



UNIVERSIDADE FEDERAL DO AMAZONAS  
FACULDADE DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

## Estimação do Ângulo de Chegada utilizando Bluetooth 5.1 e redes profundas

Lennon Brandão Freitas do Nascimento

Manaus – Amazonas

Setembro de 2023

Lennon Brandão Freitas do Nascimento

## **Estimação do Ângulo de Chegada utilizando Bluetooth 5.1 e redes profundas**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas de Controle e de Automação Modernos.

Prof. D.Sc. Celso Barbosa Carvalho (orientador)

## Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

N244e Nascimento, Lennon Brandão Freitas  
Estimação do Ângulo de Chegada utilizando Bluetooth 5.1 e  
redes profundas. / Lennon Brandão Freitas Nascimento . 2023  
67 f.: il. color; 31 cm.

Orientador: Celso Barbosa Carvalho  
Dissertação (Mestrado em Engenharia Elétrica) - Universidade  
Federal do Amazonas.

1. Localização de Direção. 2. Bluetooth. 3. Ângulo de Chegada. 4.  
Redes profundas. 5. Orientação de Objetos. I. Carvalho, Celso  
Barbosa. II. Universidade Federal do Amazonas III. Título

# LENNON BRANDÃO FREITAS DO NASCIMENTO

## ESTIMAÇÃO DO ÂNGULO DE CHEGADA UTILIZANDO BLUETOOTH 5.1 E REDES PROFUNDAS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Amazonas, como requisito parcial para obtenção do título de Mestre em Engenharia Elétrica na área de concentração Controle e Automação de Sistemas.

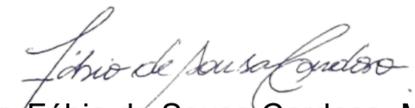
Aprovada em 22 de setembro de 2023.

### BANCA EXAMINADORA

  
Prof. Dr. Celso Barbosa Carvalho  
Presidente

Universidade Federal do Amazonas

  
Prof. Dr. Jozias Parente de Oliveira, Membro  
Universidade do Estado do Amazonas

  
Prof. Dr. Fábio de Sousa Cardoso, Membro  
Universidade do Estado do Amazonas

Resumo da Dissertação apresentada à UFAM como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica

## ESTIMAÇÃO DO ÂNGULO DE CHEGADA UTILIZANDO BLUETOOTH 5.1 E REDES PROFUNDAS

Lennon Brandão Freitas do Nascimento

Orientadores: Prof. D.Sc. Celso Barbosa Carvalho

Programa: Pós-Graduação em Engenharia Elétrica

Os sistemas de posicionamento *indoor* ganharam destaque impulsionados pelo aumento do uso de dispositivos móveis e pela necessidade de localização ou orientação precisa em diversos setores. O Bluetooth Low Energy (BLE) 5.1 destaca-se para tarefas de orientação espacial devido ao baixo consumo energético e à disponibilidade de recursos para obtenção do ângulo de chegada (AoA), por meio de amostras em quadratura IQ. O processamento dessas amostras é fundamental para a estimação do AoA. No entanto, a literatura carece de bases de dados desses sinais de rádio com amostras reais além de ainda não dispor de estudos aplicando conceitos de *machine learning* e, especificamente, de *deep learning*, para estimar o ângulo de chegada. Nesse contexto, este trabalho propõe o uso de técnicas de *deep learning* para a estimação do AoA por meio de um modelo de regressão aplicado a sistemas de orientação *indoor* baseados em Bluetooth utilizando amostra reais coletadas. Apresentamos todo o cenário de coleta e os procedimentos necessários para a validação das amostras e do modelo proposto. Através da métrica de desempenho *Mean Absolute Error* (MAE), constatamos um erro de  $1,38^\circ$  na estimação do ângulo de  $135^\circ$  e, no geral, o modelo proposto apresentou um MAE de  $1,87^\circ$ .

Palavras-chave: Localização de Direção; Bluetooth; Ângulo de Chegada; Redes profundas; Orientação de Objetos.

Abstract of Dissertation presented to UFAM as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering

## ANGLE OF ARRIVAL ESTIMATION USING BLUETOOTH 5.1 AND DEEP NETWORKS

Lennon Brandão Freitas do Nascimento

Advisors: Prof. D.Sc. Celso Barbosa Carvalho

Department: Postgraduate in Electrical Engineering

*Indoor* positioning systems have gained prominence driven by the increased use of mobile devices and the need for precise location or guidance in various sectors. Bluetooth Low Energy (BLE) 5.1 stands out for spatial orientation tasks due to its low energy consumption and the availability of resources for obtaining the angle of arrival (AoA), through IQ quadrature samples. Processing these samples is critical to AoA investigation. However, the literature lacks databases of these radio signals with real samples, in addition to not yet having studies applying concepts of *machine learning* and, specifically, *deep learning*, to estimate the angle of arrival. In this context, this work proposes the use of *deep learning* techniques to study AoA through a regression model applied to Bluetooth-based *indoor* guidance systems using real collected samples. We present the entire collection scenario and the procedures necessary to validate the samples and the proposed model. Using the *Mean Absolute Error* (MAE) performance metric, we found an error of  $1.38^\circ$  in estimating the  $135^\circ$  angle and, overall, the proposed model presented an MAE of  $1.87^\circ$ .

**Keywords:** Direction Finding; Bluetooth; Angle of Arrival; Deep Learning; Object Orientation.

# Lista de Figuras

3.1	Representação de um IPS com RNs recebendo ou emitindo sinais para a localização. Fonte: Própria. . . . .	17
3.2	Diferença de fase para cálculo do ângulo de chegada. Fonte: [1]. . . . .	19
3.3	Topologias de <i>arrays</i> de antena. (a) Topologia linear, (b) Topologia retangular e (c) Topologia circular. Fonte: Própria. . . . .	20
3.4	Pilha do protocolo BLE. Fonte: Adaptado [2]. . . . .	21
3.5	Espectro de frequência do BLE. Fonte: Adaptado [2]. . . . .	22
3.6	Máquina de estado da camada de enlace. Fonte: Adaptado [3]. . . . .	23
3.7	Formato de pacote <i>Bluetooth</i> . Fonte: [4]. . . . .	24
3.8	Arquitetura para realização do método AoA. Fonte: Adaptado [1]. . . . .	25
3.9	Temporização do CTE. Fonte: Adaptado [3,4]. . . . .	26
3.10	Janelas de amostragem para blocos de $2\mu s$ . Fonte: Adaptado [3]. . . . .	26
3.11	Comandos de configurações do HCI e transmissão do CTE no modo <i>connectionless</i> . Fonte: [1]. . . . .	27
3.12	Comandos de configurações do HCI e recepção do CTE no modo <i>connectionless</i> . Fonte: [1]. . . . .	28
3.13	Arquitetura de rede convolutiva LeNet. Fonte: [5]. . . . .	29
3.14	Três <i>kernels</i> aplicados à matrizes <i>Red</i> , <i>Green</i> e <i>Blue</i> . Fonte: [6]. . . . .	31
3.15	Exemplo de <i>padding</i> . Fonte: [7]. . . . .	31
3.16	<i>Max-pooling</i> com filtros de ordem 2. Fonte: [6]. . . . .	32
3.17	Kit de desenvolvimento nRF52833. Fonte: Adaptado [8]. . . . .	34
3.18	<i>Array</i> de antenas modelo PCA20054 do fabricante Nordic Semiconductor acoplado ao suporte. (a) Vista superior. (b) Vista inferior. Fonte: Própria. . . . .	35
3.19	Representação das entradas e saída do <i>array</i> de antenas. Fonte: Própria. . . . .	36

4.1	Etapas utilizadas no desenvolvimento, validação e avaliação de desempenho . . . . .	38
4.2	Configuração de conexões para validação do <i>array</i> . . . . .	39
4.3	Realização da validação de uma antena individual do <i>array</i> . . . . .	40
4.4	Diagrama de conexões entre os dispositivos . . . . .	41
4.5	(a)Laboratório B18 da Escola Superior de Tecnologia. (b) Elementos utilizados e suas conexões. . . . .	42
4.6	Vistas do Transmissor acoplado ao tripé. (a)Lateral esquerda. (b) Lateral direita. (c)Superior. . . . .	43
4.7	Planta baixa com indicações dos pontos de coleta e ponto central. . .	44
4.8	Vista do laboratório B18 com dispositivos de coleta. . . . .	44
4.9	Pré-processamento da base de dados. . . . .	47
4.10	Representação gráfica das amostras I e Q. . . . .	48
4.11	Formato dos dados de entrada do modelo de regressão proposto. . . .	48
4.12	Arquitetura proposta. . . . .	50
5.1	Balanceamento das amostras da base e separação para treino, validação e teste . . . . .	52
5.2	Evolução do MAE no decorrer das épocas para o Modelo proposto . .	53
5.3	Comparativo entre as Predições do modelo e valores esperados . . . .	54
5.4	Características das amostras preditas . . . . .	55
5.5	Erro absoluto e erro absoluto médio por ângulo . . . . .	56

# Lista de Tabelas

2.1	Trabalhos que utilizam técnicas de RF para Posicionamento . . . . .	11
2.2	Trabalhos que empregam redes profundas para DOA . . . . .	12
4.1	Redes Wi-Fi na faixa de 2,4GHz no laboratório . . . . .	45
4.2	Quantidade de linhas por arquivo de cada ponto de coleta da base de dados. . . . .	46
4.3	Parte das amostras IQ correspondente a um pacote <i>bluetooth</i> . . . . .	47
4.4	Detalhamento do Modelo 1 . . . . .	50

# Lista de Nomenclatura

AoA	<i>Angle of arrival</i>
BLE	<i>Bluetooth Low Energy</i>
DoA	<i>Direction of arrival</i>
FTM	<i>Fine Timing Measurement</i>
IPS	<i>Indoor Position System</i>
MAE	<i>Mean Absolute Error</i>
RF	Rádio Frequência
RFID	<i>Radio Frequency Identification</i>
RSS	<i>Radio Signal Strenght</i>
RTLS	<i>Real-time locating system</i>
SNR	<i>Signal-to-noise ratio</i>
ToA	<i>Time of arrival</i>
UWB	<i>ultra-wide-band</i>
VHF	<i>Very High Frequency</i>

# Sumário

<b>Lista de Figuras</b>	<b>I</b>
<b>Lista de Tabelas</b>	<b>IV</b>
<b>Lista de Nomenclatura</b>	<b>V</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Objetivo Geral . . . . .	4
1.2 Objetivos Específicos . . . . .	4
1.3 Estrutura da Dissertação . . . . .	4
<b>2 Revisão de literatura</b>	<b>6</b>
2.1 Sistemas baseados em Rádio Frequência . . . . .	6
2.2 <i>Deep Learning</i> aplicado aos métodos de <i>Direction of Arrival</i> . . . . .	11
2.3 Discussão dos trabalhos relacionados . . . . .	12
<b>3 Fundamentos e materiais</b>	<b>16</b>
3.1 Sistemas de posicionamento <i>indoor</i> . . . . .	16
3.1.1 Técnicas para localização <i>indoor</i> . . . . .	18
3.2 Radio Direction Finding . . . . .	18
3.2.1 Ângulo de chegada . . . . .	18
3.2.2 Topologia de <i>array</i> de antenas . . . . .	19
3.3 <i>Bluetooth</i> . . . . .	20
3.3.1 <i>Stack</i> BLE . . . . .	21
3.3.2 Camada física . . . . .	21
3.3.3 Camada de enlace . . . . .	22
3.3.4 Técnica de <i>Direction Finding</i> com <i>Bluetooth</i> . . . . .	24

