

# Redes Aéreas Inteligentes no 6G: Otimização da Cobertura com Drones e Clusterização K-Means

Marcos Hiarley<sup>1</sup>, Robert Corrêa<sup>1</sup>, Jasmine Araújo<sup>2</sup>, José Jailton<sup>1</sup>

<sup>1</sup>Faculdade de Computação – Universidade Federal do Pará – Castanhal – PA – Brasil

<sup>2</sup>Faculdade de Engenharia de Computação e Telecomunicação – Universidade Federal do Pará (UFPA)- Belém – PA – Brasil

hiarley@castanhal.ufpa.br, {robertdsgabriel, jasmine.araujo}@gmail.com, jjj@ufpa.br

**Resumo.** A evolução das redes móveis 6G demanda conectividade confiável, de alta performance e baixa latência, impulsionando soluções inovadoras para desafios de infraestrutura. Este estudo propõe o uso de drones como estações base móveis, com posicionamento inteligente baseado no algoritmo K-Means, que agrupa usuários conforme sua localização. A abordagem visa melhorar a cobertura e eficiência da rede em cenários urbanos dinâmicos. Para validação, foram realizadas simulações no NS-3, utilizando três faixas de frequência (3,5 GHz, 28 GHz e 100 GHz), analisando métricas como SINR, Path Loss e CQI. Os resultados destacam a viabilidade da proposta e o potencial do uso de aprendizado de máquina em redes aéreas inteligentes no contexto do 6G.

**Abstract.** The evolution of 6G mobile networks demands reliable, high-performance, and low-latency connectivity, driving innovative solutions to infrastructure challenges. This study proposes the use of drones as mobile base stations, employing a K-means clustering algorithm to group users based on their location and optimize drone positioning. The approach aims to enhance network coverage and efficiency in dynamic urban scenarios. To validate the proposal, simulations were conducted using the NS-3 simulator across three frequency bands (3.5 GHz, 28 GHz, and 100 GHz), evaluating metrics such as SINR, Path Loss, and CQI. The results demonstrate the feasibility of the method and the potential of machine learning for intelligent aerial networks in the 6G context.

## 1. Introdução

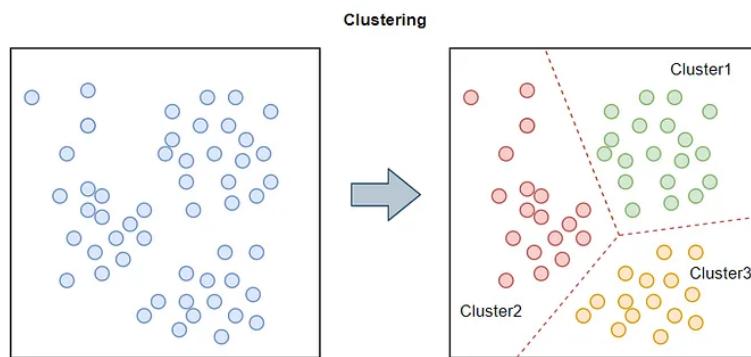
Com a evolução das redes móveis para o 6G, a demanda por conectividade ultrarrápida, confiável e de baixa latência tornou-se um dos principais desafios da nova geração de comunicações. Para lidar com esse crescimento exponencial, novas abordagens de infraestrutura têm sido exploradas, como o uso de microcélulas urbanas para aumentar a densidade de antenas e expandir a cobertura de maneira eficiente. Além disso, a operação em frequências na faixa de *Terahertz* (THz) permite serviços com altíssimas taxas de transmissão e latências extremamente reduzidas, essenciais para aplicações emergentes, como realidade estendida, automação industrial avançada e redes autônomas sensíveis ao contexto. Entre as soluções inovadoras para maximizar a flexibilidade da conectividade no 6G, o uso de drones como estações base móveis tem se

destacado como uma alternativa promissora, possibilitando a criação de infraestruturas temporárias adaptáveis à demanda dos usuários (Kaushik et al, 2024).

