

**Universidade de Brasília
Faculdade UnB Gama - FGA
Engenharia Eletrônica**

**Localização em ambiente fechado por meio
do arranjo de antenas e com uso de
traçador de raios**

Gabriel Vieira da Silva Leite

TRABALHO DE CONCLUSÃO DE CURSO
ENGENHARIA ELETRÔNICA

Brasília
2024

Universidade de Brasília
Faculdade UnB Gama - FGA
Engenharia Eletrônica

**Localização em ambiente fechado por meio
do arranjo de antenas e com uso de
traçador de raios**

Gabriel Vieira da Silva Leite

Trabalho de Conclusão de Curso submetido
como requisito parcial para obtenção do grau
de Engenheiro Eletrônico.

Orientador: Prof. Dr. Daniel Costa Araújo

Brasília
2024

FICHA CATALOGRÁFICA

Vieira da Silva Leite, Gabriel.

Localização em ambiente fechado por meio do arranjo de antenas e com uso de traçador de raios / Gabriel Vieira da Silva Leite; orientador Daniel Costa Araújo. -- Brasília, 2024.

51 p.

Trabalho de Conclusão de Curso (Engenharia Eletrônica) -- Universidade de Brasília, 2024.

1. Direção de chegada (DOA). 2. Processamento de Sinais. 3. *Beamforming*. 4. K-vizinhos mais próximos (KNN). 5. Localização em ambientes fechados. I. Costa Araújo, Daniel, orient. II. Título.

**Universidade de Brasília
Faculdade UnB Gama - FGA
Engenharia Eletrônica**

**Localização em ambiente fechado por meio do arranjo de
antenas e com uso de traçador de raios**

Gabriel Vieira da Silva Leite

Trabalho de Conclusão de Curso submetido
como requisito parcial para obtenção do grau
de Engenheiro Eletrônico.

Brasília, 19 de Setembro de 2024:

Prof. Dr. Daniel Costa Araújo
Orientador

Prof. Dr. Cristiano Jacques Miosso
Examinador interno

Prof. Dr. Daniel Mauricio Muñoz Arboleda
Examinador interno

Resumo

Este projeto aborda o desafio de localizar com precisão a posição de um usuário em ambientes fechados, onde obstáculos e múltiplos trajetos de propagação de sinais complicam a determinação da direção de chegada (DOA) de sinais eletromagnéticos. Com a implementação das redes 5G em ondas milimétricas, que exigem uma infraestrutura densa devido ao alcance limitado dos sinais, surge a oportunidade de aplicar técnicas avançadas para melhorar a estimativa de posição nesses cenários complexos.

Para resolver esse problema, a solução proposta utiliza *beamforming* para processar os sinais recebidos por arranjos de antenas e calcular as DOAs com base no canal de transmissão. Essas informações são então aplicadas a um algoritmo de aprendizado de máquina, o K-vizinhos mais próximos (KNN), que estima a posição do usuário com base em uma base de dados previamente criada, contendo as posições e suas respectivas DOAs em diferentes níveis de potência (0 dBm e 15 dBm).

A simulação foi implementada em um ambiente composto por duas salas conectadas por dois corredores, cada um equipado com arranjos de antenas retangulares uniformes de 64 elementos. Esse cenário foi projetado para garantir ao menos uma linha de visada (LOS), facilitando a validação das metodologias. A eficácia da solução foi avaliada utilizando métricas como o erro quadrático médio (RMSE), erro médio absoluto (MAE) e o coeficiente de determinação (R^2). Os resultados indicaram um RMSE de 2,4 metros para 0 dBm e 1,9 metros para 15 dBm, além de um MAE de 2,97 metros no 90º percentil para 0 dBm e 2,3 metros no 90º percentil para 15 dBm. O coeficiente de determinação (R^2) foi de aproximadamente 0,9 para as coordenadas X e Y, e de 0,36 para a coordenada Z.

Esses resultados demonstram que, ao aproveitar a infraestrutura das redes 5G e técnicas avançadas de processamento de sinais, como o *beamforming*, é possível desenvolver uma solução de baixo custo para a localização em ambientes fechados.

Palavras-chave: Direção de chegada (DOA). Processamento de Sinais. *Beamforming*. K-vizinhos mais próximos (KNN). Localização em ambientes fechados.

Abstract

This project addresses the challenge of accurately locating a user's position in indoor environments, where obstacles and multiple signal propagation paths complicate the determination of the direction of arrival (DOA) of electromagnetic signals. With the implementation of 5G networks operating in millimeter waves, which require dense infrastructure due to the limited signal range, the opportunity arises to apply advanced techniques to improve position estimation in these complex scenarios.

To tackle this problem, the proposed solution utilizes *beamforming* to process signals received by antenna arrays and calculate DOAs based on the transmission channel. These DOA data are then applied to a machine learning algorithm, K-nearest neighbors (KNN), which estimates the user's position based on a previously created database containing positions and their respective DOAs at different power levels (0 dBm and 15 dBm).

The simulation was implemented in an environment consisting of two rooms connected by two corridors, each equipped with uniform rectangular antenna arrays of 64 elements. This scenario was designed to ensure at least one line of sight (LOS), facilitating the validation of the methodologies. The effectiveness of the solution was evaluated using metrics such as the root mean square error (RMSE), mean absolute error (MAE), and the coefficient of determination (R^2). The results indicated an RMSE of 2.4 meters for 0 dBm and 1.9 meters for 15 dBm, as well as an MAE of 2.97 meters at the 90th percentile for 0 dBm and 2.3 meters at the 90th percentile for 15 dBm. The coefficient of determination (R^2) was approximately 0.9 for the X and Y coordinates and 0.36 for the Z coordinate.

These results demonstrate that by leveraging the 5G network infrastructure and advanced signal processing techniques such as *beamforming*, it is possible to develop a low-cost solution for indoor localization.

Keywords: Direction of arrival (DOA). Signal processing. *Beamforming*. K-nearest neighbors (KNN). Indoor localization.

Lista de figuras

Figura 4.1	Vista 3D do ambiente fechado	25
Figura 4.2	Vista Superior do Ambiente com Pontos de Acessos	26
Figura 5.1	Simulação dos feixes	29
Figura 5.2	Gráfico 3D da Potência do sinal recebido pelo azimute e elevação	30
Figura 5.3	CDF dos erros absolutos do azimute para APs 1, 2, 3 e 4 para 0 dBm . .	30
Figura 5.4	CDF dos erros absolutos da elevação para APs 1, 2, 3 e 4 para 0 dBm . .	31
Figura 5.5	CDF dos erros absolutos do azimute para APs 1, 2, 3 e 4 para 15 dBm . .	32
Figura 5.6	CDF dos erros absolutos da elevação para APs 1, 2, 3 e 4 para 15 dBm .	32
Figura 5.7	Diagrama de fases para estimação da localização	34
Figura 5.8	Gráfico do RMSE para K-vizinhos	35
Figura 5.9	Gráfico do CDF para RMSE	36
Figura 5.10	Gráfico do CDF para MAE	37
Figura 5.11	Gráfico do CDF para R^2	38
Figura 5.12	Gráfico de R^2 para K-vizinhos	39

Lista de tabelas

Tabela 4.1	Localização dos APs na simulação	26
Tabela 4.2	Características do Arranjo de Antenas	27
Tabela 5.1	Tabela do erro absoluto médio para cada AP em 0 dBm e 15 dBm	33
Tabela 5.2	Tabela de valores MAE por percentil	36
Tabela 5.3	Tabela de valores R^2 por coordenada	38

Lista de abreviaturas e siglas

DOA	Direção de chegada
IoT	Internet das coisas
GNSS	Sistema global de navegação por satélite
UWB	Banda ultra larga
RSSI	Indicador de força do sinal recebido
CSI	Informação do estado do canal
RTT	Tempo de ida e volta
AOA	Ângulo de chegada
TDOA	Diferença de tempo de chegada
TOA	Tempo de chegada
SVM	Máquina de vetores de suporte
KNN	K-vizinhos mais próximos
PF	Filtro de partícula
KF	Filtro de Kalman
5G	Quinta geração de internet móvel
6G	Sexta geração de internet móvel
AP	Ponto de acesso
Hz	Hertz
FFT	Transformada rápida de fourier
QAM	Modulação de amplitude em quadratura
OFDM	Multiplexação de divisão de frequência ortogonal
MIMO	Múltiplas entradas-múltiplas saídas
URA	Antena uniforme de arranjo retangular

LOS	Propagação em linha de visada
MUSIC	Classificação de múltiplos sinais
ESPRIT	Estimativa de parâmetros de sinais por técnicas de invariância rotacional
SVD	Decomposição em Valores Singulares
dB	Decibéis
dBm	Decibéis miliwatt
3D	Tridimensional
MAE	Erro absoluto médio
RMSE	Raiz do erro médio quadrático
R^2	Coefficiente de determinação
CDF	Função de distribuição cumulativa
SNR	Relação sinal-ruído

Lista de símbolos

λ	Comprimento de Onda
c	Velocidade da luz no vácuo
f	Frequência
d	Distância
U_p	Variável de posição do usuário
A_{pP}	Variável de posição do ponto de acesso
A_z	Variável do azimute
El	Variável da elevação
r	Variável do raio
$azdeg$	Variável do azimute em graus
$eldeg$	Variável da elevação em graus
d_{ij}	Diferença de distância entre os pontos de recepção das antenas i e j
$n_i(t)$	Ruído aditivo na antena i no instante t
N	Número de antenas
$r_i(t)$	Sinal recebido na antena i no instante t
$s(t)$	Sinal transmitido no instante t
t	Tempo
τ_i	Atraso de tempo do sinal na antena i
$\Delta\tau_{ij}$	Diferença de tempo de chegada entre as antenas i e j
(x, y, z)	Coordenadas do ponto de recepção do sinal
(x_i, y_i, z_i)	Coordenadas do ponto de localização da antena i
$\mathbf{A}(\theta)$	Matriz de respostas das antenas (ou matriz de direção) de dimensão $M \times K$
$\mathbf{a}(\theta)$	Vetor de resposta da antena para o ângulo θ

\mathbf{E}_n	Matriz formada pelos vetores próprios do subespaço do ruído
\mathbf{I}	Matriz identidade
$\mathbf{n}(t)$	Vetor de ruído aditivo de dimensão $M \times 1$
$\mathbf{P}_{\text{MUSIC}}(\theta)$	Função espectral do algoritmo MUSIC
\mathbf{R}_s	Matriz de covariância dos sinais transmitidos
\mathbf{R}_y	Matriz de covariância do sinal recebido
$\mathbf{s}(t)$	Vetor de sinais transmitidos pelas K fontes de dimensão $K \times 1$
$\mathbf{S}_1, \mathbf{S}_2$	Submatrizes correspondentes aos subarranjos deslocados no algoritmo ESPRIT
$\mathbf{y}(t)$	Vetor de sinais recebidos de dimensão $M \times 1$
Φ	Matriz de rotacionalidade usada no algoritmo ESPRIT
Ψ	Matriz diagonal que contém informações sobre os ângulos θ_k e o deslocamento entre os subarranjos
σ^2	Potência do ruído
$\hat{\mathbf{A}}$	Estimativa da matriz de respostas das antenas obtida pelo Método de Mínimos Quadrados
\mathbf{Y}	Matriz de dados recebidos composta pelos vetores $\mathbf{y}(t)$
\mathbf{S}^+	Pseudoinversa da matriz dos sinais transmitidos \mathbf{S}
λ_k	Autovalor da matriz Φ no algoritmo ESPRIT
$\angle \lambda_k$	Fase do autovalor λ_k
$\hat{\theta}_k$	Estimativa do ângulo de chegada θ_k
p	Percentil
k	Posição na distribuição ordenada
X	Valor na distribuição ordenada
$\lfloor k \rfloor$	Parte inteira inferior de k
$\lceil k \rceil$	Parte inteira superior de k

Sumário

1	Introdução	13
2	Descrição do problema	17
2.1	Processamento de sinal do sistema de comunicação	18
2.2	Cálculo teórico da direção dos ângulos de chegada	19
3	Desenvolvimento	21
3.1	Solução Proposta	21
3.2	Processamento de Sinais da Solução	22
3.3	Estimação da posição do usuário com algoritmo KNN	23
4	Ambiente de simulação	25
5	Resultados	28
5.1	Resultados da estimação da DOA	28
5.2	Resultados da estimação da posição do usuário	33
6	Conclusão	40
	Referências	42
	Apêndices	44
	Apêndice A Primeiro Apêndice	45
A.1	Técnicas baseadas em modelos estatísticos e algoritmos de estimação	45
A.1.1	Método da diferença do tempo de chegada	45
A.1.2	Algoritmo MUSIC	47
A.1.3	Algoritmo ESPRIT	48
A.1.4	Método de mínimos quadrados	49
A.2	Técnicas de processamento adaptativo e machine learning	50
A.2.1	Redes Neurais e Deep Learning	50
A.2.2	Métodos Baseados em Máquinas de Vetores de Suporte (SVM)	51

1 Introdução

Um sistema de localização possui diversas aplicações civis e militares, como operações de resgate, veículos autônomos, Internet das Coisas (IoT), monitoramento de saúde, entre outras aplicações que surgem. De forma geral, os aplicativos utilizam o sistema global de navegação por satélite (GNSS) para localização, especialmente em locais abertos, entretanto, como o sinal é transmitido através de satélites, o sistema não garante uma localização extremamente precisa (Win, 2017).