3.3.5	Configurações e procedimentos para uso da técnica . . . . .	27
3.4	Redes Neurais convolucionais . . . . .	29
3.4.1	Camada de Convolução . . . . .	30
3.4.2	Filtro . . . . .	30
3.4.3	<i>Padding</i> . . . . .	31
3.4.4	Camada de Pooling . . . . .	31
3.4.5	Camada Densa . . . . .	32
3.4.6	Função de Ativação ReLU . . . . .	32
3.4.7	Métodos de otimização . . . . .	33
3.4.8	Métrica de avaliação . . . . .	33
3.5	Dispositivos de <i>Hardware</i> . . . . .	34
3.5.1	Kit de desenvolvimento nRF52833 . . . . .	34
3.5.2	<i>Array</i> de antenas . . . . .	35
<b>4</b>	<b>Metodologia</b>	<b>37</b>
4.1	Validação do <i>array</i> de antenas . . . . .	38
4.2	Criação da base de dados . . . . .	40
4.2.1	Configuração de conexões dos dispositivos . . . . .	40
4.2.2	Cenário da coleta de dados . . . . .	41
4.2.3	Metodologia da coleta de dados . . . . .	45
4.3	Definição do ambiente computacional . . . . .	46
4.4	Pré-processamento dos dados coletados . . . . .	46
4.5	Definição do modelo de regressão . . . . .	49
4.6	Parametrização do modelo . . . . .	50
4.7	Avaliação de desempenho . . . . .	51
<b>5</b>	<b>Resultados e Discussões</b>	<b>52</b>
<b>6</b>	<b>Conclusões</b>	<b>59</b>
	<b>Referências Bibliográficas</b>	<b>61</b>

# Capítulo 1

## Introdução

Os sistemas de posicionamento *indoor* (*Indoor Position System* - IPS) têm sido amplamente estudados nas últimas décadas, tendo aplicações em setores como saúde, indústria, entre outros [9–12]. O aumento da popularidade de *smartphones* e dispositivos vestíveis com recursos de comunicação sem fio, tem atraído o interesse em aplicações e melhorias de técnicas de localização e rastreamento. [10]

Os IPSs aplicam diferentes técnicas ao sinal de RF (Radio Frequência), tais como a trilateração, a triangulação ou o *fingerprint*. A trilateração e a triangulação se baseiam na medição de distâncias e ângulos do objeto a ser localizado, com relação a outros objetos com localização conhecida. A técnica de *fingerprint* por sua vez é utilizada para criar um mapa do ambiente, correlacionando os locais do mapa com características dos sinais medidos em cada local. As principais características do sinal utilizadas para criar o mapa de *fingerprint* incluem a intensidade do sinal recebido, *Received Signal Strength Indicator* (RSSI), o tempo de chegada, *Time of Arrival* (TOA) e a direção de chegada, *Direction of arrival* (DOA). Comenta-se que as técnicas baseadas em RSSI não requerem processamento de sinal tão preciso e complexo quanto as técnicas de TOA e DOA, contudo, o RSSI normalmente é utilizado em sistemas de posicionamento de menor precisão [13–16].

Em relação as tecnologias de comunicação, o (*Radio Frequency Identification*), *ultra-wideband* (UWB), Bluetooth e WiFi são muito utilizadas nos IPSs [17–19]. Os IPSs que utilizam a tecnologia Bluetooth de baixa energia, Bluetooth *Low Energy* (BLE), apresentam vantagens em termos de disponibilidade, eficiência energética, e escalabilidade, com exceção do custo e da precisão [18].

Em [20], os autores propuseram um hardware compacto e economicamente viável para o *beacon* BLE, a fim de mitigar o problema do custo de implementação. Contudo, a melhoria da precisão de localização foi uma situação deixada em aberto pelos autores.

Uma das abordagens promissoras para a melhoria da precisão da localização *indoor* é a técnica DoA, também conhecida como *Angle of arrival* (AoA), que envolve a medição do ângulo de chegada do sinal em um dispositivo receptor. Atualmente, a técnica é estudada e aplicada em sistemas que utilizam as tecnologias de Wi-Fi, Bluetooth e RFID [21–23]. A utilização do AoA foi introduzida no Bluetooth 5.1, proporcionando avanços em termos de precisão e confiabilidade [3].

O AoA no Bluetooth 5.1 é baseado na medição da diferença de fase de chegada do sinal Bluetooth em várias antenas receptoras. Ao usar múltiplas antenas receptoras, o dispositivo é capaz de realizar amostragem das componentes IQ do sinal e, com isso estimar a direção em que ele está chegando com base nas diferenças de fase entre as antenas.

A respeito da camada física para a implementação do AoA utilizando o Bluetooth, vale ressaltar que nos últimos anos vem sendo difundidos *arrays* de antenas construídos para sinais de 2.4GHz, porém há poucos trabalhos na literatura que os utilizam. Em sua maioria, os trabalhos que realizam testes com AoA utilizando o Bluetooth implementam modelagem matemática da antena, do sinal do transmissor, do canal e do receptor para a realização da estimação do ângulo a partir dessas informações [22, 24].

Em relação ao processamento de amostras IQ, trata-se de um fator determinante para o correto funcionamento da aplicação que utilize a técnica de AoA com o Bluetooth. De acordo com a documentação técnica apresentada em [25], o processamento das amostras IQ pode assumir abordagem matemática simples ou até mesmo o cálculo de vários ângulos combinados com determinação de interseção entre os ângulos a fim de determinar a localização com precisão. Entretanto, a documentação informa também que o Bluetooth SIG (*Special Interest Group*) não estabelece um algoritmo padrão para tal cálculo. Dessa forma a implementação de algoritmos de localização é deixada para a camada de aplicação.

Na literatura, são encontrados trabalhos que realizam aproximações matemá-

ticas lineares para correção dos cálculos de fase do sinal a partir das amostras IQ, em conjunto com conceitos de geometria para a estimação do ângulo de chegada. Além dessa abordagem, há trabalhos que utilizam também *deep learning* para a estimação do ângulo, porém, esses últimos, em sua maioria, utilizam dados de entrada simulados. [26, 27].

Em [28], o autor utiliza o ângulo de chegada em conjunto com o RSSI empregando a técnica de *deep learning* para determinar a posição de um dispositivo com amostras reais. O modelo proposto no trabalho possui como entrada o RSSI e o ângulo de chegada previamente calculado. Entretanto a metodologia para a aquisição do valor ângulo não foi exposta no trabalho. Assim, o autor não utiliza *deep learning* em conjunto com as amostras IQs para o cálculo do ângulo de chegada. Esse fato limita a precisão do sistema, pois ainda utiliza métodos matemáticos clássicos no processo de aquisição do ângulo de chegada.

A partir da lacuna comentada no parágrafo anterior, o presente trabalho de qualificação se justifica, pois propõe método que utiliza *deep learning* em sinais transmitidos por dispositivos Bluetooth a fim de identificar o AoA. Em comparação com outros métodos de localização, a proposta do presente trabalho se destaca pela maior precisão na identificação do AoA dos sinais recebidos. Além disso, o presente trabalho se mostra relevante devido à construção de uma base de dados de amostras IQ de sinais Bluetooth reais, onde atualmente se encontra dificuldade de disponibilidade em repositórios na internet. Ademais, o trabalho contribui com o preenchimento da lacuna da literatura relacionada ao emprego de técnicas de *deep learning* para a estimação de AoA com dados reais e não apenas simulados trazendo alternativas experimentais aos métodos matemáticos clássicos já abordados por outros trabalhos. Por fim, o trabalho é proposto e implementado com um método que utiliza informações dos sinais recebidos associados a respectiva antena de recepção, como informação relevante para a estimação do ângulo de chegada, o que não é abordado em outros trabalhos da literatura.

Dessa forma, o presente trabalho possui contribuição ao estado da arte através da implementação das características supracitadas, gerando avanço e maior precisão no campo da estimação do AoA. No trabalho verificou-se que a utilização da técnica de *deep learning*, juntamente com a consideração adequada da antena de amostra-

gem, proporcionaram melhorias na estimação do AoA, ampliando sua aplicabilidade no contexto de localização.

## 1.1 Objetivo Geral

Implementar um método baseado em *deep learning* e que emprega amostras IQ de sinais para prever o AoA de sinais de rádio bluetooth transmitidos em ambientes internos objetivando um alto grau de precisão em comparação com métodos existentes.

## 1.2 Objetivos Específicos

1. Levantar do estado da arte acerca das técnicas utilizadas em sistemas de posicionamento *indoor*, ângulo de chegada e aplicações de *deep learning* nesse contexto;
2. Validar o correto funcionamento do *array* de antenas utilizado no experimento;
3. Elaborar metodologia de coleta das amostras IQs e antena de amostragem para obter dados consolidados que suportem a abordagem proposta;
4. Coletar os pacotes Bluetooth com as amostras IQ de acordo com a metodologia elaborada;
5. Realizar uma análise exploratória e pre-processamento dos dados coletados a fim de garantir a integridade dos resultados encontrados;
6. Executar testes empregando *deep learning* com os dados previamente processados;
7. Avaliar resultados obtidos a partir do modelo criado;

## 1.3 Estrutura da Dissertação

A dissertação está estruturada em cinco capítulos, que abordam diferentes aspectos do tema de sistemas de posicionamento baseado em RF e o uso de *deep learning* aplicado aos métodos *direction of arrival* conforme descrição a seguir:

- No Capítulo 1, é realizada uma introdução ao problema de posicionamento *indoor*, destacando sua importância, aplicações e desafios. Além disso, são apresentados os objetivos da dissertação e a organização dos capítulos subsequentes.
- O Capítulo 2 se dedica a apresentar o estado da arte dos sistemas de posicionamento baseado em RF. São revisados estudos e pesquisas recentes sobre o tema, explorando as principais técnicas, abordagens e avanços na área. Essa revisão bibliográfica permite estabelecer um panorama atualizado do campo de estudo e identificar lacunas que serão abordadas na presente pesquisa.
- No Capítulo 3, são apresentados os fundamentos e materiais utilizados para a compreensão e implementação dos sistemas de posicionamento *indoor*. São explorados conceitos relacionados ao *Bluetooth*, *radio direction finding* (RDF), bem como redes neurais convolucionais (CNNs) aplicadas a problemas de localização. Esses fundamentos são essenciais para embasar o desenvolvimento da metodologia proposta.
- O Capítulo 4 detalha a metodologia adotada para a criação da base de dados e a implementação do modelo proposto. São descritas as etapas de coleta de dados, tanto do sinal RF quanto dos dados de referência de posicionamento. Também são apresentadas as técnicas de pré-processamento dos dados, bem como a arquitetura da rede neural convolucional utilizada. Essa seção permite compreender como foram conduzidos os experimentos e quais foram as escolhas metodológicas feitas durante o processo.
- Por fim, no Capítulo 5, são apresentados os resultados preliminares obtidos até o momento. São analisados os resultados das etapas de treinamento e teste do modelo proposto, bem como a avaliação do desempenho em relação a métricas de acurácia para modelos de regressão. Essa seção fornece informações sobre a eficácia e o potencial do modelo proposto, além de destacar possíveis direções futuras de pesquisa.

# Capítulo 2

## Revisão de literatura

Este trabalho propõe um método de posicionamento em ambientes internos baseado na técnica AoA utilizando tecnologia de rádio frequência. A revisão de literatura realizada para a construção desta dissertação consistiu na pesquisa de artigos, teses e dissertações acerca dos temas "*Indoor position System*", "*Angle of arrival*" e "*deep learning*" a fim de se obter os trabalhos mais recentes relacionados ao tema. Após a obtenção dos trabalhos foi realizada uma breve síntese comparativa a fim de identificar as oportunidades de contribuição nas implementações já existentes.

