples e muito rápido; por isso, em muitas aplicações práticas, o método tem se mostrado uma forma bastante eficaz de produzir bons resultados de agrupamento. Em 1967, MacQueen propôs pela primeira vez o método K-Means (NA; LIU; GU, 2010), um algoritmo de agrupamento por particionamento. Esse método consiste em classificar os objetos de dados fornecidos em k clusters diferentes por meio de iterações, convergindo para um mínimo local. O algoritmo é composto por duas fases distintas: na primeira, k centros são selecionados aleatoriamente, sendo o valor de k previamente fixado; na segunda fase, cada objeto de dado é associado ao centro mais próximo. A distância euclidiana é geralmente utilizada para determinar a distância entre cada objeto de dado e os centros dos clusters. Quando todos os objetos de dados são incluídos em algum cluster, a primeira etapa é concluída e um agrupamento inicial é obtido. O recálculo da média dos clusters formados continua repetidamente até que a função de critério atinja o mínimo.

Considerando que o objeto-alvo é x e que x_i denota a média do cluster C_i , a função de critério é definida em (1):


$$E = \sum_{i=1}^k \sum_{x \in C_i} \|x - x_i\|^2 \quad (1)$$

onde E é a soma dos erros quadráticos de todos os objetos da base de dados. A distância utilizada na função de critério é a distância euclidiana, empregada para determinar a menor distância entre cada objeto dado e o centro do cluster. A distância euclidiana $d(x_i, y_i)$ entre um vetor $x = (x_1, x_2, \dots, x_n)$ e outro vetor $y = (y_1, y_2, \dots, y_n)$ pode ser obtida conforme (2):

$$d(x_i, y_i) = [\sum_{i=1}^n (x_i - y_i)^2]^{(1/2)} \quad (2)$$

em que x_i e y_i são as coordenadas dos dois pontos na i -ésima dimensão, e n é o número de dimensões.

Figura 2 – Exemplo de agrupamento com 3 clusters.




Fonte: Adaptado de Brigato, Ferreira e Prado (2025).

3 MÉTODOS EXPERIMENTAIS E DE SIMULAÇÃO

Foi projetado um ambiente experimental para simular uma experimentação próxima da realidade, com uma rede sem fio de 128 sensores IoT integrados com antenas. Cada nó transmite e recebe sinais sem fio de e para todos os demais nós. Aplicou-se a técnica de agrupamento K-Means para identificar o melhor nó central uniforme de cada cluster, denominado cluster head (CH). Esse cluster head recebe a comunicação de todos os demais sensores e transmite os dados à estação-base (base station) ou gateway, conectando-se à Internet. A Figura 3 ilustra um exemplo de agrupamento na rede de sensores sem fio, foco deste trabalho.

Figura 3 – Agrupamento (*clustering*) na rede de sensores sem fio.



Fonte: Adaptado de Brigato, Ferreira e Prado (2025).

Foram identificados os nós centrais de cada cluster, os quais recebem prioritariamente os sinais sem fio de todos os demais nós dentro de seu alcance. Diferentemente de outros trabalhos relacionados, a abordagem aqui adotada combina de forma inédita a Lei de Friis com o método K-Means para calcular as potências de transmissão e recepção, com o objetivo de reduzir o consumo de energia em função do número de clusters. O nó central (cluster head) reúne os pacotes dos demais nós de seu cluster e os transmite à estação-base. Para tanto, considera-se o alcance máximo de sinal de cada nó central, calcula-se a potência mínima necessária e valida-se a recepção por cada nó dentro do cluster, respeitando o raio máximo do cluster. Este trabalho demonstra como o K-Means pode simular e alcançar, de forma efetiva, economia de energia da bateria de cada sensor. O trabalho aplica o Modelo de Canal, o método K-Means e a Lei de Friis, descritos a seguir.

3.1 Modelo de Canal

O trabalho de simulação modelou o canal utilizando a relação de Friis (FRIIS, 1946), aplicável a sistemas com linha de visada direta (Direct Line of Sight – DLS) entre transmissor e receptor, como sistemas sem fio que operam nas faixas de ondas milimétricas ou óptica.