Neste contexto, este trabalho propõe uma abordagem baseada em aprendizado de máquina para o posicionamento inteligente de drones como estações base no 6G. Utilizando o algoritmo de clusterização K-Means, é possível distribuir dinamicamente os drones para otimizar a cobertura e o desempenho da rede, com base na localização dos usuários conectados. O K-Means é um algoritmo não supervisionado que identifica agrupamentos de usuários próximos, permitindo definir clusters que orientam o deslocamento das estações móveis. Para esta pesquisa, foram utilizados dados de posicionamento dos usuários (UEs) e estações base móveis (ENBs), possibilitando a formação de grupos estratégicos para cada unidade de antena (Naqvi, 2018). Dessa forma, a rede pode ajustar dinamicamente sua infraestrutura, garantindo conectividade otimizada e um uso mais eficiente do espectro em ambientes 6G altamente dinâmicos (Natarajan e Rebekka, 2023).

## 2. Clusterização K-Means para Redes Aéreas

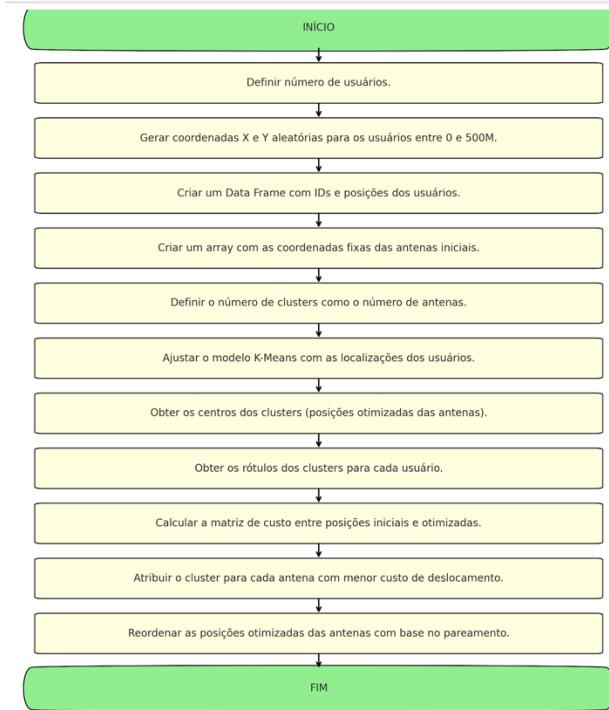
O script K-Means utiliza um sistema de clusterização para identificar grupos de usuários com características semelhantes e otimizar o posicionamento de drones com estações base embarcadas. Dessa forma, a distribuição dos drones é ajustada para maximizar a conectividade entre os usuários, além de viabilizar a implementação de redes temporárias, ideais para eventos de grande porte ou cenários emergenciais. Além da otimização proporcionada pelo K-Means, foi implementada uma modificação que reduz realocações desnecessárias, minimizando custos operacionais em situações específicas (Figura 1).



**Figura 1.** Cluster para grupo de usuários

Para a implementação e testes do algoritmo, foi utilizado o Simulador de Redes NS-3 (Network Simulator 3), amplamente conhecido por sua capacidade de simular diversos cenários com diferentes arquiteturas de redes, como Wi-Fi, redes *mesh* e redes móveis. Nesta pesquisa, foi empregado o módulo NR (New Radio), lançado em 2019 por meio da colaboração entre a *New York University (NYU) Wireless* e a *University of Padova*, permitindo a simulação de redes móveis com transmissão de dados via ondas milimétricas (mmWave).

As principais modificações no código foram realizadas para adaptar a simulação ao modelo do algoritmo K-Means, possibilitando o monitoramento do trajeto das estações base embarcadas em drones (Figura 2).



**Figura 2.** Fluxograma Algoritmo K-Means

O funcionamento do algoritmo proposto inicia-se com a definição do número de usuários que participarão do cenário de simulação. Em seguida, são geradas coordenadas aleatórias para cada usuário em um espaço bidimensional de 500 metros por 500 metros, e essas informações são organizadas em um *Data Frame* contendo os respectivos IDs e localizações. Posteriormente, define-se um conjunto de posições iniciais fixas para as antenas (ou drones com estações base embarcadas), que serão utilizadas como ponto de partida no processo de otimização.