As próximas seções abordam as sínteses supracitadas dos trabalhos adquiridos durante o processo de pesquisa. A Seção 2.1 apresenta os trabalhos de sistemas de posicionamento *indoor* que utilizam tecnologia de rádio frequência e sua respectiva técnica de posicionamento utilizada. Já Seção 2.2 apresenta os trabalhos que empregam a técnica de *deep learning* para o processo de estimativa da direção de chegada do sinal ou até mesmo do posicionamento de um dispositivo. A seção 2.3 apresenta a discussão dos trabalhos elencados com o intuito de apresentar o panorama geral dos trabalhos e as lacunas da literatura que são passíveis de contribuição por parte da presente dissertação.

### 2.1 Sistemas baseados em Rádio Frequência

Em [21], os autores utilizam ponto de acesso WiFi com múltiplas antenas como âncoras em sua proposta. Eles estimam a posição de *tags* por meio da combinação das técnicas ToA e AoA. Para medir o ToA, o ponto de acesso WiFi envia

múltiplas mensagens predefinidas para superar as restrições de largura de banda do WiFi. Para medir o AoA, a *tag* envia várias mensagens para o ponto de acesso WiFi, onde o AoA é medido utilizando a técnica de estimativa de canal, aproveitando suas múltiplas antenas. Vale ressaltar que a solução proposta foi avaliada por meio de ambiente de simulação computacional. Com o uso de 10 mensagens predefinidas, um único ponto de acesso WiFi pode alcançar uma precisão de posicionamento de 2,2m e 1m para larguras de banda de 20 MHz e 40 MHz, respectivamente. Com múltiplos pontos de acessos, a precisão de posicionamento é de 2,2 m e 0,5 m, respectivamente.

No artigo [29], é apresentado um IPS que faz uso dos sensores inerciais presentes em um *smartphone* em conjunto com a técnica FTM e RSSI do WiFi para rastrear pedestres. Além disso também é utilizado o filtro de Kalman estendido adaptativo para combinar as informações triaxiais do acelerômetro, giroscópio e magnetômetro, com o objetivo de calcular a velocidade e a direção em tempo real do pedestre. Os resultados experimentais mostram que, em comparação com os métodos que usam sensores inerciais existente e os outros métodos de fusão, o algoritmo proposto provou alcançar precisão de posicionamento interno com precisão na faixa de metro em ambientes internos.

Já em [30] foi desenvolvido um sistema de localização assistida interativa para uso em ambientes de museus inteligentes. Para fornecer localização precisa, os autores utilizaram *beacons* BLE implantados em cada sala do museu. Um dispositivo semelhante a um *smartphone* é usado pelo visitante para receber dados dos *beacons* e determinar sua localização no museu com base no RSSI. Os resultados mostraram que a estimativa de localização foi mais precisa no primeiro cenário sem linha de visão, com um dispositivo vestível localizado em três posições diferentes a 0,5m, 1m e 3m. No segundo cenário com linha de visão, a probabilidade de localização diminuiu quando o dispositivo vestível foi colocado mais próximo da porta de separação.

Outros estudos também se utilizaram da técnica de RSS com Bluetooth para atingir o objetivo de localização em um ambiente interno. Em [31] o autor objetivou analisar sinais RSSI do Bluetooth de *smartphones* e comparar os sinais RSSI em dois comportamentos distintos: em pé e sentado para melhorar a precisão e fornecer uma base essencial para a criação de algoritmos para detecção de proximidade com o objetivo de ajudar os navios a gerenciar as pessoas a bordo na era pós-pandêmica. Já

em [32] os autores utilizam a técnica para Rastreamento em tempo real de um alvo em movimento em um corredor interno do prédio do hospital. Em [33], os autores propuseram um método para aprimorar a técnica de detecção do dispositivo BLE mais próximo, o que permitiria o desenvolvimento de aplicações mais eficientes para pacotes com *advertising* de localização em feiras, exposições e museus. Ainda utilizando a técnica de RSS, os autores em [34] realizaram uma avaliação experimental com WiFi, BLE e LoRa para verificar a tecnologia mais adequada para localização interna. Os resultados obtidos no experimento mostram que o WiFi é mais preciso com um erro médio de 0,54m. O LoRa é o segundo mais preciso com um erro médio de 0,62m e o BLE é o menos preciso com um erro médio de 0,82m.

Utilizando a técnica de *fingerprint* com RSS, o trabalho [35] teve como objetivo avaliar o desempenho da técnica com *beacons* BLE estáticos em locais conhecidos. Para a coleta dos dados, foi utilizado um iPhone iOS 7 ou superior, que indicou também em qual canal a mensagem é recebida. Para avaliar a abordagem de *fingerprint*, foram medidos os RSSIs de 19 *beacons* em um andar de um edifício com área de 600 metros quadrados. Os resultados indicam que o melhor desempenho é alcançado quando são utilizados de 8 a 10 *beacons* e, mesmo reduzindo a potência de transmissão, uma boa cobertura ainda foi fornecida com um número razoavelmente baixo de *beacons*. Os autores também relatam que a implantação de um *beacon* por cada 30 metros quadrados resultou em precisões menores que 2,5m. Quando a densidade de *beacons* foi reduzida para um por cada 100 metros quadrados, a precisão diminuiu para menos de 5,5m. Já estudo realizado em [36] também teve como objetivo utilizar a tecnologia BLE RSSI para a localização interna empregando *fingerprint*. Para isso, foi realizada uma fase off-line em que sensores UWB, empregados como *groundtruth* na avaliação do posicionamento, juntamente com os *beacons* BLE, foram utilizados para construir o *fingerprint*. A sala de teste utilizada continha 12 *beacons* BLE e 8 âncoras UWB, sendo que os *beacons* enviavam pacotes de anúncios a cada 350ms com uma potência de transmissão de -4dBm. Todos os pontos de ancoragem (BLE e UWB) foram instalados a uma altura de 1,5m do chão. Os dados coletados pelo *scanner* BLE e pela *tag* UWB foram carregados no servidor de localização a cada segundo. Para a estimativa de localização por meio de *fingerprint*, os autores utilizaram algoritmos de *Machine Learning*, como k-Nearest

Neighbor (KNN) e Gradient Boosting Decision Tree (GBDT). O sistema foi treinado com 80% dos dados de *fingerprint* coletados e validado nos 20% restantes. Os resultados indicam que o erro médio de distância para diferentes algoritmos foram: Geometria básica - 2,83m, KNN - 0,72m, GDBD - 1,27m, e Floresta Aleatória - 0,85m.

A referência [37], apresenta estudo experimental, utilizando dispositivos Bluetooth BLE 5.0 e 4.2. A abordagem de medição consistiu em três elementos: a conversão do RSSI em distância, o uso de múltiplos *beacons* no plano e medições direcionais diversas. Os métodos de análise empregados para obter um posicionamento preciso incluíram o modelo de propagação do sinal, trilateração, coeficiente de modificação e filtro de Kalman. Os resultados dos experimentos demonstraram que a precisão do posicionamento pode alcançar 10 cm quando os beacons e os scanners estão no mesmo plano horizontal, em um ambiente com menos interferências. No entanto, essa precisão diminui para uma escala métrica quando as medições são realizadas em um ambiente tridimensional e complexo. De acordo com a análise realizada, o sinal sem fio BLE é suscetível a interferências em ambientes de fabricação, mas ainda é viável em certas situações. Além disso, as especificações do Bluetooth 5.0 se mostram mais promissoras para aplicações de localização em tempo real no futuro, devido à sua maior estabilidade de sinal e melhor desempenho em ambientes com menor interferência.

Em [38], os autores avaliaram do uso de técnicas de Aprendizado de Máquina e processamento de sinal para melhorar o desempenho da estimativa do (AoA) do Bluetooth. Os autores propuseram um método para combinar o algoritmo MUSIC com modelos de regressão, incluindo o Processo Gaussiano (PG), Rede Neural (RN) e Árvore de Regressão (AR) para realizar a estimativa de AoA. Os autores avaliaram a abordagem proposta usando tanto com dados simulados quanto com medições reais, no entanto não foram apresentados quais dispositivos comerciais foram utilizados para as medições reais de AoA. Além disso, os autores não apresentaram o formato dos dados utilizados para a criação dos modelos de aprendizado de máquina. Os resultados das simulações mostram que, para um SNR de 30dB, quando os efeitos de multipercurso e o ângulo de elevação são baixos, a estimativa de azimute foi 20% melhor para a abordagem RN do que o algoritmo MUSIC e 50% melhor no caso de

AR e PG. Para o SNR de 30dB e com o aumento da elevação, o RN e o PG superam o MUSIC. Ainda nesse experimento, o AR teve resultados comparáveis ao algoritmo MUSIC. Para o experimento onde o SNR estava entre 0dB e 30dB, as medições reais forneceram o MAE na estimativa de AoA da seguinte forma: MUSIC com mais de  $9^\circ$ , RN com  $3,5^\circ$ , PG atingindo  $3^\circ$  e AR em  $3,5^\circ$ . Os autores mostram que o uso do PG apresentou os melhores resultados, porém seu tempo computacional foi de 40ms, enquanto a RN obteve tempo de 7,8 ms para processar um único conjunto de teste de 1530 amostras. A abordagem AR teve o tempo computacional mais rápido, de 1,4ms, mas seu desempenho diminuiu com maior ângulo de elevação e menor SNR.

Em [22], o autor descreve os métodos de processamento de sinal para minimizar o erro de estimativa de AoA com BLE. A metodologia de processamento proposta consiste em três etapas: Aplicação de mínimos quadrados, Filtro de Kalman e Filtro Gaussiano. O método de mínimo quadrado é aplicado aos dados brutos para reduzir o ruído após a coleta dos sinais IQ. Todos os dados são ajustados em uma curva senoidal. Em seguida o Filtro de Kalman é usado para suavizar as variações de fase e frequência em diferentes amostras. Essas variações causam grandes erros na estimativa do ângulo e ocorrem devido ao deslocamento de fase do oscilador tanto no lado do transmissor quanto no lado do receptor, bem como nos elementos de chaveamento de antena. Por fim, é implementado o Filtro Gaussiano para eliminar a interferência WiFi nos canais BLE, causando erro de cálculo do ângulo. Um deslocamento angular constante é calculado para todos os 37 canais de dados BLE para melhorar a estimativa do ângulo. Os autores utilizam o kit de desenvolvimento RTLS da Texas Instruments com o conjunto de antenas BOOSTXL-AOA para a avaliação experimental. O AoA é estimado na área de  $-90^\circ$  a  $90^\circ$ . Após o processamento dos dados brutos, os resultados mostram que, de  $-60^\circ$  a  $60^\circ$ , esse método apresenta erros menores que  $10^\circ$ . Os erros crescem significativamente ao se mover em direção a  $-90^\circ$  e  $90^\circ$  e a estimativa de AoA torna-se quase aleatória. A Tabela 2.1 elenca todos os trabalhos que empregam as técnicas citadas acima.

Tabela 2.1: Trabalhos que utilizam técnicas de RF para Posicionamento

Referência	Ano	Técnica	Tecnologia RF
[21]	2015	ToF/DoA	WiFi
[29]	2020	ToF/RSS	WiFi
[30], [33], [31], [32],	2015, 2020, 2022, 2022	RSS	BLE
[34],	2021	RSS	WiFi, LoRa, BLE
[35], [36]	2015, 2019	RSS/ <i>Fingerprint</i>	BLE
[37]	2021	RSS	BLE
[38], [22]	2018, 2020	DoA	BLE

## 2.2 *Deep Learning* aplicado aos métodos de *Direction of Arrival*

Em [39] os autores analisaram o sinal de multipercorso desconhecido e concluíram que esse fenômeno distorce a característica de fase do sinal. No trabalho é apresentado método para estimativa de ângulos pequenos usando aprendizado profundo para mitigar a distorção de fase e, assim, melhorar a precisão da estimativa de direção de chegada (DoA). A verificação dos dados reais mostra que esse método melhora efetivamente a estimação de DoA.