3.2 Método de Agrupamento K-Means

Aplicou-se o método de agrupamento K-Means para identificar os clusters de sensores. Os sensores foram representados como pontos em um plano cartesiano. Utilizando a linguagem de programação Python (VAN ROSSUM, 1995), a simulação foi desenvolvida e executada em uma aplicação web de código aberto (Jupyter Notebook) para modelar a rede de sensores sem fio IoT. Todas as simulações foram executadas em um notebook com processador Intel Core i7-7500, 8 GB de RAM e sistema operacional Windows 10 Home 64 bits. As posições dos sensores, representadas como pontos em um plano cartesiano, foram salvas em um arquivo de dados. Adicionalmente, foi gerado um intervalo de 128 pontos para as coordenadas x e y, armazenados em um vetor.

3.3 Lei de Friis

A Lei de Friis é descrita em (3):

$$Pr / Pt = Gt \cdot Gr \cdot (\lambda / 4\pi R)^2 \quad (3)$$

em que Gt e Gr são os ganhos das antenas transmissora e receptora, respectivamente, λ (lambda) é o comprimento de onda, e R é a distância entre as antenas.

3.4 Parâmetros de Simulação

As variáveis, fórmulas, constantes físicas e grandezas utilizadas estão definidas na Tabela 1.

Tabela 1 – Parâmetros da simulação

Parâmetro	Valor
Modelo do transceptor	nRF24L01
Canais de comunicação	126
Tamanho máximo do pacote	32 bytes (enviados/recebidos)
Níveis de potência do transmissor	0 dBm; -6 dBm; -12 dBm; -18 dBm
Velocidade de comunicação	1 Mbps; 2 Mbps
Alcance	100 m
Consumo de corrente na transmissão	11,3 mA (0 dBm); 7 mA (-18 dBm)
Sensibilidade do receptor	-82 dBm (2 Mbps); -85 dBm (1 Mbps)
Consumo de corrente na recepção	12,3 mA (2 Mbps); 11,8 mA (1 Mbps)
Frequência do sinal transmitido	FREQ = $2,4 \cdot 10^9$ Hz

Parâmetro	Valor
Potência da antena receptora	Pr = -80 dBm
Potência da antena transmissora	Pt_transceiver = 0,001 W
Ganho da antena transmissora (Gt)	1 dBm
Ganho da antena receptora (Gr)	1 dBi
Posições dos sensores	(x, y)
Cálculo do raio máximo (Lei de Friis)	Derivado da equação de Friis
Raio mínimo	Derivado da equação de Friis
Comprimento de onda	λ
Número total de sensores (totSensors)	128
Intervalo máximo de pontos (limit)	400

Fonte: Adaptado de Brigato, Ferreira e Prado (2025).

O cálculo da distância euclidiana (R) é definido em (4). A distância entre sensores (como pontos) é medida em metros.

$$R = \sqrt{(\Delta x)^2 + (\Delta y)^2} \quad (4)$$

Raio entre x e y; cálculo do raio máximo a partir da Lei de Friis:

$$R_{Max}(Pt, Pr, \lambda) \quad (5)$$

$$R_{max} = \sqrt{(Pt / Pr) \cdot \lambda \cdot 4\pi} \quad (6)$$


3.5 Etapas do Algoritmo

O fluxograma da Figura 4 ilustra as etapas executadas pelo método K-Means para gerar as posições (x, y) dos sensores e os centroides de cada cluster:

- O usuário escolhe o número de clusters k;
- Uma base de dados D gera os centroides iniciais;
- Os pontos são gerados aleatoriamente;
- Calcula-se R (distância euclidiana);
- Calculam-se Pt (potência de transmissão) e Pr (potência de recepção), a potência mínima e o raio máximo;
- Calculam-se as distâncias entre os centroides dos clusters e todos os sensores (x, y);
- As posições dos sensores são associadas aos clusters mais próximos;
- Calcula-se a média dos clusters;
- A posição do centro é movida para a média dos pontos do cluster de dados;

- Validação: verifica-se se (x, y) do novo centroide está dentro do alcance do seu RMax (raio máximo do cluster). Caso não esteja, o ponto é realocado para outro cluster e o processo é repetido. Caso esteja, verifica-se se os centroides pararam de se mover; caso não, o processo é repetido; caso sim, o processo é encerrado;
- Os passos são repetidos até que os centroides parem de se mover.

Figura 4 – Fluxograma do método K-Means.



Fonte: Adaptado de Brigato, Ferreira e Prado (2025).