Com os dados de entrada organizados, define-se o número de clusters a ser utilizado no algoritmo K-Means, sendo esse número igual ao total de antenas disponíveis. O algoritmo é então ajustado com base na localização dos usuários, formando agrupamentos a partir da distância euclidiana entre os pontos. A saída do K-Means fornece os centros de cada cluster, que representam as posições otimizadas onde as antenas devem se posicionar para melhor atender aos usuários agrupados, além dos rótulos de cluster atribuídos a cada usuário.

Em seguida, calcula-se uma matriz de custo entre as posições iniciais das antenas e os centros otimizados dos clusters, a fim de minimizar os deslocamentos necessários. Atribui-se então a cada antena o cluster com o menor custo de realocação, realizando um pareamento eficiente entre os pontos. Por fim, as posições das antenas são reorganizadas

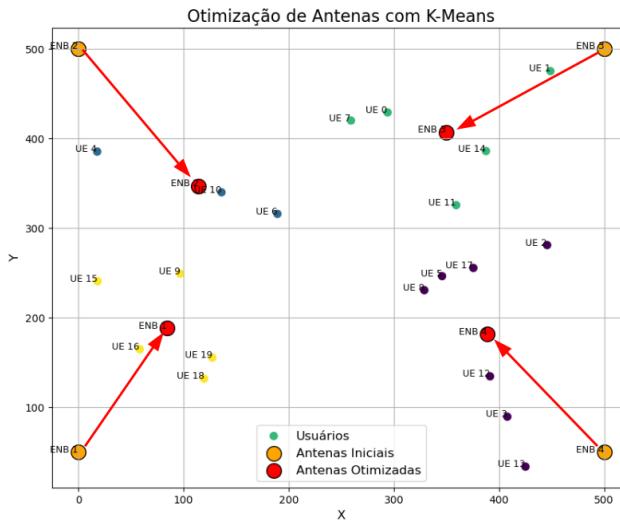
com base nesse pareamento, finalizando o processo de alocação inteligente que visa maximizar a cobertura e a eficiência da rede.

## 2.1 Cenário Simulado

O cenário de simulação proposto foi concebido com o objetivo de validar o algoritmo de posicionamento baseado em clusterização K-means em um ambiente urbano representativo. Foram definidos 20 usuários (UEs), posicionados aleatoriamente em um espaço bidimensional de  $500 \times 500$  metros. Todos os usuários foram considerados estacionários durante o período da simulação, a fim de permitir uma análise controlada do comportamento do algoritmo, sem interferência de mobilidade ou dinamicidade topológica. Essa abordagem visa facilitar a avaliação da eficiência da alocação dos drones como estações base móveis em uma situação inicial e simplificada.

Os drones operam como unidades de cobertura aérea, atuando como estações base móveis com altura de voo fixa e potência de transmissão de 40 dBm. Embora o alcance exato varie conforme a frequência adotada, a área total da macrocélula simulada é completamente coberta com a quantidade de antenas utilizada (quatro unidades). A comunicação entre os usuários e um servidor remoto foi modelada utilizando aplicações do tipo UDP, simulando o envio contínuo de dados durante 100 segundos de simulação. A escolha desse modelo visa representar um cenário de tráfego leve a moderado, típico de aplicações como vídeo, voz sobre IP e envio de dados em ambientes urbanos.

A simulação foi conduzida utilizando o módulo NR (*New Radio*) do simulador NS-3, com o modelo de canal 3GPP UMa (*Urban Macrocell*). Esse modelo contempla características típicas de ambientes urbanos, como reflexões, variações de altura e efeitos de propagação, incluindo sombreamento e dispersão. No entanto, não foram inseridos obstáculos físicos modelados geometricamente (como edifícios ou construções), sendo as condições ambientais consideradas de forma estatística, conforme previsto nos parâmetros do modelo adotado. A configuração do ambiente reflete, portanto, uma situação *outdoor* urbana, adequada para o estudo do comportamento de redes aéreas no contexto da sexta geração de redes móveis.