Em [40], os autores avaliaram duas novas técnicas para a estimativa da direção de chegada de fontes de RF: otimização inteira restrita e aprendizado profundo. A pesquisa descobriu que o aprendizado profundo é mais robusto a erros significativos de calibração para se adaptar à estimação de DoA no ambiente urbano. No trabalho [41], foi proposta uma rede neural convolucional, com valores complexos. Os experimentos mostram que o modelo tem uma taxa de convergência mais rápida do que a uma rede convolucional comum e uma maior precisão de estimação de DoA. Já em [42], os autores propuseram um modelo supervisionado para melhorar a estimação de fase de uma rede convolucional, que pode reduzir a distorção de fase ao aprimorar as suas características de fase. O modelo pode melhorar efetivamente a precisão de estimação de DoA do sistema de radar de VHF mesmo sob o fenômeno de multipercorso coerente. No trabalho [27] foi proposto um método de treinamento de cinco redes neurais convolucionais sob diferentes condições, com cada CNN aprendendo a imagem da direção convertida a partir das partes real e imaginária da matriz de covariância espacial. Os resultados de previsão de cada modelo são calculados

como um valor médio para obter os resultados finais de estimativa de (DOA). A simulação demonstrou que este método pode realizar uma efetiva estimativa DOA bidimensional (2D). Na Tabela 2.2 são apresentados os trabalhos que utilizam redes profundas para a estimação da direção de chegada do sinal.

Tabela 2.2: Trabalhos que empregam redes profundas para DOA

Ref.	Regr.	Class.	Métrica	Array	Rede	Treino		Val.	
						Simul.	Real	Simul.	Real
[39]	✓		R <sup>2</sup> RMSE	ULA	DNN		✓		✓
[40]	✓		MAE	UCA	DNN	✓		✓	
[41]		✓	Acurácia	ULA	CNN	✓		✓	
[42]	✓		RMSE	ULA	CNN	✓	✓	✓	✓
[27]	✓		MAE RMSE	UCA	CNN	✓		✓	

## 2.3 Discussão dos trabalhos relacionados

A estimação precisa do Ângulo de Chegada (AoA) é um desafio no campo da localização. Embora existam diversos métodos de localização disponíveis, o AoA se destaca pela sua capacidade de fornecer uma precisão superior [43]. No entanto, a estimação do AoA enfrenta uma série de problemas que limitam sua aplicabilidade em determinados contextos. Neste texto, exploraremos alguns desses problemas e suas implicações no desenvolvimento de técnicas de estimação do AoA.

Os trabalhos [30–34] são exemplos de uso do RSSI para localização em ambiente interno, verificação de proximidade e rastreamento em tempo real de um alvo em movimento. Já em [29], os autores utilizam também FTM em conjunto com RSSI e sensores inerciais a fim de melhorar a precisão na estimação do posicionamento nesses sistemas. Vale ressaltar que as tecnologias empregadas para a realização desses trabalhos foram utilizando Wi-Fi, BLE e LoRa. Quanto à técnica utilizada para a estimação, em [31], por exemplo, o autor realiza uma análise estatística para identificar níveis de distância entre dispositivos, enquanto em [32] o autor utiliza conceito da relação logarítmica entre RSSI e distância para o rastreamento. Os resultados de todos esses trabalhos apontam para um menor erro médio de 0,54 m empregando o RSSI com Wi-Fi que, por sua vez, torna as aplicações de localização mais custosas acerca da energia requerida. O trabalho [37] se destaca, pois atinge

resultado de 10 cm de precisão. Todavia, o autor apresenta que isso só pode ser alcançado em condição específica onde que os dispositivos encontram-se no mesmo plano.

Os estudos [35, 36], utilizam beacons *bluetooth* em conjunto com a técnica de *fingerprint* empregando RSSI para a realização da localização em ambientes internos. Em [35] realizou uma avaliação de precisão variando a quantidade de beacons em um ambiente e verificou que para o emprego de um beacon a cada 30 metros quadrados, os resultados de erro obtido foram inferiores a 2,5m. Já em [36], o emprego de técnicas de *machine learning* resultaram em um menor erro médio de distância de 0,72m. Todavia, os resultados ainda muito acima do esperado com emprego de novas técnicas de localização como AoA.

Dessa forma, embora existam outros métodos de localização baseadas em RF, como a trilateração, FTM, técnica baseada em RSSI e utilização de *fingerprint* conforme apresentados acima, eles geralmente não apresentam a mesma precisão proporcionada pelo AoA [43]. Ao analisar os trabalhos, a disparidade de precisão dessas técnicas torna o AoA uma escolha para aplicações que requerem alta acurácia de localização.

Os trabalhos [21, 22, 38] empregam a técnica de AoA para implementação de sistemas de posicionamento. Em [21], em um ambiente simulado, são utilizados pontos de acesso WiFi com múltiplas antenas. Além de utilizar a técnica de AoA, ele a combina com ToA empregando o método de estimativa de canal para estimar a posição de dispositivos. O melhor resultado obtido foi de 0,5m, porém, além de utilizar o WiFi, que requer alto consumo energético, para adquirir esse resultado, o autor necessitou a combinação de múltiplos pontos de acesso. Já em [22], a tecnologia utilizada para o emprego da técnica de AoA foi o *Bluetooth*. No trabalho, apesar de serem obtidos ótimos resultados como erros menores que 10°, são empregadas dois *arrays* lineares de três antenas. Dessa forma, o sistema proposto suporta um intervalo de  $-180 < \theta < 180$ . Além disso, ainda sobre os dispositivos utilizados, o autor apresenta apenas a distância linear de 1m entre os dispositivos e não apresenta de forma clara se eles estão em um mesmo plano ou em planos diferentes. Acrescenta-se também que, o autor explicita que existe um erro considerável nos intervalos de  $-60^\circ$  a  $-90^\circ$  e  $60^\circ$  a  $90^\circ$  devido ao hardware utilizado, o que limita o ângulo máximo

em que o sistema consegue realizar as medições de forma confiável. Por fim, o processamento realizado com as amostras IQ não emprega o uso de novas técnicas como *machine learning* e *deep learning* para o cálculo do ângulo de chegada.

Em [38], o autor não explica a característica da amostra, não dá detalhes do ambiente de medição real se era um local com armários, mesas nem o tamanho. Apenas cita que é um ambiente de escritório pequeno. O autor realizou simulação e medição real, porém apresentou as características da antena apenas para a simulação. Não ficou claro se a disposição entre os dispositivos na simulação foi similar ao real e qual foi a disposição no ambiente de medição como as distâncias entre do transmissor e receptor.

Os trabalhos [27, 39, 40, 42] empregam a técnica de *deep learning* processo de regressão enquanto [41] utiliza *deep learning* para realizar o processo de classificação. Os trabalhos [27, 40] usam *array* de antena circular, enquanto todos os demais trabalhos, apesar de empregarem *deep learning*, eles recorrem, em sua configuração de teste, apenas à antenas lineares. Esse fator se torna limitante, pois antenas lineares conseguem dispor da informação do sinal para a estimação do ângulo de chegada em apenas um plano ou uma dimensão.

Em [39, 40], os autores utilizam rede densa para a estimativa do ângulo de chegada. Apenas em [39] antes de inserir as amostras na rede, o autor realiza um processo de extração de características de fase do sinal de forma manual. Porém, em nenhum desses trabalhos essa extração de característica é realizada por uma rede convolutiva que realiza essa tarefa de maneira mais eficiente, pois utiliza camadas convolucionais para extrair informações relevantes dos dados.

Acrescenta-se que a depender do *array* utilizado, as antenas que o compõem recebem uma identificação numerada. Em nenhum dos trabalhos há a consideração da informação do número antena de amostragem como uma informação importante para a entrada de um modelo de *deep learning*. No entanto, muitos trabalhos existentes negligenciam essa informação, o que pode resultar em estimativas imprecisas ou subótimas. A incorporação adequada da antena de amostragem como um parâmetro relevante pode contribuir significativamente para melhorar a precisão e a confiabilidade da estimação do AoA.

Assim, apesar de alguns trabalhos utilizarem a abordagem de *deep learning*,

essas abordagens muitas vezes se baseiam em experimentos com dados simulados em vez de dados reais ou possuem limitações nos hardwares utilizados. Embora os resultados obtidos com dados simulados possam ser promissores, a falta de validação em ambientes reais pode limitar a generalização e a aplicabilidade desses métodos em situações práticas.

# Capítulo 3

## Fundamentos e materiais

### 3.1 Sistemas de posicionamento *indoor*

A localização é o processo de encontrar um objeto em relação a alguns pontos de referência, enquanto o posicionamento é encontrar as coordenadas de um objeto no espaço. Os sistemas de localização compreendem dois componentes: 1) nós de referência fixos ou *Reference Nodes* (RNs), chamados âncoras com posições conhecidas e 2) nós móveis ou *Mobile Nodes* (MNs), conhecidos como *beacons* ou *tags* que precisam ser localizados. A localização dos MNs é medida pela distância ou ângulo dos RNs ou desvio deles mesmos e essa informação pode ser utilizada em Sistemas de posicionamento *indoor*, ou *indoor Position System* (IPS), com diferentes tipos de tecnologia de comunicação como *Wi-Fi*, *Ultra Wide Band* e *Bluetooth Low Energy* (BLE), por exemplo. Uma representação gráfica desses elementos pode ser vista na Figura 3.1.

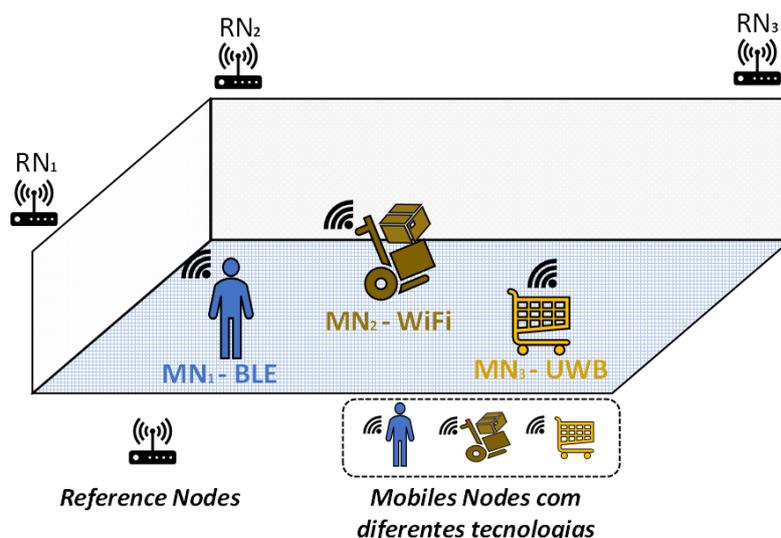


Figura 3.1: Representação de um IPS com RNs recebendo ou emitindo sinais para a localização. Fonte: Própria.