A crescente demanda por localização de alta precisão é particularmente evidente em setores como grandes centros de armazenamento e logística, onde robôs autônomos são amplamente utilizados para transportar cargas internamente. Nesses casos, é essencial rastrear não apenas a localização das mercadorias, mas também a posição exata do robô que realizará o transporte (Yang T. Cabani, 2021).

A localização em ambientes fechados também pode ser aplicada a espaços públicos, como shoppings, onde o visitante poderia receber informações ou propagandas das lojas à sua frente. Em museus, essa tecnologia permitiria ao visitante receber, por meio de um aplicativo, informações detalhadas sobre a obra que está diretamente à sua frente, melhorando assim a experiência do usuário (Geok *et al.*, 2021).

Além disso, na dissertação de Luiz Ricardo Fiera, é proposto uma tecnologia assistiva para localização em ambiente controlado, onde essa utilizaria a localização precisa em ambiente fechado para auxiliar deficientes visuais a utilizar espaços públicos de forma independente (Fiera Gustavo Bisognin, 2014).

Existem várias soluções *ad-hoc* para posicionamento de alta precisão, abrangendo desde sistemas baseado em tecnologia de largura de banda ultra larga de rádio de impulso dedicada (UWB) a sistema integrando sensores heterogêneos, contudo, a maioria das soluções disponíveis requerem a implantação de uma infraestrutura de alto custo financeiro para posicionamento *ad-hoc* com múltiplas âncoras, ou seja, múltiplos sensores de posições, especialmente em ambientes fechados (Guerra, 2021).

Em ambientes fechados, onde a interferência, reflexão e refração das forças do sinal são sobrepostas em pontos específicos, os métodos baseados em *footprint* podem superar os métodos de trilateração em termos de precisão de localização, uma vez que a estimativa da posição é baseada no algoritmo de correspondência de dados com um conjunto de dados RSSI (Indicador de Força do Sinal Recebido) confiáveis e selecionados de um banco de dados de impressão digital pré-construído (Yang T. Cabani, 2021).

RSSI é considerado o principal dado indicativo para posicionamento em ambientes internos, uma vez que a distância dos pontos âncora até a posição atual pode ser estimada

com base no RSSI, especialmente em um modelo teórico de localização baseado em distância, como a trilateração. No entanto, a medição de RSSI está sujeita a diversas interferências internas, como efeito multi-caminho, ruídos e variações nas condições de canal relacionadas ao ambiente dinâmico. Por esse motivo, o CSI (Informação do Estado do Canal) tem sido considerado um complemento ao RSSI para melhorar a precisão da localização interna. Além disso, outros parâmetros de medição, como RTT (Tempo de Ida e Volta), DOA/AOA (Direção/Ângulo de Chegada), TDOA (Diferença de Tempo de Chegada) e TOA (Tempo de Chegada), também são amplamente utilizados para aumentar a precisão dos sistemas de localização (Yang T. Cabani, 2021).

Sendo assim, surgiu o interesse em utilizar as antenas de comunicação móveis como pontos de acessos para rastreamento de alta precisão, visto que essa infraestrutura aumenta progressivamente devido a implementação de novas tecnologias como o 5G. Portanto, é interessante para realizar soluções de localização e rastreamento de rádio de alta precisão que façam uso do mesma rede de pontos de acesso (AP) já implantada para cobertura de comunicação (Guerra, 2021).

Com as redes de comunicações móveis de quinta e sexta geração (6G), mais melhorias são esperadas na localização e rastreamento. Os avanços resultarão do uso conjunto de altas frequências e grandes arranjos para comunicação e localização de alta precisão. Devido as particularidades da forma de funcionamento de uma rede móvel 5G e 6G, espera-se que um grande número de pontos de acessos, equipados com matrizes de antenas, desempenhem um duplo papel funcional de nós de referência de comunicação e localização. As grandes matrizes em cada AP permitem coletar um grande número de medições, aumentando assim a precisão da localização (Guerra, 2021).

Além disso, quando o arranjo de antenas é grande o suficiente para capturar a característica esférica da onda incidente, o que acontece quando se opera no campo próximo radiante do conjunto (região de Fresnel), uma abordagem promissora é recuperar a posição da fonte diretamente da curvatura de chegada encapsulada na frente de onda esférica. Essa abordagem, que se baseia na geometria do arranjo de antenas e na curvatura de chegada da onda, não requer sincronização e oferece uma solução robusta e precisa para localização (Guerra, 2021).

O problema de localização em ambientes internos pode ser classificado em dois ramos principais: métodos baseados em aprendizado de máquina e métodos baseados em filtros. Métodos tradicionais de aprendizado de máquina supervisionado, como SVM (máquina de vetores de suporte), KNN (k-vizinhos mais próximos), Naive Bayes e métodos de árvore de decisão são capazes de resolver problemas de extração de dados, correspondência e, notavelmente, classificação no problema de localização (Yang T. Cabani, 2021).

Diferente da maioria dos métodos de aprendizado de máquina supervisionado, que se concentram na fase de treinamento para aprender a relação de mapeamento entre a entrada

e a saída por meio de camadas ocultas, o KNN não exige um processo de treinamento complexo. Em vez disso, ele realiza previsões comparando diretamente os dados de entrada com exemplos previamente armazenados, determinando os ' k ' vizinhos mais próximos com base em uma métrica de distância, e utilizando essas informações para classificação ou regressão, sem a necessidade de ajuste de parâmetros internos. Embora a fase de treinamento offline em outros métodos permita a atualização dos parâmetros dos estados do canal, levando a um aprendizado rápido que revela relações internas no conjunto de dados, o KNN foca em decisões instantâneas baseadas nos dados vizinhos mais próximos. Métodos baseados em filtros, como o filtro de partículas (PF) e o filtro de Kalman (KF), seguem uma abordagem diferente, fornecendo soluções de localização por meio de três etapas principais: previsão, medição e assimilação dos dados, criando um modelo contínuo e dinâmico (Yang T. Cabani, 2021).

Diante desse cenário, o presente projeto propõe uma solução para a localização precisa de usuários em ambientes internos utilizando a infraestrutura de redes 5G, aliada ao *beamforming* e ao algoritmo de aprendizado de máquina KNN (K-vizinhos mais próximos). A solução é baseada na criação de uma base de dados que relaciona a posição do usuário com as DOAs calculadas em diferentes níveis de potência de transmissão, como 0 dBm e 15 dBm. Será criado um ambiente fechado, aplicado arranjos de antenas retangulares uniformes (URA) em diferentes pontos de acesso, utilizado o traçador de raios para simular a propagação do sinal pelo ambiente. O objetivo é estimar a posição do usuário na simulação com base nas medições da DOA.

O *beamforming* desempenha um papel crucial nesse contexto, pois permite direcionar e amplificar o sinal em uma direção específica, aumentando a precisão na identificação da DOA. Ele funciona formando um feixe estreito e direcional que maximiza a recepção de sinais provenientes de uma fonte específica, o que é particularmente útil em ambientes com múltiplos trajetos de propagação. A capacidade de formar e direcionar feixes dinâmicos melhora significativamente a resolução espacial e a robustez da detecção da posição, além de mitigar os efeitos da interferência e do multipercurso (Firmo, 2020).

O traçador de raios também desempenha um papel essencial na simulação de propagação dos sinais eletromagnéticos, modelando com precisão como os sinais se comportam ao interagir com objetos e superfícies no ambiente fechado. Essa técnica permite prever com exatidão o caminho que os sinais percorrem, levando em consideração fenômenos como reflexão, refração e difração. O uso do traçador de raios possibilita uma análise detalhada dos parâmetros do canal de comunicação, incluindo a direção de chegada (DOA), que será crucial para a construção da base de dados utilizada pelo algoritmo KNN. Com isso, a simulação será capaz de replicar condições realistas de propagação de sinais em ambientes fechados, fornecendo uma base sólida para a avaliação da solução proposta (Yun; Iskander, 2015).

Para isso, será detalhado o cenário proposto, incluindo a configuração do modelo de

canal, a disposição espacial e uma matriz de antenas URA (arranjo retangular uniforme) nos pontos de acesso. Adicionalmente, consideraremos um usuário equipado com uma antena isotrópica, transmitindo a 0 dBm e 15 dBm, posicionado em várias localizações distintas ao longo da simulação afim de criar uma base de dados a ser utilizado pelo algoritmo KNN. Essa abordagem nos permitirá avaliar e comparar a eficácia da técnica proposta em identificar a localização do usuário em diferentes configurações de pontos de acesso. Essa investigação visa estabelecer um paradigma robusto para soluções de localização em ambiente fechado, o uso da rede 5G existente e suas capacidades avançadas de transmissão.

Portanto, os objetivos do projeto são:

- Simular um ambiente fechado equipado com APs e aplicar o traçador de raios para verificar o funcionamento do *beamforming* para estimar a direção de chegada dos sinais do usuário.
- Estimar a posição do usuário a partir da base de dados com a DOA calculado para várias posições e utilizando algoritmo KNN.
- Verificar o o desempenho do *beamforming* em estimar a DOA e o desempenho do algoritmo KNN ao estimar a posição do usuário a partir do treinamento.

2 Descrição do problema

Este trabalho propõe uma solução para a estimativa precisa da localização de um usuário em um ambiente fechado simulado. O projeto visa analisar o comportamento dos sinais eletromagnéticos recebidos por múltiplos arranjos de antenas, denominados de ponto de acesso, estrategicamente distribuídos no ambiente, utilizando técnicas de processamento de sinais para calcular a direção de chegada dos sinais e aprendizado de máquina para estimar a posição do usuário a partir da DOA. Além disso, o estudo investiga o impacto da variação na potência de transmissão sobre a precisão da localização, explorando como a qualidade do sistema é influenciada a níveis de potência de 0 dBm e 15 dBm.

No contexto apresentado de detecção e estimação da direção de chegada dos sinais, o entendimento dos sinais eletromagnéticos é fundamental. Esses sinais são utilizados para determinar a direção de onde uma onda de rádio, som ou outro sinal eletromagnético está se originando.

Um sinal eletromagnético é uma forma de onda eletromagnética, ou seja, é uma energia que se propaga através do espaço como uma onda composta de campos elétricos e magnéticos perpendiculares entre si e à direção de propagação. Esses sinais são descritos pela teoria eletromagnética de James Clerk Maxwell, que estabeleceu que mudanças nos campos elétricos criam campos magnéticos e vice-versa, permitindo que a energia se propague através do espaço (CHEW, 2019).

A frequência, medida em Hertz (Hz), é o número de ciclos que uma onda completa por segundo. O comprimento de onda é a distância entre dois pontos consecutivos de fase igual, como cresta a cresta ou vale a vale, sendo medido em metros. A relação entre frequência e comprimento de onda é dada pela Equação (2.1):

$$\lambda = \frac{c}{f}, \quad (2.1)$$

em que, c é a velocidade da luz no vácuo (3×10^8 m/s). A amplitude de um sinal eletromagnético é a altura da onda, que indica a intensidade ou potência do sinal. Já a fase de um sinal refere-se à posição da onda em um dado ponto no tempo e no espaço (CHEW, 2019).

Os sinais eletromagnéticos podem ser gerados por diversas fontes, como antenas de rádio, transmissores de micro-ondas, equipamentos de telecomunicações, entre outros. A propagação desses sinais pode ocorrer de diferentes maneiras, dependendo do meio e das características do sinal, sendo a linha de visada (LOS) uma das formas mais comuns quando não há obstáculos significativos entre o transmissor e o receptor, característica das comunicações por micro-ondas e satélites. Além disso, outros fenômenos de propagação também influenciam a trajetória do sinal: a reflexão ocorre quando o sinal encontra uma

superfície e é refletido; a refração acontece ao atravessar meios com propriedades diferentes, alterando sua direção de propagação; a difração permite ao sinal contornar obstáculos ou se espalhar após passar por uma abertura; e, por fim, a dispersão faz com que o sinal se espalhe em várias direções ao encontrar pequenas partículas ou irregularidades no meio (CHEW, 2019).

Para a detecção de sinais eletromagnéticos, são utilizados receptores equipados com antenas apropriadas aos sinais transmitidos, que capturam esses sinais e os convertem em sinais elétricos (Orfanidis, 1999a).

Em ambientes fechados, onde a propagação de sinais é complexa devido a múltiplos percursos causados por reflexões, refrações e difrações em paredes, móveis e outros obstáculos, a análise da direção de chegada torna-se desafiadora (Orfanidis, 1999a).