**Figura 3.** Cenário de Simulação

Embora as faixas de frequência do 6G ainda estejam em processo de definição por entidades de padronização como o 3GPP e a ITU, estudos preliminares indicam uma forte tendência de exploração em múltiplas bandas. A frequência de 3,5 GHz é atualmente utilizada em redes 5G e serve como referência de desempenho para frequências sub-6 GHz, sendo ideal para propagação em ambientes urbanos com boa penetração. A faixa de 28 GHz, amplamente pesquisada para o 5G mmWave, representa uma transição entre frequências médias e altas, sendo promissora para aplicações de alta capacidade em áreas densas. Já a faixa de 100 GHz se insere no início do espectro Terahertz (THz), que é um dos principais candidatos para o 6G devido ao seu potencial de oferecer altíssimas taxas de transmissão, apesar dos desafios relacionados à atenuação e alcance. A escolha dessas três faixas permite analisar o comportamento da rede em diferentes regimes de propagação e oferece uma visão comparativa sobre os desafios e oportunidades do 6G (Tabela I).

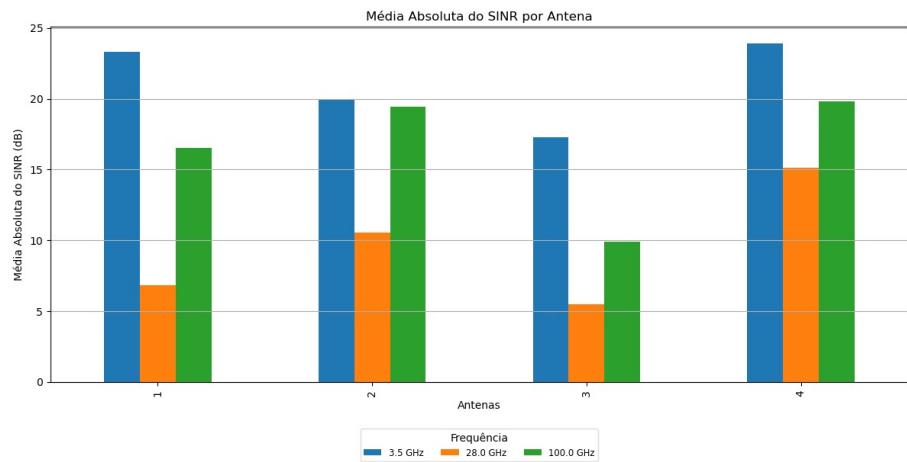
Tempo de Simulação	100s
Frequência de Atuação	3.5GHz, 28GHz e 100GHz
Largura de Banda	200MHz
Altura(Estações bases)	25m
TxPower (Potencia das antenas)	40dBm
Bandwith Scenario (cenário de banda-larga)	UMa ( <i>Urban Macrocell</i> )
Número de Usuários	20
Números de Drones	4

**Tabela I.** Parâmetros de Simulação

### 3. Resultados

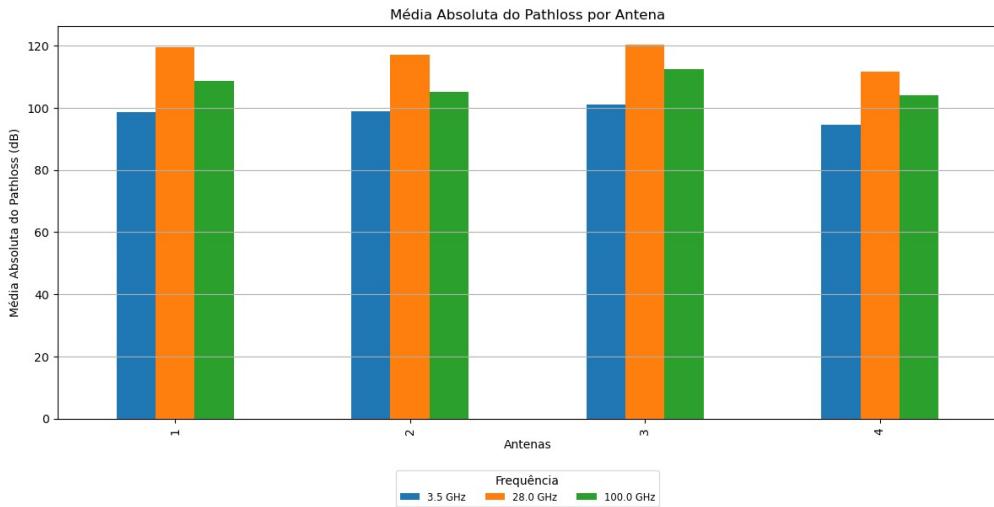
Para a análise dos cenários, os dados foram extraídos dos arquivos de saída das simulações: DLPathlossTrace, que armazena os valores de *Path Loss* (Perda de Percurso), indicando a atenuação do sinal durante a transmissão; DLCtrlSinr, que contém a taxa de SINR (*Signal-to-Interference-plus-Noise Ratio*), medindo a relação entre o sinal recebido e as interferências presentes no canal; e RxPacketTrace, que registra informações sobre os pacotes recebidos, permitindo a análise da qualidade do sinal e eficiência da transmissão.