Os sistemas de posicionamento podem ser divididos com base nas características de ambiente que estão inseridos que são internos ou externos. Esses sistemas podem determinar a posição de objetos nesses locais, além de oferecer quatro tipos de serviços: 1) rastreamento; 2) navegação; 3) proximidade; e 4) base de medição inercial. Nos sistemas de rastreamento, que possuem objetivo de rastrear a posição de um objeto, utiliza uma *tag* de posicionamento (MN) que deve ser instalada ou montada na superfície do objeto de interesse para transmitir sua informação aos RNs. Em navegação ou sistemas ativos, os usuários precisam executar uma aplicação em um dispositivo como um *smartphone* para encontrar suas localizações em relação aos RNs. Já os sistemas de proximidade notificam os usuários ou terceiros quando estão nas proximidades de um ponto de interesse. A principal aplicação deste sistema é a definição de zonas de interesse em ambientes, como espaços públicos e museus. Por fim, um sistema de medição inercial é um sistema autônomo que mede o movimento linear e angular de objetos por meio de sensores como acelerômetro, giroscópio, e magnetômetro. O melhor caso de uso desse sistema é em dispositivos móveis, onde pode ser usado como complemento de outros serviços para encontrar direções, especialmente em espaços internos. Um exemplo de sistemas de posicionamento para ambientes externos é o *Global Position System* (GPS) que utiliza satélites para cobertura de grandes áreas. Todavia, áreas cobertas e internas, como edifícios e estruturas urbanas no subsolo não são abarcadas.

### 3.1.1 Técnicas para localização *indoor*

As técnicas mais utilizadas para sistemas de localização *indoor* são baseadas em propriedades físicas como *Angle of arrival* (AoA) ou *Direction of arrival* (DoA) que consiste na aquisição da direção de chegada de um sinal, *Time of arrival* (ToA) ou *Time of flight* (ToF) que utiliza o tempo de propagação do sinal para estimar a distância, *Time Difference of Arrival* (TDoA) que explora a diferença nos tempos de propagação dos sinais de diferentes transmissores medidos no receptor, *Received Signal Strength Indicator* (RSSI) que utiliza a força do sinal de rádio para estimar a distância entre dispositivos e a técnica *Return Time of Flight* (RToF) que mede o tempo de propagação do sinal de ida e volta (isto é, transmissor-receptor-transmissor) para estimar a distância entre os dispositivos. Essas técnicas exploram diferentes características de um sinal para realizar a localização de dispositivos no ambiente. Os sistemas baseados em AoA geralmente utilizam a técnica de triangulação diferentemente dos baseados ToA e RSSI que geralmente calculam a localização via trilateração enquanto o TDoA usa uma técnica chamada multilateração. A técnica a ser abordada neste trabalho será a AoA com a tecnologia *Bluetooth* 5.1, dada a disponibilização de recursos de hardware para a implementação dessa funcionalidade a partir dessa versão.

## 3.2 Radio Direction Finding

### 3.2.1 Ângulo de chegada

A técnica Ângulo de Chegada, ou *Angle of Arrival* (AoA), é uma técnica de localização que utiliza informações das fases em que os sinais chegam a um conjunto de antenas nos receptores. No caso mais simples para o método de AoA, o receptor é dotado de um *array* com duas antenas separadas pela distância  $d$ , enquanto o dispositivo transmissor usa uma única antena para enviar o sinal. No momento em que o sinal atinge a antena 1 do receptor no instante  $t_1$ , é possível traçar uma linha perpendicular a partir de uma frente de onda, estendendo-se até a antena 2 do receptor formando um triângulo retângulo, conforme mostrado na Figura 3.2.

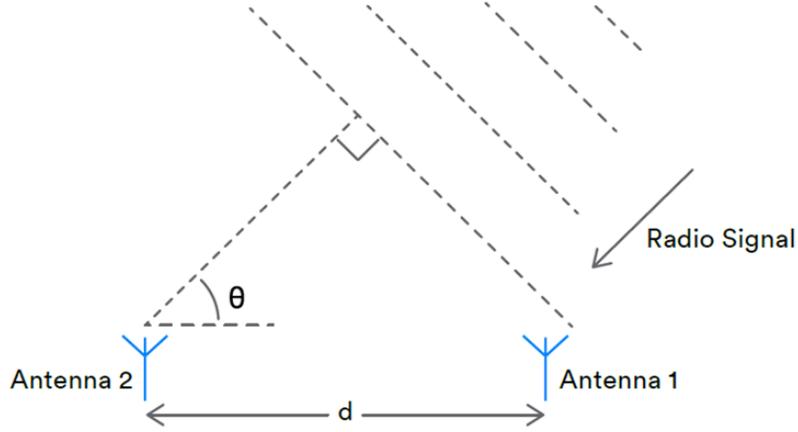


Figura 3.2: Diferença de fase para cálculo do ângulo de chegada. Fonte: [1].

A linha traçada corresponde a distância linear,  $d \cos(\theta)$ , que o sinal necessita percorrer para atingir a segunda antena no instante  $t_2$ , onde  $\theta$  representa o ângulo de chegada do sinal. Dado que o sinal atinge as antenas em instantes diferentes, há uma diferença de fase  $\psi$  entre os sinais que chegam até elas. A partir dessa diferença de fase  $\psi$ , distância linear  $d \cos(\theta)$  e do comprimento de onda  $\lambda$ , o ângulo de chegada do sinal  $\theta$  pode ser definido a partir da Equação 3.1.

$$\theta = \arccos\left(\frac{\psi \lambda}{2\pi d}\right) \quad (3.1)$$

### 3.2.2 Topologia de *array* de antenas

Os *arrays* de antenas para técnica de AoA são normalmente classificados em três tipos: Linear, Circular e Retangular. Mais detalhadamente, os retangulares e circulares são bidimensionais, enquanto a linear é unidimensional. Em detrimento dessa característica, a linear tem a desvantagem de determinar apenas um ângulo correspondente a um plano. Já as circulares e retangulares UCAs e URAs permitem estimar de forma confiável os ângulos de elevação e azimute, ou seja duas dimensões, portanto conseguem fornecer mais informações para um IPS. As topologias de array linear, retangular e circular podem ser vistas na Figura 3.3a, 3.3b e 3.3c.

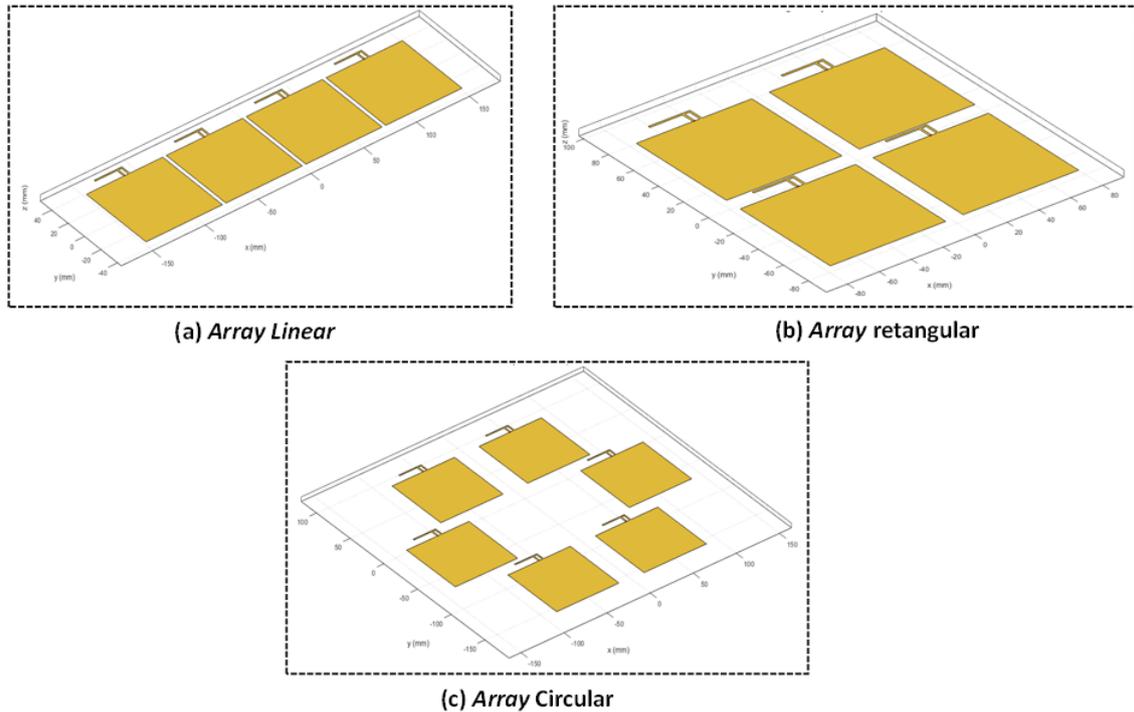


Figura 3.3: Topologias de *arrays* de antena. (a) Topologia linear, (b) Topologia retangular e (c) Topologia circular. Fonte: Própria.

### 3.3 *Bluetooth*

O *Bluetooth* é uma tecnologia de comunicação classificada como *wireless Personal Area Network* (WPAN) que possui como uma de suas principais finalidades a transferência de dados entre dispositivos a curta distância. Está atualmente disponível na maioria dos dispositivos eletrônicos, como *smartphones*, dispositivos de Internet das Coisas (IoT) e notebooks. Em detrimento dessa vasta disponibilidade e melhorias em relação ao consumo energético implementadas, essa tecnologia é amplamente utilizada em diversas áreas [44], [45], [46] [47] [48].

A versão 5.1 do *Bluetooth*, uma das mais recentes, é compatível com a tecnologia de baixo consumo de energia *Bluetooth Low Energy* (BLE), inclusa na versão 4.0, onde os dispositivos podem se conectar e compartilhar informações consumindo menos energia que em versões anteriores. Além disso, a principal funcionalidade agregada na versão 5.1 é o *Direction Finding*. Essa funcionalidade introduziu a técnica chamada *Angle of Arrival* (AoA) utilizada para determinar a direção de chegada de um sinal *Bluetooth* para identificação da posição de outros dispositivos, o que viabiliza o uso da tecnologia em sistemas de localização *indoor* em tempo real.

### 3.3.1 Stack BLE

A arquitetura para os dispositivos BLE é dividida em três blocos básicos: *Application*, *host* e *Controller*. Cada bloco constitui a pilha do protocolo BLE e é subdividido em camadas que fornecem as funcionalidades da tecnologia. Neste trabalho serão abordadas apenas as camadas inerentes ao *Controller* que consta em destaque na pilha do BLE apresentada na Figura 3.4.

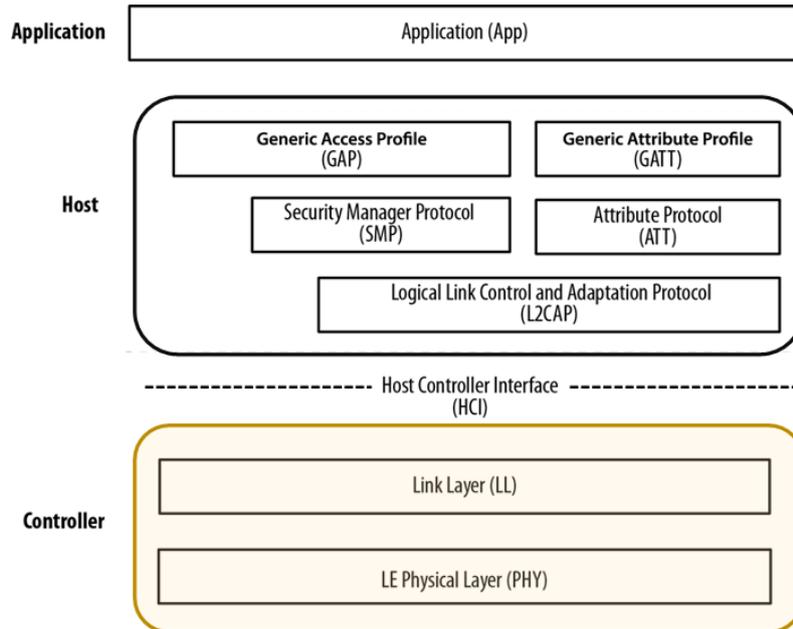


Figura 3.4: Pilha do protocolo BLE. Fonte: Adaptado [2].