Arranjos de antenas são amplamente utilizados para captar sinais provenientes de diferentes direções e determinar a direção de chegada por meio de técnicas avançadas de processamento de sinais (Orfanidis, 1999a). Entre essas técnicas, destacam-se o *Beamforming*, Método dos Mínimos Quadrados, a Classificação de Sinais Múltiplos (MUSIC) e a Estimativa de Parâmetros de Sinais por Técnicas de Invariância Rotacional (ESPRIT) (Waweru D. B. O. Konditi, 2014). Além disso, algoritmos de machine learning, como KNN, Redes Neurais, e métodos baseados em máquinas de vetores de suporte (SVM), também são empregados para aprimorar a precisão da localização a partir da DOA, tornando o processo mais robusto e eficiente (Yang T. Cabani, 2021).

2.1 Processamento de sinal do sistema de comunicação

O processamento de sinal no sistema de comunicação é fundamental para estimar a localização e a direção de chegada dos sinais transmitidos. O modelo básico do sinal recebido pelo sistema pode ser representado pela Equação (2.2):

$$y[m,i] = A(\theta)s[m,i] + n[m,i], \quad (2.2)$$

em que, $y[m,i]$ é o sinal recebido, $A(\theta)$ é a matriz de resposta do arranjo para os ângulos θ , $s[m,i]$ são os símbolos transmitidos e $n[m,i]$ é o vetor de ruído aditivo gaussiano. Este modelo descreve como o sinal transmitido $s[m,i]$ é afetado pelo canal de comunicação e pelo ruído ao ser recebido.

A extração dos ângulos de chegada ocorre ao calcular os ângulos θ_l e baseando-se no modelo de múltiplos caminhos, que pode ser representado pela Equação (2.3):

$$h[m,i] = \sum_{l=0}^{L-1} \rho_l e^{j\varphi_l} a(\theta_l) e^{j2\pi m \Delta f \tau_l}, \quad (2.3)$$

no qual, ρ_l é o ganho de amplitude do l -ésimo caminho, $e^{j\varphi_l}$ representa a fase associada ao caminho l , $a(\theta_l)$ é o vetor de resposta da antena para o ângulo θ_l , e $e^{j2\pi m \Delta f \tau_l}$ modela o efeito

do atraso temporal no l -ésimo caminho, considerando o espaçamento entre subportadoras Δf , o atraso τ_l , e o índice da subportadora m . Esse modelo descreve como o sinal se propaga no ambiente por múltiplos percursos, cada um caracterizado por diferentes atrasos, ângulos e ganhos, afetando a recepção nos pontos de acesso.

Diversas técnicas podem ser utilizadas para extrair os ângulos de chegada θ_l , cada uma com suas vantagens, dependendo das condições do ambiente e do tipo de sistema, nas quais devem processar o sinal recebido para identificar a direção dos múltiplos caminhos. O objetivo é calcular com precisão os ângulos θ_l para cada caminho do canal, o que é essencial para a estimação da localização do usuário em ambientes complexos.

2.2 Cálculo teórico da direção dos ângulos de chegada

Para calcular a direção de chegada de forma teórica, é necessário determinar os ângulos de azimute, elevação e o raio a partir da distância teórica entre os pontos de acesso e o receptor. As coordenadas cartesianas dos pontos são convertidas em coordenadas esféricas dentro de um laço, com o objetivo de calcular esses ângulos para cada ponto em relação ao usuário de forma analítica e, em seguida, comparar os resultados teóricos com os obtidos na simulação (Guerra, 2021).

O processo começa calculando os vetores de distância (\vec{d}) entre o usuário e cada ponto de acesso a partir da diferença entre as coordenadas correspondentes, como descrito pela Equação (2.4):

$$\vec{d} = \vec{u}_p - \vec{A}_{pP} \quad (2.4)$$

Com o vetor distância, é possível calcular o azimute (Az), que é o ângulo horizontal medido a partir do norte em direção ao ponto de interesse. O azimute é obtido a partir das coordenadas x e y do vetor \vec{d} , conforme a Fórmula (2.5):

$$Az = \arctan \left(\frac{\vec{d}(y)}{\vec{d}(x)} \right). \quad (2.5)$$

Em seguida, calcula-se a elevação (El), que é o ângulo vertical medido a partir do plano horizontal até o ponto de interesse. Para isso, utiliza-se a componente z do vetor \vec{d} e a distância radial r , através da Equação (2.6):

$$El = \arcsin \left(\frac{\vec{d}(z)}{r} \right), \quad (2.6)$$

tal que, o raio r é determinado a partir das três componentes do vetor \vec{d} pela Expressão (2.7):

$$r = \sqrt{\vec{d}(x)^2 + \vec{d}(y)^2 + \vec{d}(z)^2}. \quad (2.7)$$

Por fim, os ângulos de azimute e elevação são convertidos para a escala de graus, permitindo a comparação com os ângulos de direção obtidos nas simulações. As conversões são realizadas pelas Equações (2.8) e (2.9):

$$az_{deg} = Az \times \left(\frac{180}{\pi} \right); \quad (2.8)$$

$$el_{deg} = El \times \left(\frac{180}{\pi} \right). \quad (2.9)$$

Dessa forma, o cálculo teórico da DOA envolve a determinação precisa dos ângulos de azimute e elevação para cada ponto de acesso em relação ao receptor, permitindo uma comparação direta com os resultados simulados.

3 Desenvolvimento

3.1 Solução Proposta

A solução proposta para a estimativa de direção de chegada em ambientes de comunicação complexos utiliza *beamforming* em conjunto com o algoritmo k-vizinhos mais próximos para fornecer estimativas precisas dos ângulos de chegada dos sinais, tanto em condições de transmissão de 0 dBm quanto de 15 dBm. O *beamforming* é particularmente vantajoso em sistemas de antenas devido à sua capacidade de formar feixes direcionais que maximizam a relação sinal-ruído (SNR) ao focar a recepção em direções específicas, o que o torna ideal para ambientes onde os sinais são refletidos ou dispersos por obstáculos. Em vez de depender de técnicas mais complexas e computacionalmente custosas, como MUSIC ou ESPRIT, que exigem alta precisão na modelagem dos sinais, o *beamforming* oferece uma solução eficiente e robusta para captar sinais em ambientes realistas.

O uso do KNN complementa essa abordagem ao ajustar as estimativas da direção de chegada com base em um banco de dados de ângulos previamente conhecidos. Diferente de técnicas que requerem maior sofisticação matemática, como SVM ou redes neurais, o KNN se destaca por sua simplicidade e precisão em ambientes onde há um grande volume de dados de treinamento e a resposta do sistema pode ser diretamente comparada com dados já processados. Assim, o sistema pode ajustar a previsão da DOA com base em padrões conhecidos, otimizando o desempenho em termos de tempo de processamento e robustez frente a ruídos.

O processamento de sinal no sistema de comunicação começa com a modelagem do sinal recebido, descrita pela Equação (2.2). Para capturar a interação do sinal com o ambiente e suas trajetórias, utilizamos o traçador de raios. Esta técnica simula a propagação dos sinais através do ambiente, considerando reflexões, difrações e dispersões. O traçador de raios gera um banco de dados detalhado sobre como o sinal se propaga, essencial para a modelagem do canal de múltiplos caminhos. O modelo de múltiplos caminhos é representado pela Equação (2.3), que descreve como o sinal se propaga através de diferentes caminhos.

A estimativa da direção dos ângulos de chegada é realizada por meio da formação de feixe, onde a matriz de resposta da antena projeta o sinal recebido, calculando $P(\theta)$. A busca pelos ângulos que maximizam $P(\theta)$ é feita utilizando o algoritmo de *beamscanning*. Após a determinação da DOA, o algoritmo KNN ajusta as previsões comparando os sinais recebidos com um banco de dados de ângulos previamente conhecidos, permitindo estimar com precisão a posição do usuário. Além disso, o sistema é calibrado com símbolos pilotos de magnitude unitária, o que melhora sua robustez ao lidar com ruído aditivo gaussiano,

garantindo maior precisão nas estimativas das DOAs.

3.2 Processamento de Sinais da Solução

O sistema de transmissão é configurado para simular condições realistas e avaliar a precisão das estimativas das DOAs dos sinais. Ele inclui transmissores e receptores distribuídos estrategicamente para cobrir o ambiente e captar sinais a partir de diferentes direções em pelo menos 1 receptor. Além disso, arranjos de antenas são dispostos de forma a maximizar a cobertura e suportar técnicas de formação de feixe. Os parâmetros do canal são definidos com base no traçador de raios, garantindo uma representação precisa da propagação do sinal.

A eficácia da solução proposta para a estimativa da direção de chegada depende fortemente do modelo de transmissão implementado. Esta seção descreve a configuração do sistema de transmissão, as condições experimentais e como essas configurações são utilizadas para validar as estimativas das DOAs.

A solução propõe extrair os ângulos de chegada θ_l do canal de comunicação usando a técnica de *beamforming*, onde o sinal recebido é processado de forma a identificar as direções mais prováveis de onde o sinal foi transmitido. O canal de comunicação é modelado como um sistema de múltiplos caminhos, onde cada trajeto tem características únicas de amplitude ρ_l , fase φ_l , atraso τ_l e o ângulo de chegada θ_l e é representado pela equação (2.3). A busca pelos ângulos de chegada é realizada através de um algoritmo de *beamscanning*, que identifica os ângulos que maximizam $P(\theta)$ na Equação (3.1):

$$P(\theta) = a^H(\theta)\mathbf{R}a(\theta), \quad (3.1)$$

em que, nesta equação, $a(\theta)$ é a matriz de resposta da antena para um ângulo θ específico, $a^H(\theta)$ é o seu conjugado transposto, e R é a matriz de correlação dos sinais recebidos, que captura as interdependências entre os sinais medidos pelas diferentes antenas. A função $P(\theta)$ indica o quão bem o sinal recebido se alinha com a direção θ , sendo que os picos dessa função correspondem às direções de chegada estimadas.

O processo de *beamscanning* envolve a varredura de diferentes ângulos candidatos θ e o cálculo de $P(\theta)$ para cada um deles. Os ângulos θ_l que maximizam $P(\theta)$ são interpretados como as estimativas dos ângulos de chegada dos diferentes trajetos do canal. Este método é robusto para ambientes com múltiplos trajetos, onde os sinais podem chegar ao receptor a partir de várias direções simultaneamente.

3.3 Estimação da posição do usuário com algoritmo KNN

K-vizinhos mais próximos é um modelo de classificação de vizinho mais próximo no qual você pode alterar a métrica de distância e o número de vizinhos mais próximos. Como o classificador KNN armazena dados de treinamento, você pode usar o modelo para calcular previsões de substituição. Alternativamente, use o modelo para classificar novas observações usando o método de previsão (MatLab, 2024).

O algoritmo KNN é um dos métodos de aprendizado de máquina mais simples e eficazes para tarefas de classificação e regressão. Baseia-se na ideia de que objetos semelhantes estão próximos uns dos outros. Portanto, para classificar um novo dado, o algoritmo examina os 'k' vizinhos mais próximos no conjunto de treinamento e decide a classe ou valor com base nesses vizinhos. O KNN é um algoritmo baseado em instâncias, pois não constrói explicitamente um modelo durante a fase de treinamento. Em vez disso, ele armazena os exemplos de treinamento e realiza a classificação ou regressão apenas quando um novo dado precisa ser processado (Zhang *et al.*, 2017).

A aplicação do KNN para estimar a posição do usuário parte da análise da direção de chegada dos sinais, obtidos a partir do processo de *beamforming*. Para cada novo dado de entrada, ou seja, para cada nova estimativa da DOA, o KNN identifica os 'k' vizinhos mais próximos com base em um banco de dados de sinais previamente registrados, cujas direções de chegada e posições são conhecidas. Assim, o KNN calcula a posição estimada do usuário com base nas posições desses vizinhos (Peng *et al.*, 2020).

O algoritmo KNN possui a seguinte forma de funcionamento (Peng *et al.*, 2020):

1. **Definição do Valor de k:** O número de vizinhos 'k' define quantos pontos mais próximos serão utilizados para a estimação da posição. Um valor pequeno de 'k' pode resultar em alta sensibilidade ao ruído, enquanto um valor elevado de 'k' pode suavizar as previsões, mas também reduzir a precisão.

O algoritmo KNN utiliza a métrica de distância Euclidiana para medir a similaridade entre uma nova estimativa da DOA e os ângulos de chegada presentes no banco de dados de treinamento. A distância Euclidiana entre dois pontos, em que \mathbf{x} são as direções de chegada, em azimute e elevação, a serem testadas, \mathbf{y} são as direções de chegada, também em azimute e elevação, da base de dados e N representa o número de variáveis consideradas na comparação, é calculada da seguinte forma:

$$d(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}, \quad (3.2)$$

em que, a métrica de distância será aplicada para comparar as características dos sinais entre a nova entrada e os dados de referência.