Os 128 pontos de entrada X e Y (sensores), bem como os centroides iniciais dos k clusters, foram gerados de forma aleatória e uniforme, influenciando diretamente os resultados do agrupamento. Na fase preliminar desta pesquisa, determinou-se empiricamente que 400 repetições do laço do programa forneceram o melhor desempenho, após testes com 500, 800 e 1000 repetições.

A potência de cada sensor foi calculada utilizando a Lei de Friis (FRIIS, 1946). O principal objetivo deste trabalho é simular a técnica K-Means visando estender a vida útil da bateria, mantendo o enlace de transmissão de sinais entre os nós e assegurando que o nó sink receba o sinal e o transmita a um gateway de Internet. O agrupamento de redes de sensores sem fio (WSN) é uma das técnicas que podem estender a vida útil de toda a rede, agregando dados no cluster head (CHANG; JU, 2012; KAPOOR; SINGH; LAXMI, 2018).

4 RESULTADOS DA SIMULAÇÃO

Foram realizadas simulações com 4, 8, 16, 32, 64 e 128 clusters para comparar a eficiência energética de 128 sensores IoT. Embora ter mais clusters do que sensores possa parecer contraintuitivo, essa abordagem permitiu observar tendências no consumo de energia à medida que o número de clusters aumentava para uma quantidade fixa de sensores. Nessas simulações, comparou-se a potência média de transmissão dos sensores para seus respectivos Cluster Heads (CHs) em diferentes quantidades de clusters. A Figura 5 apresenta o gráfico da potência média de transmissão dos sensores para o CH em função do número de clusters.

Figura 5 – Potência média dos sensores para os Cluster Heads (CHs).




Fonte: Adaptado de Brigato, Ferreira e Prado (2025).

A Figura 5 ilustra a relação entre a potência média de transmissão de cada sensor até seu Cluster Head (CH) e o número de clusters. O aumento do número de clusters de 4 para 8 leva a uma elevação da potência média de transmissão (ATP),

apesar da redução da distância média entre os sensores e seus CHs; essa tendência se torna mais acentuada quando os clusters aumentam de 8 para 16. No entanto, além de 16 clusters, a ATP declina acentuadamente entre 16 e 32 clusters. De 32 a 64 clusters, a queda na ATP continua em ritmo mais gradual e, além de 64 clusters, a ATP reduz-se ainda mais suavemente, atingindo seu ponto mais baixo em 128 clusters. Vale notar que, com 128 sensores neste estudo, o número máximo viável de CHs é 128, resultando em cada sensor atuando como seu próprio CH. Esse cenário de simulação demonstra que a eficiência energética, no que se refere à ATP em relação aos CHs, melhora significativamente além de 16 clusters, alcançando a eficiência ótima em 128 clusters nesse contexto de comunicação intracluster.

A Figura 6 fornece informações relevantes sobre o comportamento da eficiência energética em relação ao aumento do número de clusters. O programa utilizado para gerar esse gráfico está disponível no repositório (GitHub).

Figura 6 – Eficiência energética em função do número de clusters.



Fonte: Adaptado de Brigato, Ferreira e Prado (2025).

A Equação (7) apresenta a fórmula utilizada nesses cálculos:

$$CEE = 1 / (potência_transmitida_sensores + potência_CH_sink) \quad (7)$$
 em que CEE (Clusters Energy Efficiency) denota a eficiência energética dos clusters. Nessa equação, *potência_transmitida_sensores* representa a potência total transmitida pelos sensores, e *potência_CH_sink* refere-se à potência consumida pelo Cluster Head ao se comunicar com o sink.

Observou-se que a maior eficiência energética ocorreu com 64 clusters, provavelmente devido ao equilíbrio entre dois fatores principais. O primeiro é a redução da distância de transmissão até os Cluster Heads (CHs): à medida que os

clusters aumentam, cada sensor se conecta a um CH mais próximo, reduzindo a potência de transmissão necessária entre sensores e CHs. Entretanto, além de 64 clusters, as transmissões dos CHs para o sink passam a demandar mais potência, devido à maior distância total que cada CH precisa percorrer para alcançá-lo. Assim, em 64 clusters as transmissões locais (sensor-para-CH) e centralizadas (CH-para-sink) ficam mais equilibradas, otimizando a energia necessária em ambas as etapas. O segundo fator é a desvantagem do excesso de Cluster Heads: com mais clusters, o número de CHs aumenta, elevando o consumo agregado de energia para a transmissão ao sink. Em redes com alta densidade de clusters (mais de 64, neste estudo), a energia necessária para manter as comunicações com o sink pode superar os ganhos obtidos por transmissões locais mais curtas. Portanto, 64 clusters representam o ponto de equilíbrio (trade-off): aumentar ainda mais o número de clusters elevaria o consumo de energia da rede como um todo, ainda que reduzisse o consumo interno de cada cluster, já que os sensores precisariam de menos potência para enviar sinais ao CH.