O controlador normalmente é um dispositivo físico que pode modular, transmitir e receber e demodular sinais de rádio através de circuitos analógicos de comunicação e e transformá-los em símbolos digitais. Ele é composto pela camada física, ou *Physical Layer*(PHY), e a camada de enlace, ou *Link Layer* (LL), descritas na subseções seguintes [2].

### 3.3.2 Camada física

A camada física (PHY) é a camada mais baixa da pilha de protocolos Bluetooth LE. Ela aborda o método físico usado para transmitir e receber bits brutos por meio de ondas de Rádio frequência (RF). Ela Define como esses bits são modulados em uma onda portadora de RF, bem como como essa onda portadora de RF é transmitida e recebida pelo de rádio. Esse rádio que deve operar na banda ISM (*Industrial, Scientific, and Medical*) de 2,4 GHz (2400MHz-2483,5MHz). A banda é

segmentada em 40 canais de RF separados por 2 MHz entre os centros dos canais. Esses 40 canais são divididos em canais de *advertising* e canais de dados.

Os canais 37 (2402MHz), 38 (2426MHz) e 39 (2480MHz) são classificados como canais *advertising* totalizando 3 do total de 40 citados. Eles são empregados para descobrir outros dispositivos, estabelecer uma conexão e transmissão *broadcast*. Quando um dispositivo quer transmitir dados, envia pacotes de *advertising* através desses canais e é denominado *advertiser*. Essa transferência é realizada em intervalos chamados de eventos e é feita sequencialmente através de todos os canais.

Os 37 demais canais são denominados de canal de dados. Eles são utilizados para a comunicação bi-direcional entre os dispositivos empregando a técnica chamada *Frequency-hopping spread spectrum* (FSSS) e o *Adaptive Frequency Hopping* (AFH) para mitigar problemas de colisão de sinal. A Figura 3.5 apresenta a banda de frequência e seus canais, bem como a divisão dos canais de *advertising* e canais de dados.

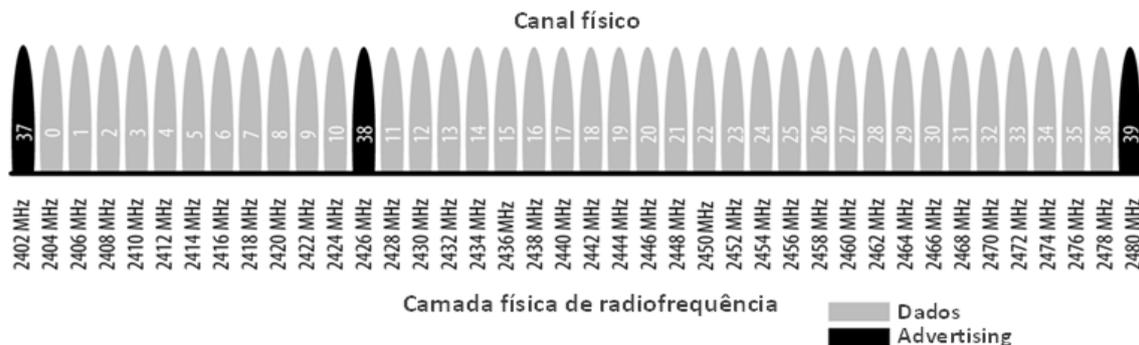


Figura 3.5: Espectro de frequência do BLE. Fonte: Adaptado [2].

A modulação escolhida para codificar o fluxo de bits é o *Gaussian Frequency Shift Keying* (GFSK), a mesma modulação usada pelo *Bluetooth* clássico e vários outros protocolos sem fio proprietários de baixa potência [2].

### 3.3.3 Camada de enlace

A camada de enlace é responsável pelas conexões, garantir a estruturação e integridade dos pacotes utilizando valores de verificação e sequências de criptografia calculados corretamente. A operação da Camada de Enlace pode ser descrita em termos de uma máquina de estado com os seguintes estados: *Standby State*; *Adver-*

*tising State; Scanning State; Initiating State; Connection State e Synchronization State.* Neste trabalho serão abordados apenas o *Advertising State* e *Scanning State* que podem ser visualizados em destaque na Figura 3.6.

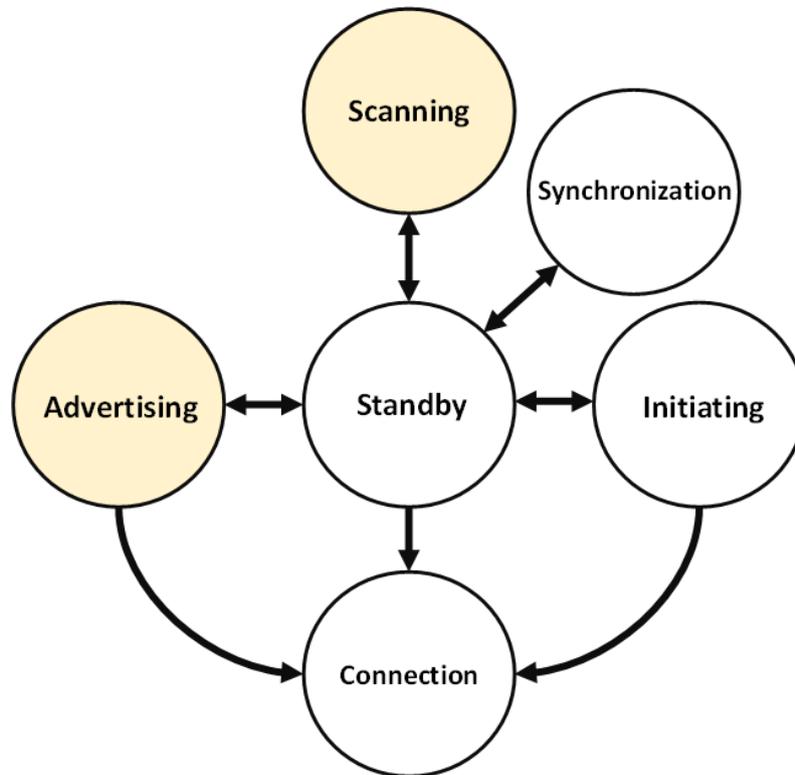


Figura 3.6: Máquina de estado da camada de enlace. Fonte: Adaptado [3].

A Camada de enlace no estado de *Advertising* transmite pacotes nos canais de *Advertising* e pode escutar e responder a requisições contidas em pacotes desses canais. Um dispositivo no estado *Advertising* é conhecido como *Advertisers*. O estado de *Advertising* pode ser acionado a partir do estado *Standby*.

A camada de enlace no estado de *Scanning* escuta pacotes dos canais de *Advertising* oriundos de dispositivos *Advertisers*. Um dispositivo no estado *Scanning* é conhecido como scanner. O estado *Scanning* pode ser acionado a partir do estado *Standby*.

A camada de enlace é responsável também por conter as diretrizes para a estrutura do pacote a ser trocado. Nessa questão, o *Bluetooth* 5.1 possui na composição do seu pacote quatro campos obrigatórios e um campo opcional. Os campos obrigatórios são Preâmbulo, Endereço de Acesso, *Protocol Data Unit* PDU e o *cyclic redundancy check* (CRC). O campo opcional é *Constant Tone Extension* (CTE) que foi incluso na versão 5.1 para suportar as funcionalidades de *Direction Finding*. O

formato de pacote é mostrado na Figura 3.7.



Figura 3.7: Formato de pacote *Bluetooth*. Fonte: [4].

O preâmbulo é de 1 ou 2 octetos ao transmitir ou receber à uma taxa de 1Mbps ou 2Mbps respectivamente. O endereço de acesso é de 4 octetos. A faixa do PDU é de 2 a 258 octetos enquanto o CRC é de 3 octetos. Caso o CTE seja incluso, sua duração é entre 16 e 160  $\mu$ s.

### 3.3.4 Técnica de *Direction Finding* com Bluetooth

O *Direction Finding* consiste em uma funcionalidade agregada ao *Bluetooth* 5.1 para o emprego da tecnologia em sistemas de posicionamento *indoor*. Essa funcionalidade oferece dois métodos distintos para realizar a localização de dispositivos. O primeiro dos dois métodos é chamado de Ângulo de Chegada, ou *Angle of Arrival* (AoA) e o segundo é chamado de Ângulo de Partida, ou *Angle of Departure* (AoD). Neste trabalho é abordado apenas a técnica de ângulo de chegada. Nesse caso, pacotes com CTE são transmitidos por um dispositivo e são usados pelo receptor para calcular a direção do sinal recebido. O receptor contém um *array* com múltiplas antenas e a arquitetura básica para funcionamento pode ser visualizada na Figura 3.8.

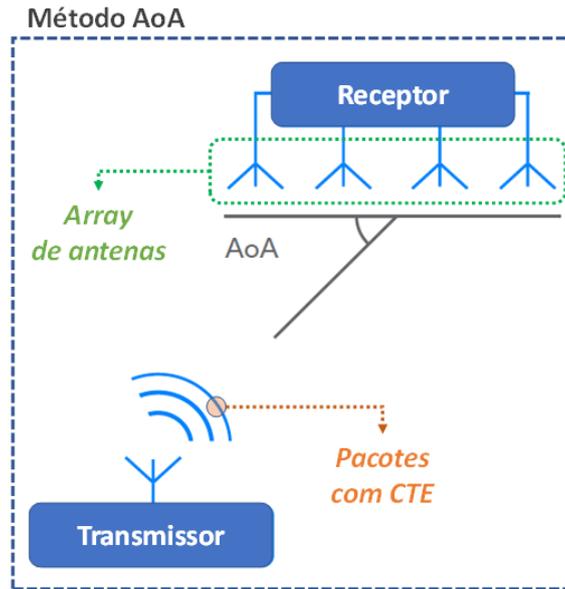


Figura 3.8: Arquitetura para realização do método AoA. Fonte: Adaptado [1].

Vale ressaltar que o *Bluetooth* SIG não define um algoritmo padrão para a estimação de ângulos a partir das amostras IQ. Dessa forma, a escolha do algoritmo é deixada para a camada de aplicação.

### 3.3.4.1 *Constant Tone Extension*

O entendimento do *Constant Tone Extension* (CTE) é fundamental para a técnica de *Direction Finding* com o *bluetooth*. Ele consiste em uma série de bits 1 modulada sem a técnica *whitening* aplicada a eles. Ao manter uma série de bits 1, a frequência do sinal e o comprimento de onda permanecem constante. Isso é fundamental para o processo de amostragem IQ desse sinal no rádio.

O CTE possui temporização para realização do chaveamento e a amostragem do CTE. O tempo para o processamento do CTE é dividido em um período de guarda inicial de  $4 \mu s$ , um período de referência de  $8 \mu s$  seguido de uma sequência de blocos de chaveamento, ou *switches*, e blocos de amostra, ou *sampling*, ambos de  $2 \mu s$  para a implementação deste trabalho. A amostragem ocorre durante os blocos de amostragem e o chaveamento da antena durante os blocos de chaveamento. Essa temporização pode ser visualizada na Figura 3.9.