2. **Identificação dos Vizinhos Mais Próximos:** Após calcular as distâncias entre a DOA atual e as DOAs no banco de dados, o algoritmo seleciona os 'k' vizinhos mais próximos. Esses vizinhos representam os sinais com direção dos ângulos de chegada mais semelhantes as DOA que está sendo analisado.
3. **Estimação da Posição do Usuário:** No caso de regressão, que é o foco da estimação de posição, a localização do usuário será calculada com base nas posições dos 'k' vizinhos mais próximos. A abordagem mais comum é calcular a média das posições dos vizinhos, ponderando ou não de acordo com a distância do novo dado aos vizinhos.

Desse modo, o KNN fornece uma abordagem simples e eficaz para estimar a posição do usuário a partir de dados da DOA, pois permite que o modelo utilize diretamente as informações de treinamento para prever a localização com base em sinais previamente conhecidos. Ao refinar as estimativas da DOA com o KNN, o sistema pode alcançar uma maior precisão na localização do usuário, especialmente em ambientes fechado de comunicação, onde reflexões e múltiplos caminhos dificultam a propagação de sinais.

4 Ambiente de simulação

Para validar a solução proposta, foi definido o ambiente que será testado o código do MATLAB com o traçador de raios. Para fins de estudo, foi criado um ambiente genérico com sala menor, corredores, curvas e sala maior e inserido um ponto de acesso em cada área, garantindo que o usuário esteja na linha de visada de no mínimo um AP. O ambiente simulado encontra-se disponível no repositório do projeto ([GitHub, 2024](#)).




Figura 4.1 – Vista 3D do ambiente fechado

O ambiente de simulação foi desenvolvido no Blender, que é uma ferramenta que permite a criação de vastos conteúdos de 3D. Oferece funcionalidades completas para modelagem, renderização, animação, pós-produção, criação e visualização de conteúdo 3D interativo, entre outros. Originalmente desenvolvido pela empresa Not a Number, o Blender é desenvolvido como software livre, e o seu código fonte está disponível sobre a licença GNU GPL ([Blender, 2002](#)).

A simulação mostrado na Figura 4.1 foi adicionado ao código MATLAB e os pontos de acessos foram adicionados em cada ambiente manualmente, estando no centro e cobrindo todo o local, conforme apresentado na Figura 4.2 e suas coordenadas na Tabela 4.1. A partir dessa configuração, é possível simular todas as direções dos ângulos de chegada dos raios eletromagnéticos proveniente do usuário através da ferramenta traçador de raios.

O método de traçar raios, fundamentado na óptica de raios que resolve as equações de Maxwell em regime de alta frequência, é uma técnica numérica poderosa e versátil para modelagem de propagação de ondas eletromagnéticas ([Yun; Iskander, 2015](#)). Diferente de modelos teóricos e empíricos que oferecem fórmulas simplificadas para perda de caminho, o traçador de raios utiliza métodos computacionais para simular a propagação considerando reflexão, refração, difração e absorção. Amplamente utilizado em gráficos computacionais, design de produtos e engenharia, na área de comunicações sem fio, ele é essencial para modelar canais de comunicação em ambientes complexos, fornecendo detalhes precisos sobre potência do sinal, atraso de propagação e desvanecimento, o que o torna uma ferramenta crucial para o desenvolvimento e avaliação de sistemas de comunicação do projeto. ([Moe T.](#)

et al., 2017)

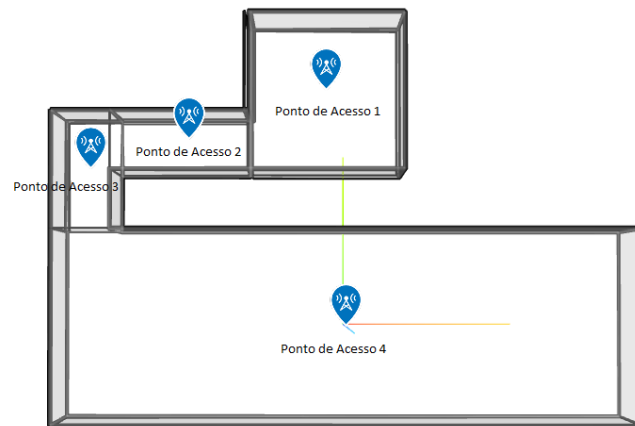


Figura 4.2 – Vista Superior do Ambiente com Pontos de Acessos

Ponto de Acesso	Coordenadas
AP1	[-1 m; 12 m; 2.8 m]
AP2	[-8 m; 9.5 m; 2.8 m]
AP3	[-13 m; 8 m; 2.8 m]
AP4	[0 m; 0 m; 2.8 m]

Tabela 4.1 – Localização dos APs na simulação

Os pontos de acesso são configurações de múltiplas antenas individuais, organizadas de maneira sistemática para formar um único sistema de antena que pode direcionar e receber sinais eletromagnéticos de forma mais eficiente e precisa (Orfanidis, 1999b). Esses arranjos de antenas são amplamente utilizados em sistemas de comunicação, radar e navegação para a estimativa da direção dos ângulos de chegada dos sinais recebidos. A capacidade de determinar a direção de chegada de um sinal é essencial para a localização e rastreamento de fontes de sinal, o que é fundamental em diversas aplicações, incluindo redes sem fio e sistemas de monitoramento (Zhou *et al.*, 2020).

Com o cenário definido, o usuário foi posicionado em posições diferentes para criar a base de dados a ser utilizada para treinamento do algoritmo KNN que irá estimar a posição do usuário. Os resultados foram salvos e adicionado também no repositório (GitHub, 2024).

Um arranjo de antenas consiste em múltiplas antenas individuais, conhecidas como elementos, dispostas em uma configuração específica. Os arranjos mais comuns incluem o arranjo linear, onde as antenas são dispostas em linha reta; o arranjo circular, em que as antenas são organizadas em um círculo; e o arranjo retangular ou plano, onde as antenas formam uma grade retangular e que será utilizado na simulação (Orfanidis, 1999b).

Esses arranjos de antenas podem ser caracterizados de diversas formas. A diretividade

é uma das características importantes, pois os arranjos podem ser projetados para aumentar a diretividade do sistema de antena, concentrando a recepção ou transmissão de sinais em determinadas direções. Outra característica é a largura de feixe, que representa a medida angular da dispersão do sinal transmitido ou recebido pelo arranjo. Arranjos de antenas podem ser ajustados para ter feixes mais estreitos, aumentando a precisão na direção do sinal. O ganho também é uma característica relevante, sendo a medida da capacidade de amplificação do sinal em uma direção específica, em comparação com uma antena isotrópica ideal (Orfanidis, 1999b).

O funcionamento dos arranjos de antenas baseia-se no princípio da superposição e interferência de ondas eletromagnéticas. Quando um sinal chega ao arranjo, ele é captado por cada elemento em diferentes tempos devido à diferença de percurso. Ao combinar os sinais recebidos com diferentes atrasos (ou fases), é possível reforçar os sinais que chegam de uma determinada direção e atenuar os sinais provenientes de outras direções (Orfanidis, 1999b).

O usuário é posicionado como um transmissor no ambiente da simulação que utiliza uma antena isotrópica, emitindo sinais uniformemente em todas as direções. Por outro lado, os pontos de acesso operam como receptores empregando uma antena uniforme de arranjo retangular de 64 elementos, sendo 8 no eixo X e 8 no eixo Y.

Denominação dos pontos no Arranjo	Função	Antena
Ponto de Acesso 1	Receptor	Antena URA
Ponto de Acesso 2	Receptor	Antena URA
Ponto de Acesso 3	Receptor	Antena URA
Ponto de Acesso 4	Receptor	Antena URA
Usuário	Transmissor	Antena Isotrópica

Tabela 4.2 – Características do Arranjo de Antenas

5 Resultados

5.1 Resultados da estimação da DOA

Com o objetivo de criar uma base de dados de posições diferentes dos usuários e suas respectivas direções de chegada do sinal em cada ponto de acesso, o código do projeto irá calcular a DOA na simulação para um transmissor que percorre o ambiente em 423 posições diferentes.

Em cada iteração foram definidos os parâmetros para o canal, incluindo o espaçamento entre as portadoras, estabelecido em $2^4 \times 15$ kHz (240 kHz), e o comprimento da transformada rápida de Fourier (FFT), fixado em 2^{11} (2048 amostras). Essas definições são cruciais para otimizar a largura de banda do sinal e minimizar a interferência, além de influenciar diretamente a resolução de frequência e a eficiência espectral do sistema.

A comunicação simulada entre usuário e APs permite a aplicação da técnica de *beamforming*, graças ao espaçamento entre os elementos da antena ajustado para metade do comprimento de onda ($\lambda/2$). Esse arranjo favorece a formação de feixes direcionais e aperfeiçoa a recepção de sinais, adaptando-se eficientemente a ambientes com múltiplos caminhos de propagação e interferências.

A formação de feixe é uma técnica utilizada para direcionar o padrão de radiação de um arranjo de antenas para uma direção específica. Isso é alcançado ajustando as fases e amplitudes dos sinais recebidos ou transmitidos por cada elemento da antena. O *beamforming* adaptativo permite que as direções dos feixes sejam ajustadas dinamicamente com base nos sinais recebidos, proporcionando desempenho superior em ambientes dinâmicos (Krishnaveni *et al.*, 2012). Operando na frequência de 60 GHz, parte do espectro de ondas milimétricas, o sistema é projetado para suportar altas taxas de transmissão de dados, apesar dos desafios associados à atenuação do sinal e à sensibilidade a obstáculos físicos, que resultam em múltiplos percursos.

Na simulação para estimar os ângulos de chegada, o processo começa com a projeção dos raios entre o usuário e o ponto de acesso, utilizando técnicas de traçador de raios. Este método cria um modelo de canal detalhado que considera múltiplos caminhos de propagação, como reflexões e difrações. Com o canal modelado, os parâmetros da modulação de amplitude em quadratura (QAM) são configurados para modular as subportadoras individualmente. Em seguida, a modulação e demodulação são realizadas usando a multiplexação por divisão de frequência ortogonal (OFDM). O OFDM utiliza múltiplas subportadoras para transmitir símbolos, lidando de forma eficiente com a dispersão no tempo e na frequência.

Os símbolos OFDM são ajustados com parâmetros como o comprimento da FFT,




Figura 5.1 – Simulação dos feixes

bandas de guarda, subportadora nula, subportadoras piloto e comprimento do prefixo cíclico. Após a transmissão, o sinal OFDM é demodulado e, a partir do sinal recebido, o algoritmo de estimação da DOA calcula os ângulos de chegada. O *beamforming* é usado para correlacionar o sinal com as respostas da antena e identificar os ângulos que maximizam a correlação.

A formação de feixe é crucial para direcionar a radiação das antenas. Ajustando as fases e amplitudes dos sinais, o sistema ajusta dinamicamente as direções dos feixes com base na força do sinal recebido. O processo envolve a varredura de ângulos de azimute e elevação, criando um "mapa" de potência do sinal que permite identificar a direção de maior intensidade (Krishnaveni *et al.*, 2012).

A Figura 5.2 apresenta um gráfico tridimensional (3D) que ilustra a distribuição espacial da potência do sinal em um cenário fechado simulado. Nesse gráfico, são representados os ângulos de azimute e elevação nos eixos horizontal e vertical, respectivamente, enquanto o eixo de profundidade (z) indica a potência do sinal em decibéis (dB).

O pico de potência observado na Figura 5.2 corresponde à estimativa da DOA, identificando a direção de onde o sinal é mais forte. Esse processo de ajuste fino permite ao sistema determinar com alta precisão os ângulos de azimute e elevação, que correspondem à localização angular do transmissor em relação ao receptor.