Em suma, a Figura 6 mostra que, inicialmente, o aumento do número de clusters melhora a eficiência energética, pois clusters menores exigem menos energia para transmissões locais. O equilíbrio entre os custos de transmissão dos sensores para os CHs e dos CHs para o sink é otimizado com 64 clusters, configuração em que cada cluster contém sensores suficientes para reduzir o número de CHs e, com isso, a frequência de transmissões CH-para-sink, mantendo curtas as distâncias sensor-CH. Além de 64 clusters, até 128, observa-se leve declínio na eficiência, pois o maior número de CHs demanda transmissões de maior alcance ao sink, elevando o consumo de energia, ao mesmo tempo em que clusters menores reduzem o tráfego interno por CH. Esse desequilíbrio pode gerar desperdício de energia em transmissões de baixa carga. As simulações identificam, portanto, 64 clusters como o equilíbrio ótimo entre eficiência energética e desempenho para a WSN analisada; esse número ótimo pode variar conforme características específicas da rede, como densidade de sensores, área de cobertura e capacidades de comunicação. A otimização do consumo de energia é fundamental em diversos setores, incluindo o monitoramento ambiental e a agricultura de precisão, permitindo o projeto de redes mais eficientes e sustentáveis, adaptadas às demandas de cada aplicação.

Khodr et al. (2017) apresentam uma solução energeticamente eficiente para sensores IoT, incorporando tecnologia de wake-up por radiofrequência (RF) e

capacidade de endereçamento. Essa abordagem minimiza o consumo de energia dos sensores ao ativá-los somente quando necessário, aumentando significativamente a longevidade e a eficiência das redes de sensores. A presente pesquisa não avalia sensores com rádio de wake-up, que transmitem em microssegundos (KHODR et al., 2017). Em última análise, a eficiência da rede depende do desempenho energético dos clusters, e o sistema falhará quando o cluster menos eficiente falhar. Nesse sentido, a distância média dos sensores até o coletor é crítica, e a frequência de comunicação também desempenha papel significativo, uma vez que impacta diretamente o consumo de energia.

5 CONSIDERAÇÕES FINAIS

Este estudo utiliza a Lei de Friis, o algoritmo de agrupamento K-Means e o protocolo LEACH para examinar a otimização do consumo de energia em Redes de Sensores Sem Fio (WSNs) voltadas a aplicações de Internet das Coisas (IoT). Simulações com 4 a 128 clusters indicam que o aumento do número de clusters reduz o consumo de energia, alcançando eficiência ótima com 64 clusters nas condições experimentais consideradas. Esse desempenho decorre principalmente das distâncias de comunicação mais curtas entre os sensores e seus respectivos Cluster Heads (CHs), minimizando o gasto médio de energia por cluster. Os resultados sugerem que a configuração da WSN com 64 clusters proporciona um equilíbrio ótimo sob os parâmetros de rede específicos considerados, aprimorando de forma efetiva o desempenho geral da rede. Pesquisas futuras explorarão algoritmos de roteamento mais eficientes e compararão o K-Means com outras técnicas de agrupamento em cenários de redes complexas e dinâmicas, visando aprimorar a eficiência energética em WSNs.

REFERÊNCIAS

- BHUSHAN, S.; ANTOSHCHUK, S. G. A hybrid approach to energy efficient clustering for heterogeneous wireless sensor network. n. 2, p. 15–20, 2018.
- BISHOP, C. M.; NASRABADI, N. M. Pattern Recognition and Machine Learning. New York: Springer, 2006.
- CHANG, J. Y.; JU, P. H. An efficient cluster-based power saving scheme for wireless sensor networks. Eurasip Journal on Wireless Communications and Networking, v. 2012, 2012.