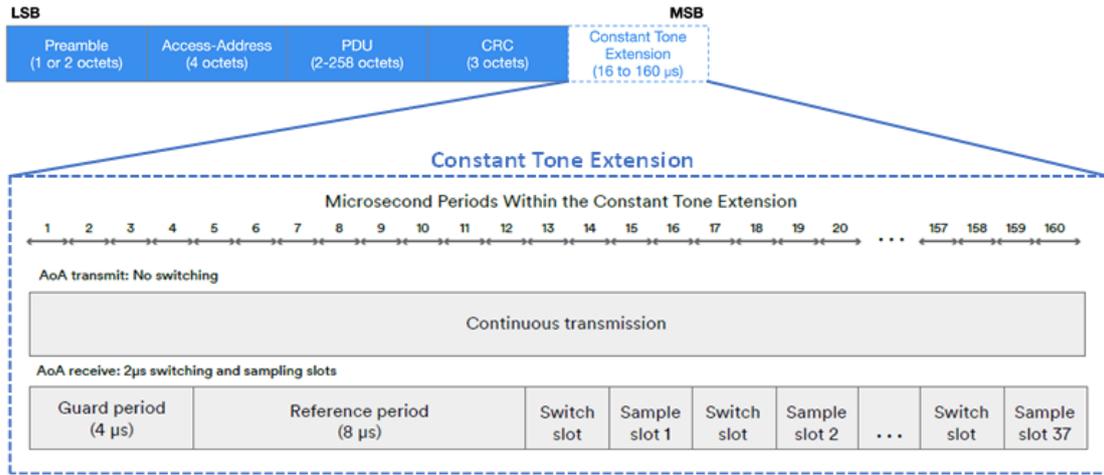


Figura 3.9: Temporização do CTE. Fonte: Adaptado [3, 4].

A fim de obter dados de boa qualidade para estimativa de ângulo, as amostras de IQ devem ser coletadas no mesmo ponto dentro de cada Janela de Amostragem de IQ. Segundo [49], a técnica de AoA requer que uma amostragem seja realizada para cada microssegundo dentro do período de referência e uma vez para cada janela de amostra. Essa janela de amostragem inicia  $0,125\mu s$  após o início do período de microssegundo e finaliza  $0,125\mu s$  antes do final de cada período de microssegundo. No caso onde os blocos de amostragem possuam  $2\mu s$ , como neste trabalho, a amostragem ocorre no último microssegundo conforme mostrado na Figura 3.10.

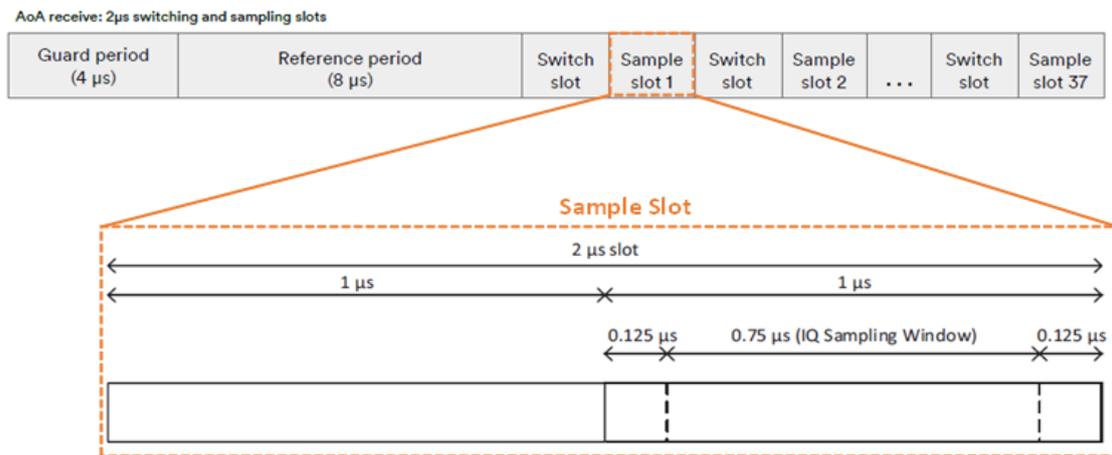


Figura 3.10: Janelas de amostragem para blocos de  $2\mu s$ . Fonte: Adaptado [3].

Assim, o receptor, ao receber um pacote que contém o CTE, deve realizar o chaveamento e a amostragem IQ e obter as informações de amplitude e fase para a realização do cálculo do ângulo de chegada do sinal.

### 3.3.5 Configurações e procedimentos para uso da técnica

As especificações do *Bluetooth* v5.1 para o controlador *Bluetooth* LE permitem que a técnica de AoA seja usada com ou sem o pareamento dos dispositivos. Neste trabalho será abordada a configuração sem pareamento ou *connectionless*. As configurações do controlador são realizadas através da interface denominada *Host Controller Interface* (HCI), onde a geração e recepção do CTE são ajustadas.

Na configuração *connectionless*, o *host* em um dispositivo *advertiser* deve executar etapas de inicialização do controlador para que pacotes de *advertising* expandidos e periódicos com CTE sejam gerados. Os passos para essa configuração são: Configurar o *advertising* expandido; Configurar o *advertising* periódico; Configurar a transmissão do CTE; habilitar o *advertising* com CTE; habilitar o *advertising* periódico; habilitar o *advertising* expandido; Definir os dados de *advertising*. Essas configurações realizadas na transmissão podem ser visualizadas na Figura 3.11.

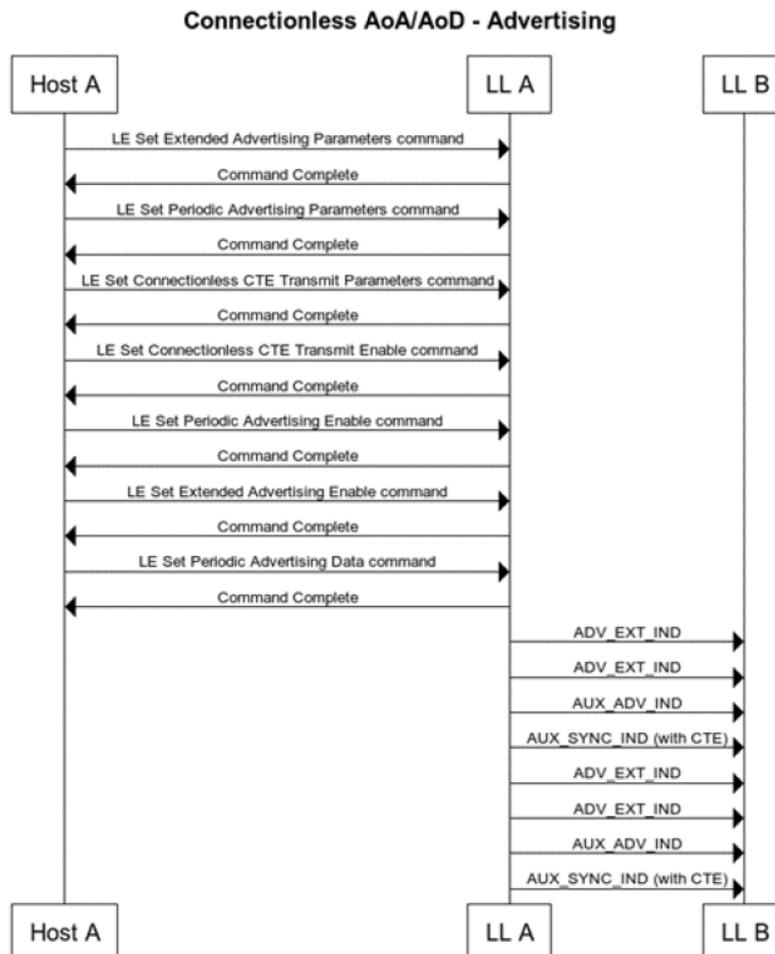


Figura 3.11: Comandos de configurações do HCI e transmissão do CTE no modo *connectionless*. Fonte: [1].

Já no lado do receptor ou dispositivo *Scanner* que deve receber e amostrar o CTE, são realizados quatro configurações no controlador para então receber e processar as amostras IQ que são: Configurar *Scanning* expandido; Iniciar o *Scanning* expandido; Sincronizar com o pacote periódico para sincronização recebido; Ativar amostragem IQ no modo *connectionless*. Essas configurações realizadas para a recepção são expostas na Figura 3.12.

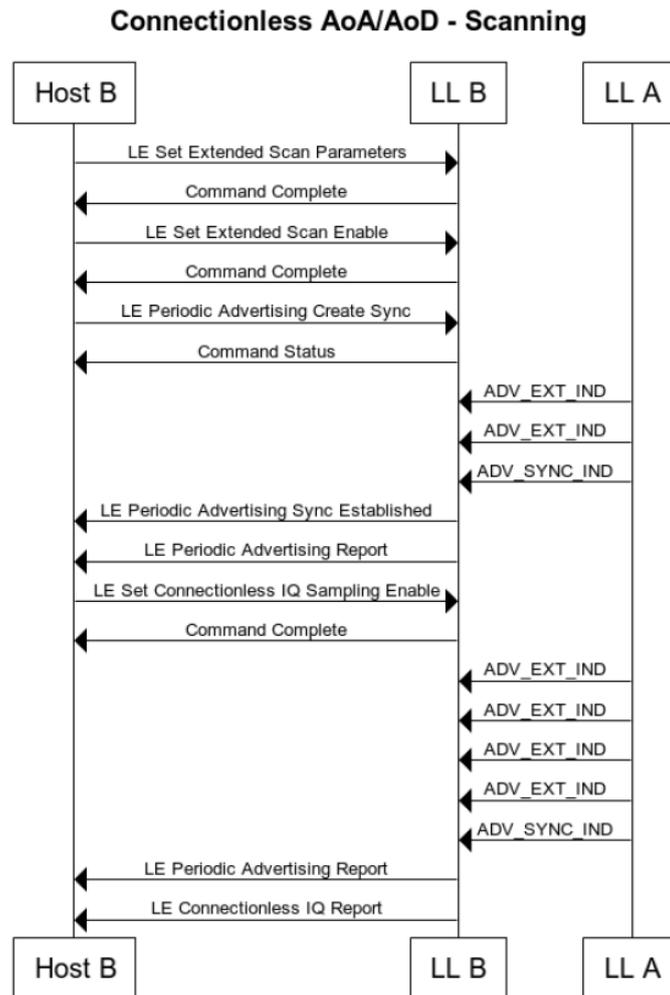


Figura 3.12: Comandos de configurações do HCI e recepção do CTE no modo *connectionless*. Fonte: [1].

Dessa forma é possível verificar o processo de configuração, geração, transmissão, recepção e amostragem dos sinais que possibilitam o emprego da técnica de AoA de *Direction finding* no modo *connectionless*.

### 3.4 Redes Neurais convolucionais

As redes neurais convolucionais, do inglês *Convolutional Neural Network*, são um tipo especializado de rede neural para processamento de dados que possui uma formato semelhante a uma grade. Assim, incluem dados de séries temporais como uma grade de uma dimensão coletando amostras em intervalos de tempo regulares e dados de imagem, que podem ser pensados como uma grade de duas dimensões de *pixels*, onde esses dados devem possuir forte dependência com as regiões adjacentes locais. As imagens, por exemplo, possuem essa característica de forte dependência espacial com regiões adjacentes, visto que geralmente apresentam valores de cor semelhantes dos *pixels* individuais.

As CNNs consistem em uma sequência de camadas, em que os neurônios de uma camada se conectam apenas a uma pequena região de neurônios da camada anterior, reduzindo substancialmente a quantidade de parâmetros da rede. As camadas que compõem essas redes são: camada de entrada de dados, camada de convolução, camada de ativação, camada de *pooling* e camada totalmente conectada. Vale ressaltar que a camada de ativação é frequentemente omitida das ilustrações de arquiteturas de CNN [7]. As camadas mencionadas acima são empregadas para alcançar efetivamente a extração e classificação de características dos dados de entrada. Existem várias arquiteturas de CNNs disponíveis que foram precursoras e são referências na construção dessa técnica. Algumas delas são: LeNet-5; AlexNet; VGGNet; GoogleNet; ResNet e ZFNet. A rede LeNet-5 foi empregada com o objetivo de reconhecer dígitos manuscritos em imagens [50] e sua arquitetura é exibida como um exemplo de redes dessa natureza na Figura 3.13.