Além disso, observa-se na Figura 5.2 a quantidade de sinais adjacentes que o arranjo de antenas capta. Essa complexidade na leitura de múltiplos sinais pode impactar diretamente a precisão na estimativa da DOA. Para avaliar o desempenho das estimativas, foi utilizado o *erro absoluto*, que mede a diferença entre os valores simulados e os teóricos das DOAs para as transmissões de 0 dBm e 15 dBm. O erro absoluto é fundamental para quantificar o desvio entre a estimativa e o valor de referência, considerando a possível interferência de sinais adjacentes capturados pelo arranjo de antenas.

$$\text{Erro Absoluto} = |\text{Valor Simulado} - \text{Valor Teórico}|. \quad (5.1)$$

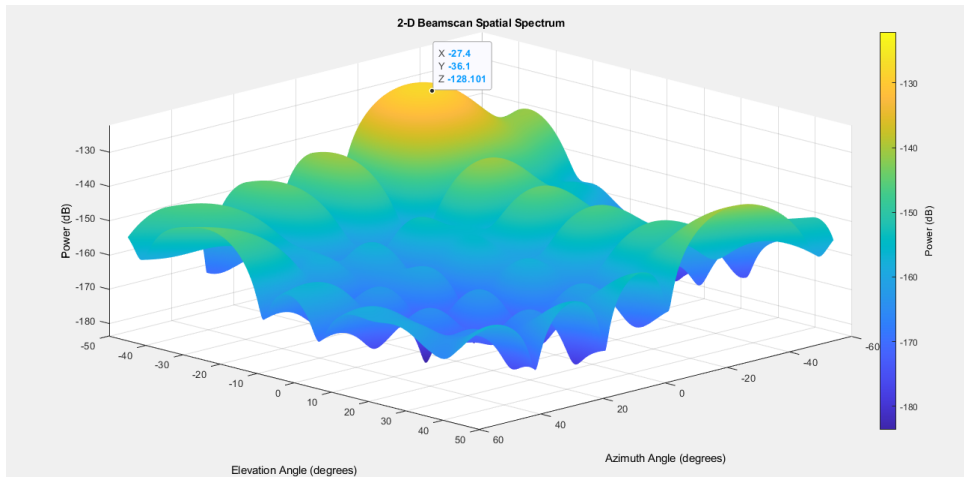


Figura 5.2 – Gráfico 3D da Potência do sinal recebido pelo azimute e elevação

Ao calcular o erro absoluto para todas as amostras do azimute e a elevação de cada ponto de acesso em 0 e 15 dBm, observa-se como a interferência de sinais múltiplos pode afetar a precisão das medições. A análise dos gráficos dos erros absolutos, apresentados nas Figuras 5.3 e 5.4, revela como essa interferência pode impactar as estimativas da direção dos ângulos de chegada para diferentes pontos de acesso tanto no azimute quanto na elevação.




Figura 5.3 – CDF dos erros absolutos do azimute para APs 1, 2, 3 e 4 para 0 dBm

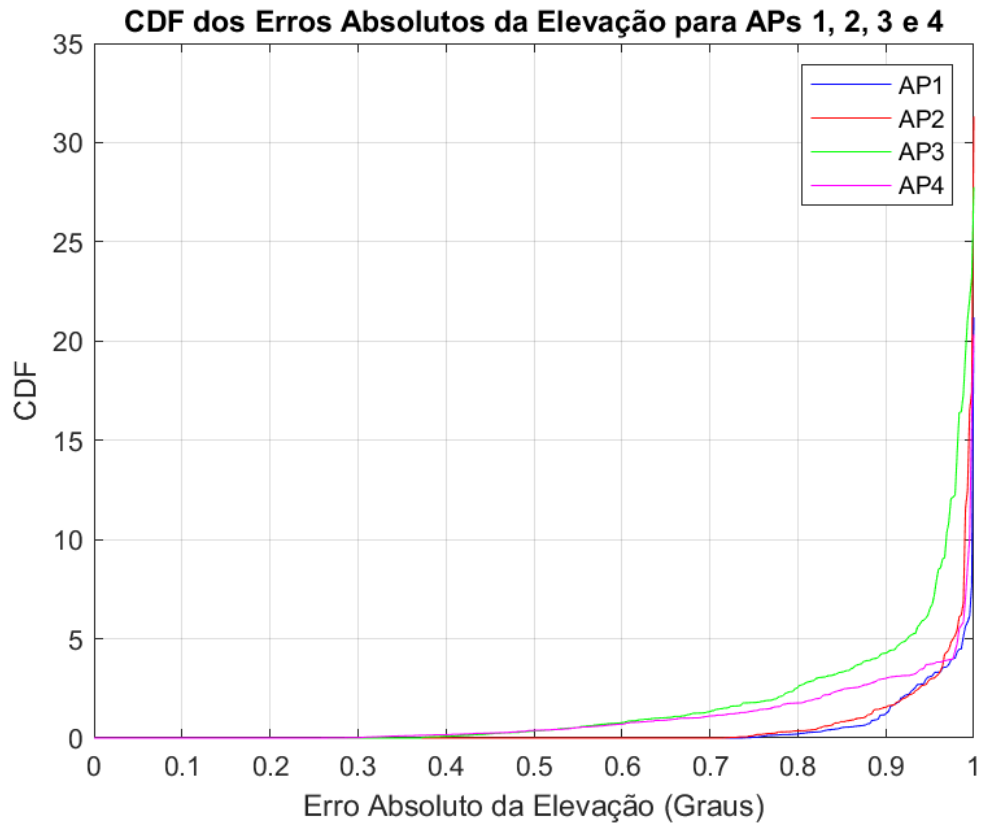


Figura 5.4 – CDF dos erros absolutos da elevação para APs 1, 2, 3 e 4 para 0 dBm

Enquanto, os Gráficos 5.5 e 5.6 apresenta os erros absolutos do azimute e da elevação para os APs 1, 2, 3 e 4 em 15 dBm e mostra um comportamento semelhante em relação aos valores encontrados em 0 dBm, indicando uma consistência nas estimativas sob diferentes condições de potência.

Todos esses gráficos ilustram a distribuição dos erros e permitem uma análise detalhada do desempenho do sistema, evidenciando como a complexidade na leitura de múltiplos sinais pode criar desvios significativos, especialmente nos ângulos do azimute.

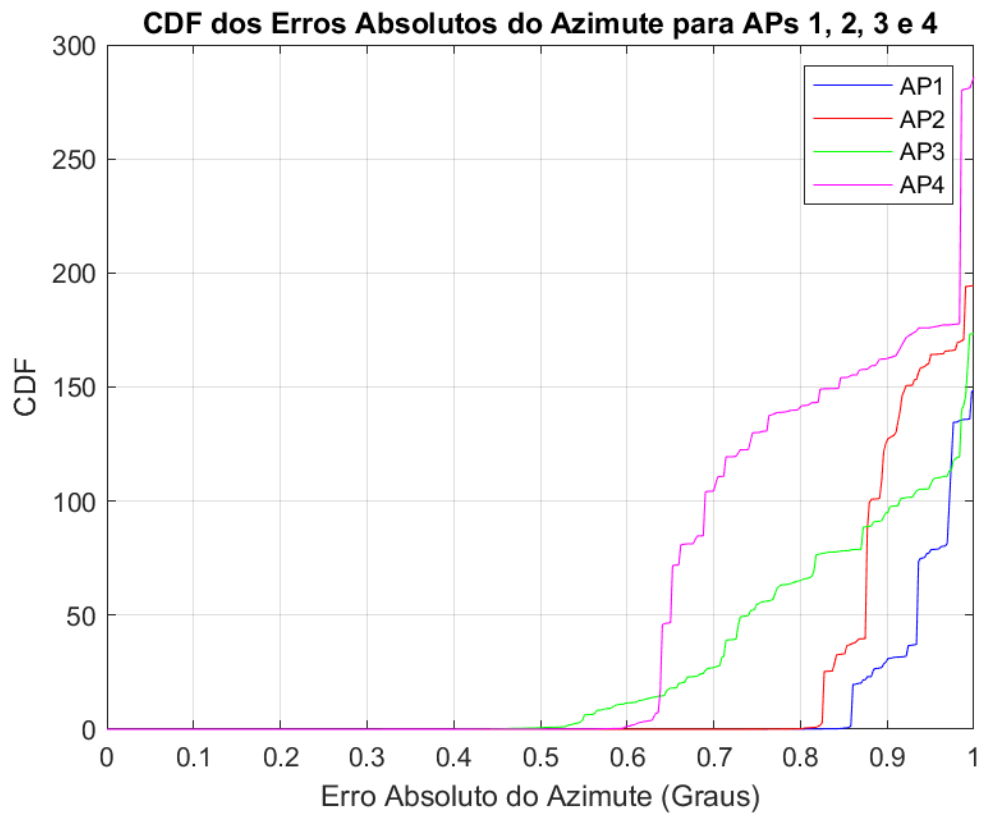


Figura 5.5 – CDF dos erros absolutos do azimute para APs 1, 2, 3 e 4 para 15 dBm




Figura 5.6 – CDF dos erros absolutos da elevação para APs 1, 2, 3 e 4 para 15 dBm

Além disso, a análise do erro absoluto médio (MAE) fornece uma visão geral sobre a performance dos diferentes pontos de acesso em 0 dBm e 15 dBm. O erro absoluto médio para cada AP foi calculado e os resultados são apresentados na Tabela 5.1. Esta tabela revela que os erros médios podem variar significativamente entre os diferentes APs, refletindo a capacidade dos sistemas de estimar com precisão a direção de chegada em diferentes condições. Notavelmente, o AP4 apresentou o pior desempenho na estimativa da DOA por estar cobrindo a maior área da simulação.

O erro absoluto médio (MAE) foi calculado utilizando a Equação (5.2):

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (5.2)$$

em que, n é o número total de amostras, neste caso são 423, \hat{y}_i é o valor estimado para a i -ésima amostra, e y_i é o valor teórico para a i -ésima amostra. O MAE fornece uma medida da precisão das estimativas realizadas, onde menores valores indicam maior precisão.

AP	0 dBm	15 dBm
Erro absoluto médio para AP 1	4.94°	4.79°
Erro absoluto médio para AP 2	10.73°	10.52°
Erro absoluto médio para AP 3	15.14°	14.39°
Erro absoluto médio para AP 4	27.03°	26.73°

Tabela 5.1 – Tabela do erro absoluto médio para cada AP em 0 dBm e 15 dBm

A distribuição dos erros, apresentada através dos gráficos, permite uma análise detalhada do desempenho do sistema e como a sobreposição ou ruído nos sinais adjacentes pode criar desvios significativos nos ângulos de azimute e elevação. O erro absoluto médio, sendo uma métrica agregada do desvio, fornece uma ferramenta útil para comparar diretamente a precisão dos diferentes pontos de acesso e entender como a complexidade da leitura múltipla pode impactar a qualidade das estimativas em diferentes níveis de potência.

Os resultados das estimativas das DOAs, posições dos pontos de acesso e posições dos usuários são armazenados em listas para posterior análise e são exportados para um banco de dados. Caso o ponto de acesso não receba um sinal suficiente, um valor "999" é registrado para indicar uma falha na estimativa e não impactar o algoritmo KNN. Por fim, os resultados da simulação são armazenados em uma base de dados, que também é disponibilizada no GitHub ([GitHub, 2024](#)).

5.2 Resultados da estimação da posição do usuário

Para a estimação da posição do usuário, o algoritmo KNN iniciará lendo o conjunto de dados obtidos na simulação de treinamento e eliminando as posições que não obtiveram

resultados, ou seja, qualquer posição do usuário que todos os quatro pontos de acessos não encontraram resultado.

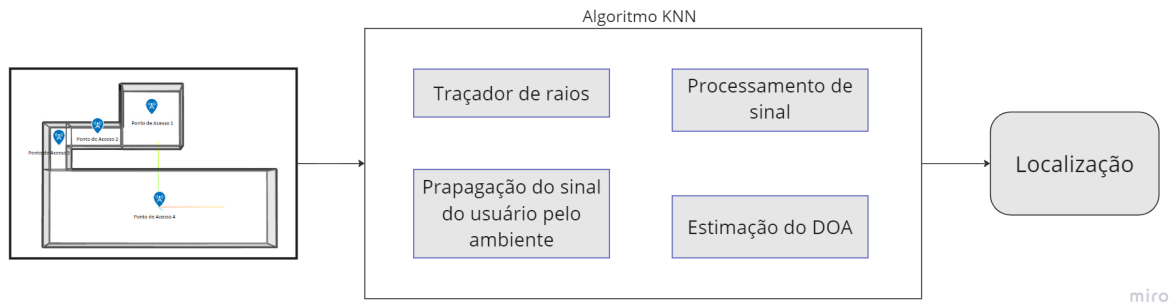


Figura 5.7 – Diagrama de fases para estimação da localização

O código organiza os dados em conjuntos correspondentes a cada ponto de acesso e suas respectivas posições. Para cada linha dos dados, ele verifica se os índices estão dentro dos limites, atribui os valores da DOA e posição, e verifica se todas as posições são iguais e se pelo menos uma DOA é válida. Se essas condições forem satisfeitas, as DOAs e a posição correspondente são adicionados aos conjuntos.

Os dados da DOA são padronizados para garantir que as 423 posições tenham o mesmo número de elementos. Isso é feito adicionando valores replicados até que todos os arranjos tenham o mesmo tamanho. Com os conjuntos do mesmo tamanho, os dados são concatenados formando 1 vetor contendo os 4 direções de chegada, calculados para cada posição em cada AP, para atender as especificações do funcionamento do algoritmo KNN.

Os dados são então divididos em conjuntos de treinamento e teste utilizando uma partição de validação cruzada com 20% dos dados reservados para teste. Essa divisão é feita para avaliar o desempenho do modelo com dados não vistos durante o treinamento. O Modelo de regressão KNN é criados e treinados para prever as coordenadas x, y e z das posições dos usuários.