A Figura 4 revela que a frequência de 3,5 GHz apresentou a melhor taxa de SINR, o que se deve à sua maior capacidade de penetração em obstáculos, garantindo uma conexão mais estável em diferentes cenários. Em contrapartida, a frequência de 28 GHz registrou a menor taxa de SINR na maioria dos testes, indicando que sua implementação é mais adequada para cenários indoor, onde há menos interferência de barreiras físicas e a propagação do sinal é mais controlada. Já a frequência de 100 GHz, apesar de apresentar valores intermediários, demonstra maior sensibilidade às condições do ambiente, reforçando a necessidade de estratégias de mitigação de perdas em aplicações de redes 6G.



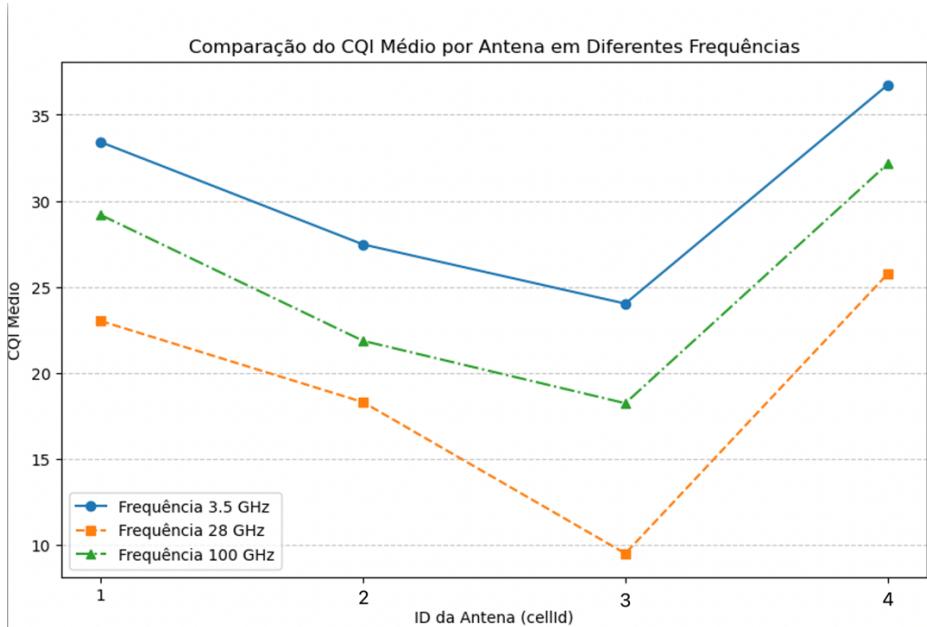
**Figura 4.** Média Absoluta do SINR

A análise do *Path Loss* (Perda de Percurso) na Figura 5 revela que a frequência de 28 GHz apresentou os maiores valores de atenuação de sinal, indicando que essa frequência é menos eficiente para comunicações de longa distância ou ambientes com muitos obstáculos. Isso ocorre porque frequências mais altas possuem menor capacidade de penetração em estruturas físicas, resultando em maior perda de sinal. Já a frequência de 3,5 GHz demonstrou a menor taxa de *Path Loss*, reforçando sua maior robustez para cenários urbanos com múltiplas barreiras. A frequência de 100 GHz, por sua vez, apresentou perdas intermediárias, mas ainda elevadas, evidenciando a necessidade de estratégias de mitigação, como técnicas de *beamforming* e redes densificadas, para viabilizar sua aplicação eficiente em redes 6G.