- FRIIS, H. T. A note on a simple transmission formula. *Proceedings of the IRE*, v. 34, n. 5, p. 254–256, 1946.
- GOLDSMITH, A. *Wireless Communications*. Cambridge, UK: Cambridge University Press, 2005.
- GULATI, K. et al. A review paper on wireless sensor network techniques in Internet of Things (IoT). *Materials Today: Proceedings*, Elsevier Ltd, 2021.
- HARRIS, S.; DE AMORIM, R. C. An Extensive Empirical Comparison of k-means Initialization Algorithms. *IEEE Access*, v. 10, p. 58752–58768, 2022.
- HEINZELMAN, W. R.; CHANDRAKASAN, A.; BALAKRISHNAN, H. Energy-Efficient Communication Protocol for Wireless Microsensor Networks. In: *PROC. 33rd Annu. Hawaii Int. Conf. System Sciences*, Maui, HI, USA, 2000. p. 1–10.
- KAPOOR, C.; SINGH, H.; LAXMI, V. A Survey on Energy Efficient Routing for Delay Minimization in IoT Networks. In: *PROC. 2018 Int. Conf. Intell. Circuits Syst. (ICICS)*, 2018. p. 320–323.
- KHODR, H.; KOUZAYHA, N.; ABDALLAH, M.; COSTANTINE, J.; DAWY, Z. Energy efficient IoT sensor with RF wake-up and addressing capability. *IEEE Sensors Letters*, v. 1, n. 6, p. 1–4, dez. 2017.
- MAKWANA, P.; KODINARIYA, T. M.; MAKWANA, P. R. Review on Determining of Cluster in K-means Clustering. *International Journal of Advance Research in Computer Science and Management Studies*, v. 1, n. 6, 2013.
- NA, S.; LIU, X.; GU, Y. Research on k-means clustering algorithm: An improved k-means clustering algorithm. In: *PROC. Int. Symp. Intelligent Information Technology Security Informatics (IITSI)*, IEEE, 2010.
- PRADO, F. O. C. et al. Regression-Based Law of Energy Efficiency in Wireless Sensor Networks. In: *Congresso Brasileiro de Automática (CBA)*, Rio de Janeiro, 2024. p. 1–6.
- PUCCINELLI, D.; HAENGGI, M. Wireless sensor networks: applications and challenges of ubiquitous sensing. *IEEE Circuits and Systems Magazine*, v. 5, n. 3, p. 19–31, 2005.
- RAZZAQ, M.; NINGOMBAM, D. N.; SHIN, S. Energy efficient K-means clustering-based routing protocol for WSN using optimal packet size. In: *PROC. Int. Conf. Information Networking*, IEEE Computer Society, abr. 2018.
- SAMIE, F.; BAUER, L.; HENKEL, J. IoT technologies for embedded computing: A survey. In: *PROC. Int. Conf. Hardware/Software Codesign System Synthesis (CODES+ISSS)*, IEEE, nov. 2016.
- TAMANDANI, Y. K. T.; BOKHARI, M. U.; KORD, M. Z. Computing geometric median to locate the sink node with the aim of extending the lifetime of wireless sensor networks. *Egyptian Informatics Journal*, v. 18, n. 1, p. 21–27, 2017.

- TUBAISHAT, M.; MADRIA, S. Sensor networks: an overview. IEEE Potentials, v. 22, n. 2, p. 20–23, abr. 2003.
- TZOUNIS, A. et al. Internet of Things in agriculture, recent advances and future challenges. Biosystems Engineering, Academic Press, dez. 2017.
- XU, C. et al. An energy-efficient region source routing protocol for lifetime maximization in WSN. IEEE Access, v. 7, p. 135277–135289, 2019.
- XU, Y.; HEIDEMANN, J.; ESTRIN, D. Geography-informed Energy Conservation for Ad Hoc Routing. In: PROC. 7th Annu. Int. Conf. Mobile Computing Networking, 2001.
- ZHENG, J.; JAMALIPOUR, A. Wireless Sensor Networks: A Networking Perspective. Hoboken, NJ: Wiley-IEEE Press, 2009.
- DAANOUNE, I.; ABDENNACEUR, B.; BALLOUK, A. A comprehensive survey on LEACH-based clustering routing protocols in Wireless Sensor Networks. Ad Hoc Networks, 2021.
- VAN ROSSUM, G. Python Tutorial. Amsterdam: Centrum voor Wiskunde en Informatica (CWI), Tech. Rep. CS-R9526, 1995.