O algoritmo no Matlab utiliza-se da função *fitcknn* para treinar o modelo KNN. É calculado a distância euclidiana entre todos os pontos de cada ponto de acesso, sendo (az_1, el_1) , representando o valor da DOAs, em azimute e elevação, para a posição que está sendo testada e (az_2, el_2) , representando o valor das DOAs, em azimute e elevação, para uma posição na base de dados, utilizando a Equação (5.3):

$$d = \sqrt{(az_2 - az_1)^2 + (el_2 - el_1)^2}. \quad (5.3)$$

Com a distância euclidiana calculada para todas as direções a serem testadas com a base de dados, o algoritmo KNN encontra os vizinhos mais próximos e, assim, prever as coordenadas (x, y, z) das posições dos usuários.

Sendo assim, as posições estimadas foram comparadas com as posições simuladas e avaliadas a partir das métricas de erro: erro médio absoluto, a raiz do erro médio quadrático (RMSE), e o coeficiente de determinação (R^2) apresentaram os resultados

A raiz do erro médio quadrático fornece uma medida da magnitude média dos erros quadráticos. É calculado na Equação (5.4):

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (5.4)$$

em que n é o número total de amostras ou observações, y_i é o valor real da i -ésima observação no banco de dados e \hat{y}_i é o valor estimado ou predito pelo modelo para a i -ésima observação.

Na Figura 5.8, é apresentado o gráfico do RMSE para diferentes valores de K no KNN. O gráfico demonstra que, tanto para 0 dBm quanto para 15 dBm, o valor $K = 1$ minimizou o RMSE, com valores de 2,4448 metros para 0 dBm e 1,9004 metros para 15 dBm. Isso evidencia que, mesmo com diferentes potências de transmissão, o uso de um único vizinho no KNN ofereceu as estimativas mais precisas em termos de RMSE.

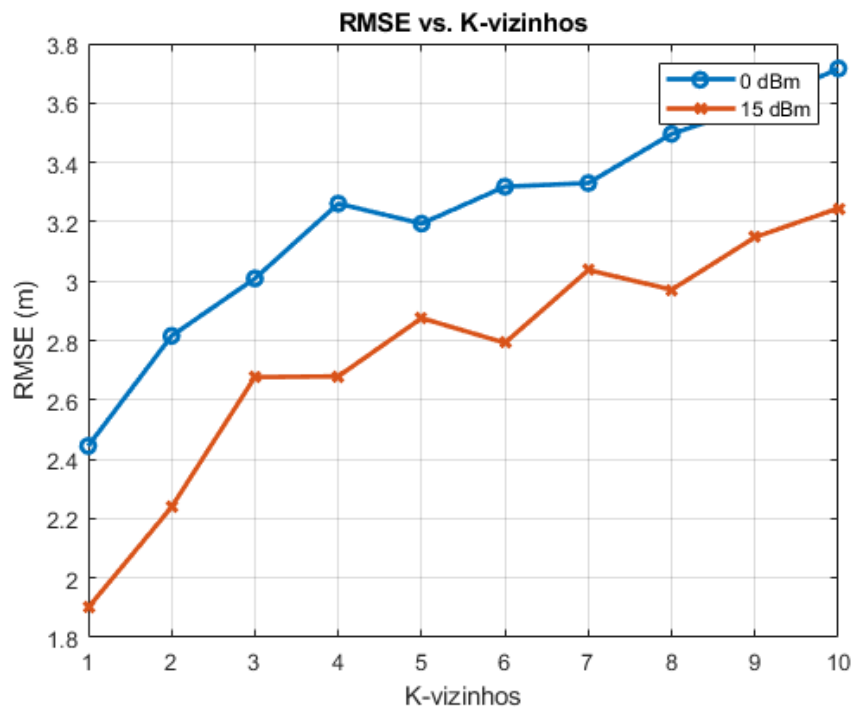


Figura 5.8 – Gráfico do RMSE para K-vizinhos

Enquanto a Figura 5.9 mostra a função de distribuição cumulativa do RMSE. Este gráfico é fundamental para avaliar a probabilidade acumulada do erro em diferentes níveis de RMSE, oferecendo uma perspectiva clara sobre a frequência de ocorrência de erros menores e maiores em ambos os cenários de potência.

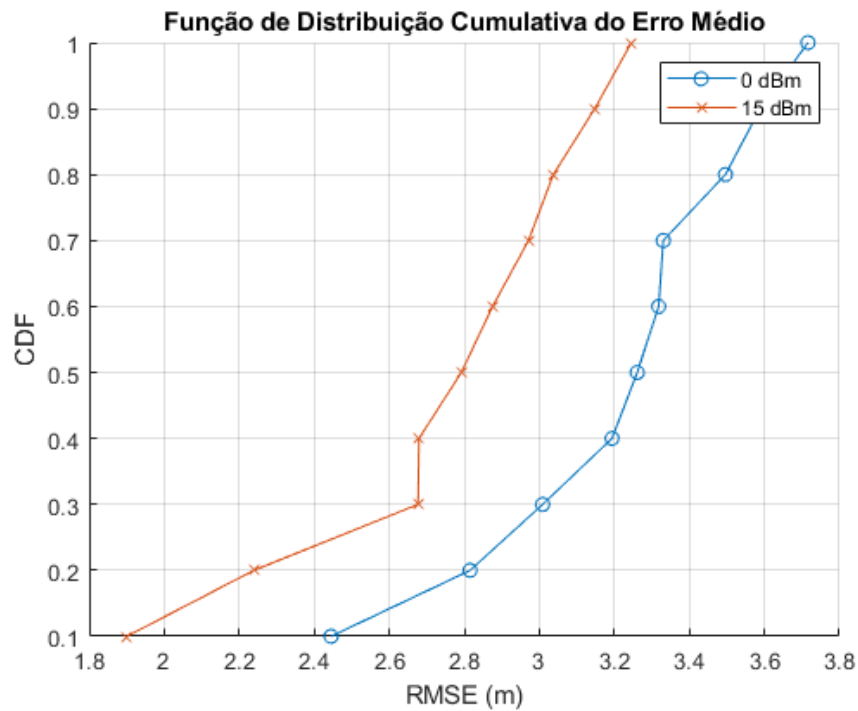


Figura 5.9 – Gráfico do CDF para RMSE

O erro médio absoluto fornece uma medida direta da magnitude média dos erros de previsão. O MAE é calculado como a média dos valores absolutos das diferenças entre os valores reais (y_i) e os valores previstos (\hat{y}_i) na Equação (5.2).

Além disso, o MAE pode ser avaliado por percentil para oferecer uma visão mais detalhada da distribuição dos erros. A análise do MAE por percentil examina o desempenho do modelo em diferentes quantis da distribuição dos erros.

Percentil	0 dBm	15 dBm
10°	0.4 m	0.2 m
50°	1.4 m	1.0833 m
90°	2.97 m	2.3 m

Tabela 5.2 – Tabela de valores MAE por percentil

A Tabela 5.2 apresenta o MAE por percentil (10°, 50°, e 90°) para as estimativas do modelo para 0 dBm e 15 dBm. Esses dados elucidam a distribuição dos erros ao longo dos diferentes percentis, proporcionando uma visão detalhada do desempenho do modelo em diferentes cenários. Já a Figura 5.10 apresenta o CDF para o MAE. Este gráfico complementa a análise do RMSE, permitindo uma avaliação detalhada da distribuição dos erros absolutos em diferentes percentis, e reforça a importância do valor $K = 1$ para minimizar os erros.

Por fim, o coeficiente de determinação (R^2) é uma métrica que indica a proporção da variância nas posições reais que é explicada pelas posições estimadas. O R^2 é calculado

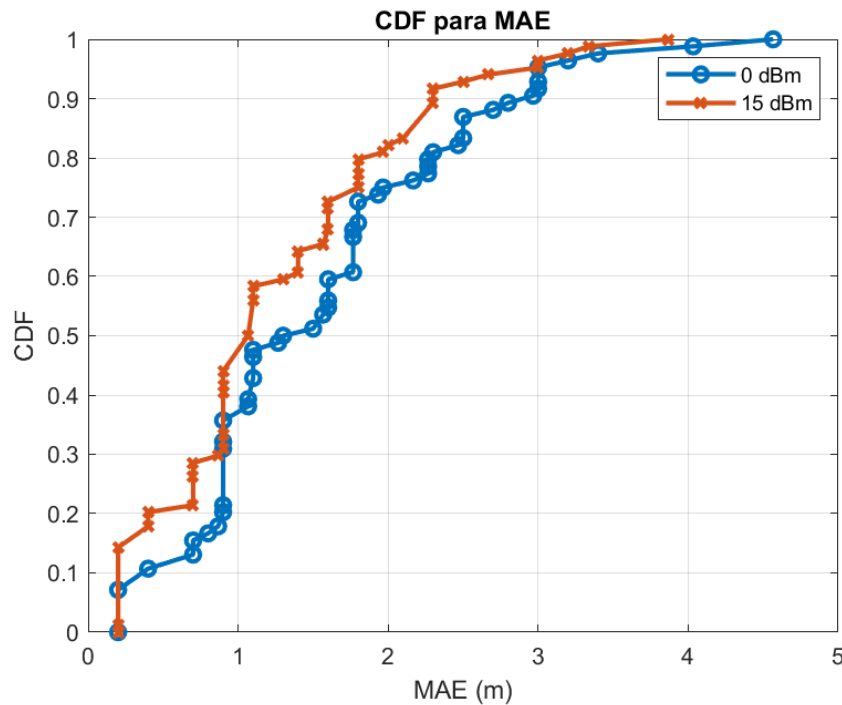


Figura 5.10 – Gráfico do CDF para MAE

utilizando a fórmula:

$$R^2 = 1 - \frac{SS_{\text{res}}}{SS_{\text{tot}}}, \quad (5.5)$$

visto que,

$$SS_{\text{res}} = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5.6)$$

e

$$SS_{\text{tot}} = \sum_{i=1}^n (y_i - \bar{y})^2, \quad (5.7)$$

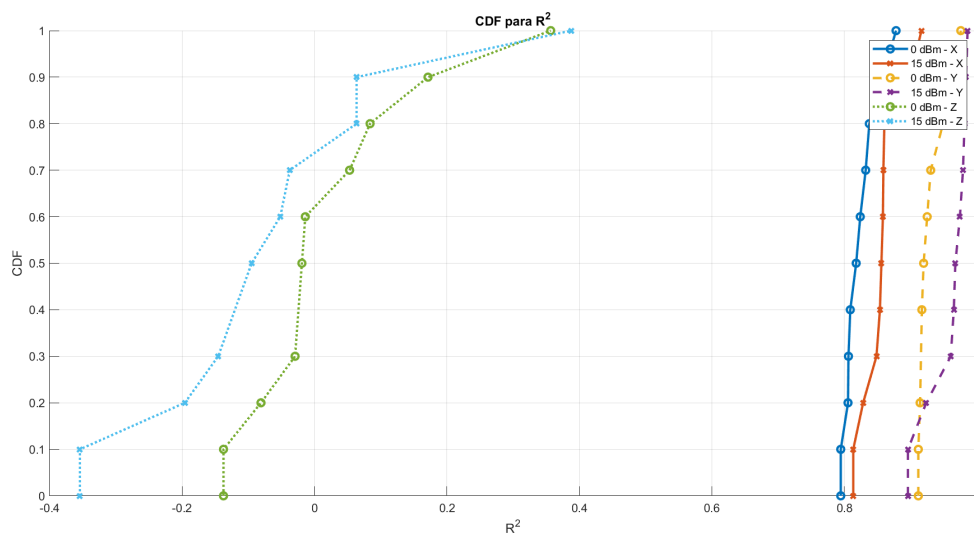
sendo y_i os valores calculados e armazenados na base de dados, \hat{y}_i os valores previstos pelo modelo e \bar{y} a média dos valores reais observados. O R^2 avalia o ajuste do modelo na previsão das coordenadas x , y e z . Um valor de R^2 próximo de 1 indica um bom ajuste, enquanto valores negativos ou próximos de 0 indicam que o modelo tem um desempenho ruim, diferentemente do MAE e o RMSE que fornecem medidas diretas da magnitude dos erros.

A Tabela 5.3 detalha os valores de R^2 por coordenada nos cenários de 0 dBm e 15 dBm. Observa-se que, em 15 dBm, os valores de R^2 variam consideravelmente entre as coordenadas, com um desempenho superior nas coordenadas X e Y , enquanto a coordenada Z apresenta um desempenho significativamente comparado as eixos X e Y . A informação apresentada pelos valores de R^2 corroboram com as métricas RMSE e MAE em relação a melhoria do algoritmo com o aumento da potência de transmissão.

Coordenada	0 dBm	15 dBm
X	0.87815	0.91644
Y	0.97593	0.98614
Z	0.35662	0.38765

Tabela 5.3 – Tabela de valores R^2 por coordenada

A Figura 5.11 ilustra o CDF para o coeficiente de determinação. O R^2 é uma métrica crucial que indica a proporção da variância nas posições simuladas que é explicada pelas posições estimadas. Este gráfico evidencia a capacidade do modelo de capturar a variabilidade nas posições ao longo de diferentes níveis de potência de transmissão.