**Figura 5.** Média Absoluta do *Path Loss*

A análise do *Channel Quality Indicator* (CQI) na Figura 6 demonstra que as frequências mais baixas apresentaram índices mais elevados de qualidade de canal, indicando maior estabilidade na comunicação. A frequência de 3,5 GHz obteve os melhores valores médios de CQI, reforçando sua adequação para cenários outdoor, onde a propagação do sinal precisa ser mais resistente a obstáculos e variações ambientais. Já a frequência de 28 GHz apresentou os menores valores de CQI, o que sugere sua maior vulnerabilidade a interferências e reforça sua aplicabilidade em ambientes indoor ou redes densificadas. A frequência de 100 GHz, por sua vez, mostrou um desempenho intermediário, exigindo técnicas avançadas, como *beamforming* e MIMO massivo, para garantir uma conectividade estável e de alta qualidade em redes 6G.



**Figura 6.** Média do Channel Quality Indicator (CQI)

#### 4. Considerações Finais

Com base nos dados obtidos nas simulações, conclui-se que, para o cenário de macrocélulas urbanas simuladas, a frequência de 3,5 GHz apresentou o melhor desempenho global, destacando-se pelos valores mais altos de SINR e CQI, além do menor nível de Path Loss, o que garante uma conectividade mais estável, com menor suscetibilidade a interferências e perdas de sinal. Essa faixa de frequência demonstrou ser a mais adequada para comunicações em ambientes urbanos abertos, especialmente quando associada ao uso de drones como estações base móveis.

A frequência de 100 GHz apresentou desempenho intermediário, sendo impactada por perdas significativas de propagação. No entanto, demonstrou potencial promissor ao atingir níveis razoáveis de qualidade de sinal, desde que associada a técnicas de mitigação como beamforming, redes densificadas e algoritmos adaptativos de posicionamento, que poderão compensar sua maior sensibilidade à atenuação. Por fim, a frequência de 28 GHz apresentou os piores resultados, com elevado Path Loss e baixos índices de CQI, sugerindo que seu uso é mais apropriado em cenários indoor ou em arquiteturas densas baseadas em microcélulas e picocélulas, onde a distância entre os nós e os obstáculos é reduzida.

Como trabalhos futuros, pretende-se incorporar informações sobre a demanda de tráfego dos usuários ao processo de clusterização, além de considerar cenários com mobilidade e obstáculos geométricos, visando aumentar o realismo das simulações. Também está prevista a aplicação de outros algoritmos de agrupamento e aprendizado de máquina, além da avaliação do impacto de diferentes estratégias de alocação de recursos em redes aéreas 6G.

#### 5. Referências Bibliográficas

S. A. R. Naqvi, S. A. Hassan, H. Pervaiz and Q. Ni, "Drone-Aided Communication as a Key Enabler for 5G and Resilient Public Safety Networks," in IEEE Communications Magazine, vol. 56, no. 1, pp. 36-42, Jan. 2018, doi: 10.1109/MCOM.2017.1700451.

A. Kaushik et al., "Toward Integrated Sensing and Communications for 6G: Key Enabling Technologies, Standardization, and Challenges," in IEEE Communications Standards Magazine, vol. 8, no. 2, pp. 52-59, June 2024, doi: 10.1109/MCOMSTD.0007.2300043.

J. Natarajan e B. Rebekka, "An energy efficient dynamic small cell on/off switching with enhanced k-means clustering algorithm for 5G HetNets," *International Journal of Communication Networks and Distributed Systems*, vol. 29, nº 2, pp. 209-237, 2023