Figura 5.11 – Gráfico do CDF para R^2

E, por último, a Figura 5.12 apresenta o gráfico de R^2 em função do número de vizinhos K utilizados no KNN. O gráfico mostra como o coeficiente de determinação varia com diferentes valores de K , reafirmando que o valor $K = 1$ proporciona o melhor ajuste para os cenários analisados, principalmente para a coordenada Z.

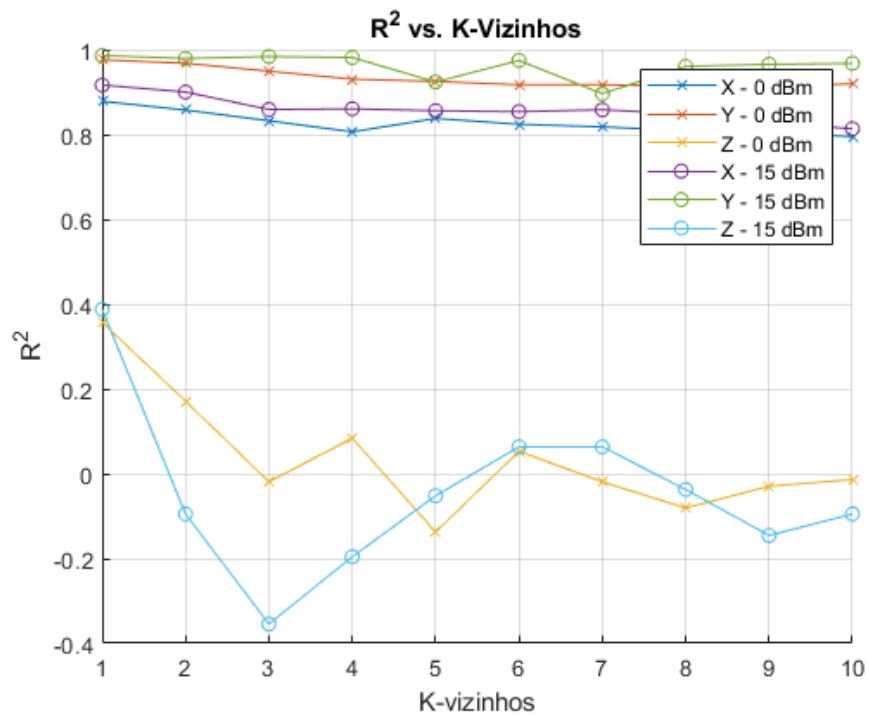


Figura 5.12 – Gráfico de R^2 para K-vizinhos

6 Conclusão

Portanto, neste estudo, foi apresentado um método de estimativa de Direção de Chegada utilizando um arranjo de antenas e a técnica de *beamforming* para reduzir os erros de multi percursos em um ambiente fechado. A viabilidade do método foi analisada por simulação, com base em métricas de erro, destacando a eficácia do processamento de sinais na melhoria da precisão das estimativas.

Ao comparar a eficiência dos pontos de acessos para estimar a direção de chegada dos sinais, observou-se que o ponto de acesso 1, localizado na sala menor da simulação, apresentou um erro menor que o ponto de acesso 4, localizado na sala maior, indicando que existe uma relação entre a área coberta por um AP e a precisão da estimação da DOA. Observa-se também que, em algumas posições, o usuário está na linha de visada de apenas um AP, e mesmo assim, o algoritmo conseguiu estimar a posição em 3 dimensões.

Em relação aos cenários de potência de transmissão, nota-se que o aumento de 0 dBm para 15 dBm resulta em uma pequena redução no erro absoluto médio da estimação da DOA, que conseqüentemente, reduz de 2,4 metros para 1,9 metros no RMSE de estimativa da posição, enquanto nos percentis mais altos, foi reduzido de 2,97 metros no percentil 90° para 2,3 metros no mesmo percentil. Esse resultado ressalta a robustez do modelo KNN em ambientes com sinais de maior qualidade, onde os valores da DOA são menos suscetíveis a interferências e ruídos, demonstrando a importância de um processamento de sinais eficiente.

Além disso, os resultados indicam que o uso de uma potência de transmissão mais alta pode ser uma estratégia eficaz para melhorar a precisão de sistemas de localização que empregam técnicas de processamento de sinais, como o KNN. No entanto, é crucial balancear essa escolha com as limitações de consumo energético e possíveis efeitos de interferência em cenários reais.

O modelo KNN apresentou desempenho consistente para a maioria das previsões, com erros aceitáveis na maioria dos cenários. A escolha do valor de K impactou diretamente o desempenho do modelo, tornando essencial a adaptação do algoritmo para validar todos os k -vizinhos e, conseqüentemente, minimizar os erros de previsão. A eficácia do processamento de sinais foi evidente na capacidade do modelo de reduzir o impacto de multi percursos, melhorando as estimativas de posição.

Os valores de R^2 demonstraram uma boa capacidade do modelo de explicar a variabilidade das posições reais nas coordenadas X e Y, no entanto, o modelo mostrou degradação de desempenho na coordenada Z. Essas limitações podem ser mitigadas com aprimoramentos no processamento de sinais, aumento no número de APs, variação do eixo Z na posição dos

APs ou com a aplicação de técnicas mais avançadas para estimar a posição do usuário.

Portanto, os resultados obtidos mostram que o modelo é eficaz na previsão de posições em ambientes fechados, utilizando processamento de sinais na DOA. Apesar dos desafios, como a presença de valores atípicos, posições com apenas 1 linha de visada, o modelo se mostrou promissor e pode ser aprimorado para aplicações em sistemas de localização em tempo real.

Trabalhos futuros podem explorar a integração de técnicas de filtragem, como filtros de Kalman, para suavizar as previsões e reduzir o impacto de valores atípicos. Também pode ser analisado a utilização de mais APs em diferentes posições, sua eficiência por metro quadrado e outras combinações de técnicas de estimação com diferentes modelos de transmissão que suportam ambientes fechados. Ademais, a investigação de modelos mais complexos, como redes neurais, pode contribuir para melhorar ainda mais a acurácia das estimativas de posição, especialmente quando combinados com processamento de sinais avançado.

Referências

- ADEGE A.B.; LIN, H. T. G. M. Y. Y. L. An indoor and outdoor positioning using a hybrid of supportvector machine and deep neural network algorithms. **Journal of Sensors**, 2021. Citado na p. 51.
- BLENDER. **Blender 3D**. [S.l.], 2002. Disponível em: <https://www.blender.org/>. Citado na p. 25.
- CHEW, W. C. **Lectures on Electromagnetic Field Theory**. [S.l.]: Purdue University, 2019. Citado nas pp. 17 e 18.
- DU P; ZHANG, S. C. C. Y. H. Z. W. Z. R. A. A. Y. Y. Experimental demonstration of 3d visible light positioning using received signal strength with low-complexity trilateration assisted by deep learning technique. **IEEE Access**, 2019. Citado na p. 50.
- FIERA GUSTAVO BISOGNIN, M. e. C. d. M. L. R. Ferramenta para localização em ambiente controlado utilizando mapa de sinais wireless. **Revista Iniciação Científica**, v. 12, n. 1, 2014, 2014. Citado na p. 13.
- FIRMO, A. S. e A. Desvendando 5g - beamforming e massive mimo. **Embedded UFCG**, 2020. Citado na p. 15.
- GEOK, T. K. *et al.* Review of indoor positioning: Radio wave technology. **Faculty of Engineering and Technology, Multimedia University, Melaka, Malaysia**, 2021. Citado nas pp. 13, 45 e 46.
- GITHUB. **Repositório do projeto**. [S.l.], 2024. Disponível em: https://github.com/araujoUnb/TCC-Gabriel_Vieira. Citado nas pp. 25, 26 e 33.
- GUERRA, A. Near-field tracking with large antenna arrays: Fundamental limits and practical algorithms. 2021. Citado nas pp. 13, 14 e 19.
- HOANG M.T.; YUEN, B. D. X. L. T. W. R. R. K. Recurrent neural networks for accurate rssi indoor localization. 2019. Citado na p. 51.
- KRISHNAVENI, V. *et al.* Beamforming for direction-of-arrival (doa) estimation-a survey. **International Journal of Computer Applications**, 2012. Citado nas pp. 28 e 29.
- LI GUISHENG LIAO, S. Z. S. W. C. An esprit-like algorithm for coherent doa estimation based on data matrix decomposition in mimo radar. **National Laboratory of Radar Signal Processing, Xidian University**, 2011. Citado nas pp. 48 e 49.
- LOPES IVANIL S. BONATTI, P. L. D. P. R. F. C. A.; ALVES, C. A. A doa estimator based on linear prediction and total least squares. 2002. Citado nas pp. 45, 49 e 50.
- MATLAB. [S.l.], 2024. Citado na p. 23.
- MOE T., Z. S. *et al.* Ultra-wideband technology and applications. 2017. Citado na p. 26.

-
- NJIMA W.; CHAFII, M. N. A. F. G. Deep learning based data recovery for localization. **IEEE Access**, 2020. Citado na p. 50.
- ORFANIDIS, S. J. **Electromagnetic Waves and Antennas**. [S.l.]: Rutgers University, 1999. Citado na p. 18.
- ORFANIDIS, S. J. **Electromagnetic Waves and Antennas**. [S.l.]: Rutgers University, 1999. Citado nas pp. 26 e 27.
- PAK, J. M. Switching extended kalman filter bank for indoor localization using wireless sensor networks. 2021. Citado nas pp. 45 e 46.
- PENG, X. *et al.* An improved weighted k-nearest neighbor algorithm for indoor localization. 2020. Citado na p. 23.
- WAWERU D. B. O. KONDITI, P. K. L. N. P. Performance analysis of music, root-music and esprit doa estimation algorithm. **World Academy of Science, Engineering and Technology International Journal of Electronics and Communication Engineering**, 2014. Citado nas pp. 18, 45 e 47.
- WIN, M. Z. A theoretical foundation of network localization and navigation. 2017. Disponível em: <https://winslab.lids.mit.edu/wp-content/papercite-data/pdf/winshedai-j18.pdf>. Citado na p. 13.
- YANG T. CABANI, A. C. H. A survey of recent indoor localization scenarios and methodologies. **Sensors**, 2021. Citado nas pp. 13, 14, 15, 18, 45 e 50.
- YUN, Z.; ISKANDER, M. F. Ray tracing for radio propagation modeling: Principles and applications. 2015. Disponível em: <https://ieeexplore.ieee.org/document/7152831>. Citado nas pp. 15 e 25.
- ZHANG, S. *et al.* Learning k for knn classification. **Guangxi Normal University**, 2017. Citado na p. 23.
- ZHOU, X. *et al.* Accurate doa estimation with adjacent angle power difference for indoor localization. 2020. Citado na p. 26.

Apêndices

Apêndice A – Primeiro Apêndice

A.1 Técnicas baseadas em modelos estatísticos e algoritmos de estimação

A modelagem de transmissão para técnicas de estimativa de direção de chegada, como soma e diferença, MUSIC, ESPRIT e mínimos quadrados, visa representar o sinal recebido levando em consideração o comportamento multi percurso em ambientes fechados. Esses métodos partem da premissa de que o sinal transmitido é afetado por múltiplas reflexões e difrações, criando diversos caminhos com diferentes atrasos, amplitudes e fases. (Yang T. Cabani, 2021)

O modelo matemático assume que o sinal recebido em cada antena de um arranjo é uma combinação linear das respostas dos diferentes caminhos, modulada pelos parâmetros associados ao ângulo de chegada e aos atrasos. A técnica de Diferença de Tempo de Chegada foca na diferença de tempo entre a chegada dos sinais em diferentes antenas. (Pak, 2021) Em contraste, os algoritmos MUSIC e ESPRIT baseiam-se na análise dos subespaços para estimar os ângulos de chegada. (Waweru D. B. O. Konditi, 2014) Já o método dos Mínimos Quadrados ajusta os parâmetros para minimizar o erro em relação ao modelo. (Lopes Ivanil S. Bonatti; Alves, 2002)

Essas abordagens são cruciais em ambientes fechados, onde os efeitos de múltiplos caminhos são mais pronunciados. Cada técnica oferece uma solução robusta para a determinação precisa da DOA, considerando as complexidades impostas pelos múltiplos trajetos e variabilidades no ambiente. (Yang T. Cabani, 2021)

A.1.1 Método da diferença do tempo de chegada

O método usa as diferenças de tempo de chegada dos sinais entre antenas para estimar a direção de chegada. O modelo matemático inclui a diferença de tempo de chegada entre antenas e a formação de feixe ajustada com base nesse atraso. O objetivo final é resolver um sistema de equações para estimar a origem do sinal (Geok *et al.*, 2021).

Para um sinal transmitido que chega a diferentes antenas com diferentes atrasos de tempo, o modelo pode ser descrito da seguinte forma:

Se o sinal transmitido é $s(t)$, e o sinal recebido na antena i é $r_i(t)$, então:

$$r_i(t) = s(t - \tau_i) + n_i(t),$$

em que, τ_i representa o atraso de tempo do sinal na antena i , enquanto $n_i(t)$ corresponde ao ruído aditivo na antena i . (Pak, 2021).

Se temos N antenas, a diferença de tempo de chegada entre duas antenas i e j é dada por:

$$\Delta\tau_{ij} = \tau_i - \tau_j.$$

(Pak, 2021).

Com base na diferença de tempo de chegada entre diferentes pares de antenas, pode-se calcular a diferença de tempo de chegada relativa. Se o sinal é recebido em um ponto de coordenadas (x, y, z) , e as antenas estão localizadas em pontos (x_i, y_i, z_i) , a diferença de tempo de chegada pode ser expressa como:

$$\Delta\tau_{ij} = \frac{d_{ij}}{c} = \frac{\sqrt{(x - x_i)^2 + (y - y_i)^2 + (z - z_i)^2} - \sqrt{(x - x_j)^2 + (y - y_j)^2 + (z - z_j)^2}}{c},$$

na qual d_{ij} é a diferença de distância entre os pontos de recepção das antenas i e j , e c é a velocidade do sinal, que pode ser a velocidade da luz ou a velocidade do som, dependendo do tipo de sinal (Pak, 2021).

O objetivo do método é calcular a direção de chegada dos sinais. Para isso, a diferença de tempo de chegada é utilizada para ajustar o padrão de formação de feixe. O sinal de cada antena é ajustado para corresponder ao tempo de chegada relativo, e a formação de feixe é empregada para determinar a direção do sinal (Geok et al., 2021).

A formação de feixe ajustada com base no TDOA pode ser descrita por:

$$r_i(t) = \sum_{j \neq i} (s(t - \tau_i + \Delta\tau_{ij}) + n_i(t)),$$

pois, a diferença de tempo de chegada é incorporada para ajustar o sinal recebido em cada antena. (Pak, 2021)

Usando a diferença de tempo de chegada, pode-se formar um sistema de equações baseado na geometria das antenas e no atraso de tempo. A resolução desse sistema permite determinar a direção de chegada do sinal a partir das diferenças de tempo observadas entre os pares de antenas. (Geok et al., 2021)

A.1.2 Algoritmo MUSIC

O modelo de transmissão para o algoritmo MUSIC é baseado na decomposição do espaço de sinais e ruídos, sendo utilizado para estimar a direção de chegada dos sinais incidentes em um arranjo de antenas. Esse modelo considera um cenário com várias fontes de sinal e explora a estrutura espacial do sinal recebido. (Waweru D. B. O. Konditi, 2014)

Considere M elementos de antena e K fontes de sinal incidentes. O sinal recebido em cada elemento de antena pode ser descrito pela seguinte equação:

$$\mathbf{y}(t) = \mathbf{A}(\theta)\mathbf{s}(t) + \mathbf{n}(t),$$

em que $\mathbf{y}(t)$ representa o vetor de sinais recebidos, com dimensão $M \times 1$. A matriz $\mathbf{A}(\theta)$ é a matriz de respostas das antenas (ou matriz de direção), de dimensão $M \times K$, cujas colunas correspondem aos vetores de resposta das antenas para cada ângulo θ_k . O vetor $\mathbf{s}(t)$ é o vetor de sinais transmitidos pelas K fontes, com dimensão $K \times 1$. Já $\mathbf{n}(t)$ é o vetor de ruído aditivo, de dimensão $M \times 1$, assumido como ruído aditivo gaussiano com média zero e variância σ^2 .

O algoritmo MUSIC baseia-se na matriz de covariância \mathbf{R}_y do sinal recebido, que é dada por:

$$\mathbf{R}_y = \mathbb{E}[\mathbf{y}(t)\mathbf{y}^H(t)] = \mathbf{A}(\theta)\mathbf{R}_s\mathbf{A}^H(\theta) + \sigma^2\mathbf{I},$$

visto que, $\mathbf{R}_s = \mathbb{E}[\mathbf{s}(t)\mathbf{s}^H(t)]$ é a matriz de covariância dos sinais, e $\sigma^2\mathbf{I}$ representa o ruído aditivo, com σ^2 sendo a potência do ruído e \mathbf{I} a matriz identidade (Waweru D. B. O. Konditi, 2014).

A matriz \mathbf{R}_y é decomposta em subespaços de sinal e ruído utilizando a decomposição em valores singulares (SVD) ou decomposição espectral. O algoritmo MUSIC identifica o subespaço do ruído e o utiliza para estimar os ângulos θ correspondentes às direções de chegada dos sinais. A função espectral MUSIC é dada por:

$$P_{\text{MUSIC}}(\theta) = \frac{1}{\mathbf{a}^H(\theta)\mathbf{E}_n\mathbf{E}_n^H\mathbf{a}(\theta)},$$

sendo, $\mathbf{a}(\theta)$ é o vetor de resposta da antena para o ângulo θ , e \mathbf{E}_n é a matriz formada pelos vetores próprios do subespaço do ruído (Waweru D. B. O. Konditi, 2014).

Os picos da função espectral $P_{\text{MUSIC}}(\theta)$ correspondem aos ângulos de chegada dos sinais, fornecendo estimativas de alta resolução (Waweru D. B. O. Konditi, 2014).

A.1.3 Algoritmo ESPRIT

O algoritmo ESPRIT é uma técnica eficiente para estimar a direção de chegada de sinais, utilizando a invariância rotacional das subespaços de sinal em arranjos de antenas. Esse método é conhecido por sua eficiência computacional e por não exigir uma busca exaustiva por ângulos, como em outros algoritmos de alta resolução. (Li Guisheng Liao, 2011)

Considere um arranjo de antenas composto por M elementos e K fontes de sinal incidentes. O modelo de sinal recebido em um instante de tempo t pode ser representado também por:

$$\mathbf{y}(t) = \mathbf{A}(\theta)\mathbf{s}(t) + \mathbf{n}(t).$$

O algoritmo ESPRIT explora a estrutura de invariância rotacional entre subarranjos deslocados do conjunto de antenas. Se o arranjo de antenas for dividido em dois subarranjos deslocados por uma distância fixa, a relação entre os vetores de resposta dos subarranjos pode ser expressa como:

$$\mathbf{A}_2(\theta) = \mathbf{A}_1(\theta)\mathbf{\Psi},$$

onde $\mathbf{\Psi}$ é uma matriz diagonal que contém informações sobre os ângulos θ_k e o deslocamento entre os subarranjos. Essa relação é fundamental para a estimativa dos DOAs. (Li Guisheng Liao, 2011)

O algoritmo ESPRIT utiliza a decomposição da matriz de covariância $\mathbf{R}_y = \mathbb{E}[\mathbf{y}(t)\mathbf{y}^H(t)]$ para separar os subespaços de sinal e ruído. A partir do subespaço de sinal, duas submatrizes \mathbf{S}_1 e \mathbf{S}_2 , correspondentes aos subarranjos deslocados, são extraídas. A matriz de rotacionalidade $\mathbf{\Phi}$ é então estimada como: (Li Guisheng Liao, 2011)

$$\mathbf{\Phi} = \mathbf{S}_1^\dagger \mathbf{S}_2,$$

na qual \mathbf{S}_1^\dagger é a pseudoinversa de \mathbf{S}_1 .

Os autovalores de $\mathbf{\Phi}$ estão diretamente relacionados aos ângulos de chegada θ_k . Os DOAs são calculados a partir dos autovalores λ_k de $\mathbf{\Phi}$ como:

$$\theta_k = \arcsin\left(\frac{\angle \lambda_k}{d}\right),$$

em que d é a distância entre as antenas e $\angle \lambda_k$ representa a fase do autovalor λ_k . (Li Guisheng Liao, 2011)

O ESPRIT é computacionalmente eficiente, pois evita a necessidade de uma busca por ângulos. Além disso, o uso da invariância rotacional simplifica a estimativa dos DOAs, tornando o algoritmo robusto e adequado para aplicações em tempo real. (Li Guisheng Liao, 2011)

A.1.4 Método de mínimos quadrados

O Método de Mínimos Quadrados é uma técnica de estimativa que minimiza o erro quadrático entre os sinais recebidos e os sinais esperados. Esta abordagem é amplamente utilizada para a estimação da direção de chegada quando os sinais podem ser modelados de forma linear (Lopes Ivanil S. Bonatti; Alves, 2002).

Para um arranjo de antenas com M elementos e K fontes de sinal, o sinal recebido $\mathbf{y}(t)$ pode ser modelado também como:

$$\mathbf{y}(t) = \mathbf{A}\mathbf{s}(t) + \mathbf{n}(t).$$

O objetivo do método de mínimos quadrados é encontrar a matriz $\hat{\mathbf{A}}$ que minimiza a diferença entre o vetor de sinais recebidos e os sinais esperados. O problema é formulado como:

$$\hat{\mathbf{A}} = \arg \min_{\mathbf{A}} \|\mathbf{y}(t) - \mathbf{A}\mathbf{s}(t)\|^2,$$

no qual $\|\cdot\|^2$ denota a norma euclidiana ao quadrado (Lopes Ivanil S. Bonatti; Alves, 2002).

Para resolver este problema, o método dos mínimos quadrados fornece a solução:

$$\hat{\mathbf{A}} = \mathbf{Y}\mathbf{S}^+,$$

com \mathbf{Y} sendo a matriz de dados recebidos, composta pelos vetores $\mathbf{y}(t)$ observados, e \mathbf{S}^+ a pseudo inversa de \mathbf{S} , onde \mathbf{S} é a matriz dos sinais transmitidos (Lopes Ivanil S. Bonatti; Alves, 2002).

Após a estimação da matriz $\hat{\mathbf{A}}$, os ângulos de chegada podem ser extraídos resolvendo o sistema:

$$\mathbf{y}(t) = \hat{\mathbf{A}}\mathbf{s}(t).$$

Os valores estimados dos ângulos de chegada $\hat{\theta}_k$ podem ser obtidos através da decomposição da matriz $\hat{\mathbf{A}}$ e da identificação dos ângulos correspondentes aos vetores de resposta de antena estimados (Lopes Ivanil S. Bonatti; Alves, 2002).

O Método de Mínimos Quadrados é eficaz em cenários onde o modelo linear dos sinais é adequado e o número de antenas é suficiente para capturar a variabilidade dos sinais. Ele fornece uma solução otimizada que minimiza o erro quadrático e é amplamente utilizado em sistemas de comunicação e radares para a estimativa da DOA (Lopes Ivanil S. Bonatti; Alves, 2002).

A.2 Técnicas de processamento adaptativo e machine learning

A.2.1 Redes Neurais e Deep Learning

As redes neurais e técnicas de *deep learning* são cada vez mais aplicadas à estimativa de DOA devido à sua capacidade de aprender representações complexas e não lineares dos dados. (Yang T. Cabani, 2021)

A.2.1.1 Redes Neurais Artificiais (ANNs)

As ANNs consistem em camadas de neurônios artificiais que podem modelar complexas relações entre os dados de entrada e as saídas. Para problemas de DOA, uma rede neural pode ser treinada para mapear os sinais recebidos em estimativas precisas da direção de chegada. A arquitetura da rede pode incluir camadas densas, funções de ativação não lineares e técnicas de regularização para melhorar a precisão e evitar o sob reajuste. (Du P; Zhang, 2019)

A.2.1.2 Redes Neurais Convolucionais (CNNs)

As CNNs são uma classe de redes neurais especialmente eficazes em capturar padrões espaciais e temporais, sendo úteis para a análise de dados de sinais com estrutura espacial complexa. Em problemas de DOA, as CNNs podem ser usadas para extrair características relevantes dos sinais recebidos e melhorar a estimativa da direção de chegada. (Njima W.; Chafii, 2020)

A.2.1.3 Redes Neurais Recorrentes (RNNs) e LSTM (*Long Short-Term Memory*)

As RNNs e suas variantes, como LSTM (*Long Short-Term Memory*), são adequadas para lidar com dados sequenciais e temporais. Essas redes podem modelar a dependência temporal dos sinais recebidos e prever a DOA com base em sequências temporais de sinais. As LSTMs são particularmente eficazes em capturar longas dependências temporais, o que é útil em cenários onde a informação sobre a direção de chegada pode variar ao longo do tempo. (Hoang M.T.; Yuen, 2019)

A.2.2 Métodos Baseados em Máquinas de Vetores de Suporte (SVM)

Máquinas de Vetores de Suporte são usadas para problemas de classificação e regressão. No contexto da estimativa de DOA, SVM pode ser aplicada para classificar diferentes ângulos de chegada com base nas características extraídas dos sinais recebidos. O modelo é treinado para encontrar um hiperplano que separa as diferentes classes de ângulos de chegada com base nos dados disponíveis. (Adege A.B.; Lin, 2021)