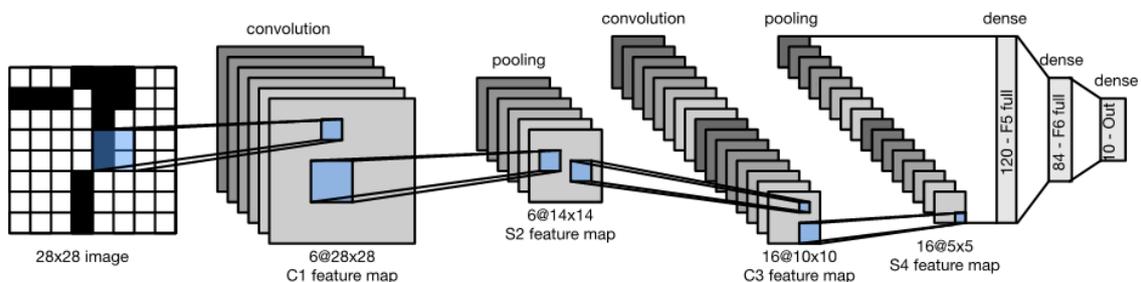


Figura 3.13: Arquitetura de rede convolutiva LeNet. Fonte: [5].

Nas subseções seguintes são abordadas os conceitos para a construção de uma rede convolutiva como a camada de convolução, filtro, conceitos de *padding*, funções

de ativação, camada de *pooling*, reformatação e, por fim, camada densa.

### 3.4.1 Camada de Convolução

Na terminologia de rede convolucional, o primeiro argumento para a convolução é frequentemente referido como a entrada e o segundo argumento como o *kernel*.

A etapa de convolução consiste no bloco de construção principal de uma rede neural convolucional em que o resultado consiste em um mapa de características, do inglês *feature map*. Em sua forma mais geral, a convolução é uma operação com duas funções de um argumento de valor real. No contexto das CNNs, essas duas funções são os elementos de entrada e o *kernel*, também denominado filtro. O *kernel* é convoluido ao longo da altura e largura dos dados de informação utilizando o produto escalar. Essa operação matemática pode ser visualizada na equação 3.2.

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i + m, j + n)K(m, m) \quad (3.2)$$

Onde  $I$  representa a entrada e  $K$  representa um *kernel*, ambos bidimensionais. A partir dessa operação, é construído um mapa de características também bidimensional desse *kernel*. Com isso, a CNN aprende rapidamente essas características, que são ativadas quando um determinado tipo de recurso em alguma posição espacial da entrada é observado.

### 3.4.2 Filtro

Os filtros, também denominados de *kernels*, são matrizes utilizadas no processo de convolução dos elementos de entrada. Eles possibilitam a extração de características relevantes dos dados. No caso de imagens, ele extrai características como, bordas, linhas verticais, horizontais e entre outras coisas. Eles são aplicados no modo de janela deslizante sobre uma imagem de entrada e, nesse processo, é realizado produto entre os elementos correspondentes da matriz. Dessa forma, a partir do somatório desse produto, é gerada uma nova matriz que será inserida na entrada da próxima camada. Isso pode ser visualizado na Figura 3.14.

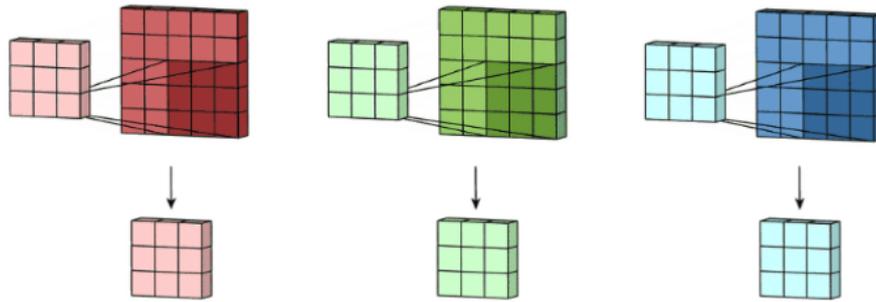


Figura 3.14: Três *kernels* aplicados à matrizes *Red*, *Green* e *Blue*. Fonte: [6].

### 3.4.3 *Padding*

A operação de convolução reduz o tamanho dos dados utilizados na entrada. Este tipo de redução de tamanho não é desejável em geral, pois tende a perder informações durante a extração de características. Para contornar esse problema, utiliza-se o *padding* que adiciona o valor 0 nas bordas da imagem para que, quando o *kernel* percorrer a matriz, não haja áreas perdidas na imagem. O processo de *padding* pode ser visualizado na Figura 3.15.

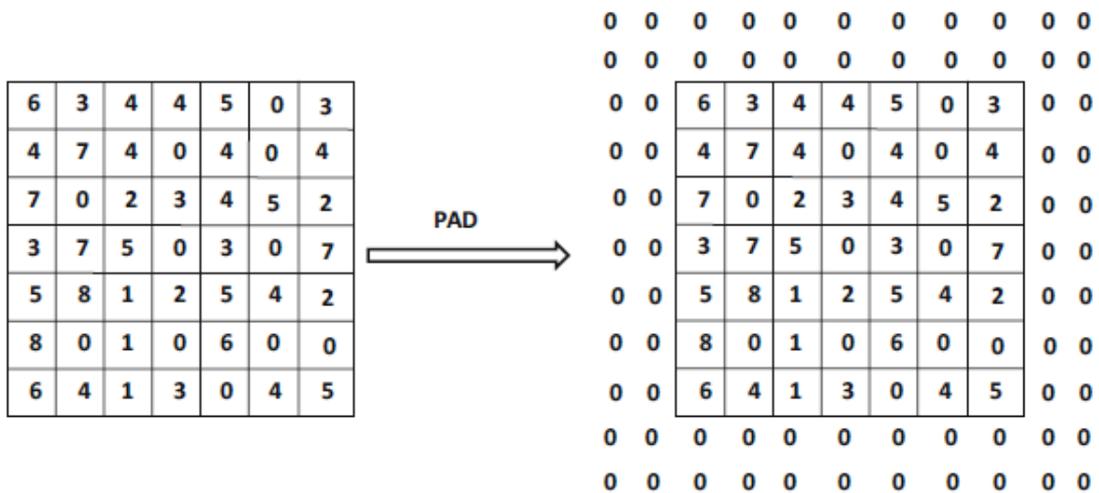


Figura 3.15: Exemplo de *padding*. Fonte: [7].

### 3.4.4 Camada de Pooling

A camada de *pooling* é responsável por realizar subamostragem na saída da convolução, ou seja, ajuda a reduzir continuamente a dimensionalidade para reduzir o número de parâmetros e cálculos na rede. Isso acarreta na diminuição do tempo

de treinamento e controla o *overfitting*. Essa técnica realiza a substituição de uma região da saída da rede com uma estatística dos valores vizinhos. A forma mais comum para aplicação de *pooling* é o *Max-pooling*, que assume o valor máximo em cada vizinhança. Esses tamanhos de janela precisam ser especificados com antecedência. Isso diminui o tamanho do mapa de características e, ao mesmo tempo, mantém as informações mais relevantes [51]. O processo de subamostragem baseado no maior vizinho é ilustrado na Figura 3.16

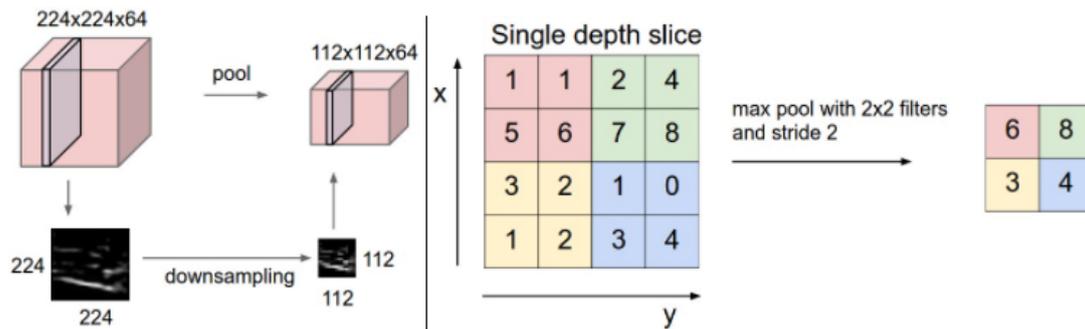


Figura 3.16: *Max-pooling* com filtros de ordem 2. Fonte: [6].

### 3.4.5 Camada Densa

Essa camada funciona exatamente da mesma maneira que uma rede *feed-forward* tradicional. Na maioria dos casos, pode-se usar mais de uma camada totalmente conectada para aumentar o poder de cálculo do modelo. As conexões entre essas camadas são estruturadas exatamente como uma rede *feed-forward* tradicional. Como essa camada possui muitos nós conectados, nela se situam a grande maioria dos parâmetros, acarretando em um maior custo computacional para o modelo. A entrada para a camada densa é a saída da Camada Pooling ou Convolutiva final, que é nivelada e, em seguida, alimentada na camada totalmente conectada.

### 3.4.6 Função de Ativação ReLU

Em uma rede neural, a função de ativação é responsável por transformar as entradas somadas em uma saída. A função de unidade linear retificada, ou ReLU, é uma função de ativação não linear cuja principal vantagem é a não ativação todos os neurônios simultaneamente. Quando sua entrada assume valores negativos, a

saída será convertida em 0 e o neurônio não será ativado. Do contrário, o neurônio será ativado e receberá o valor da entrada. Essa característica pode ser expressa conforme mostrado na equação 3.3.

$$ReLU(x) = \max(0, x) \quad (3.3)$$

## 3.4.7 Métodos de otimização

### 3.4.7.1 Método Adam

Do inglês *Adaptive Moment Estimation*, este é um dos otimizadores mais utilizados em redes neurais pelo baixo tempo de convergência em redes multicamadas ou convolucionais. Em vez de usar todo o conjunto de dados para calcular o gradiente, este algoritmo usa um subconjunto de dados selecionado aleatoriamente para criar uma aproximação estocástica [52].

## 3.4.8 Métrica de avaliação

### 3.4.8.1 Mean Absolute Error - MAE

O erro médio absoluto (MAE) também é uma métrica de avaliação comumente utilizada para medir o desempenho de modelos de regressão. O MAE fornece uma medida direta da magnitude média dos erros entre os valores preditos pelo modelo,  $y_i$ , e os valores esperados,  $\hat{y}_i$ . Ao contrário do RMSE, o MAE considera apenas as diferenças absolutas, não elevando os erros ao quadrado. A expressão matemática para o MAE é dada pela equação 3.4.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.4)$$

Uma das vantagens do MAE é que a métrica é expressa na mesma unidade da variável dependente, o que facilita a interpretação dos resultados e permite uma comparação direta entre diferentes modelos. Por isso o MAE é uma métrica simples e para avaliar modelos de regressão devido sua interpretação direta, facilidade de comparação entre modelos e robustez em relação a *outliers*. No entanto, é importante considerar a relevância da magnitude dos erros e a sensibilidade a outliers ao

selecionar a métrica mais apropriada para a tarefa de avaliação [53].

## 3.5 Dispositivos de *Hardware*

Nesta subseção apresentaremos os dispositivos de hardware utilizados na proposta deste trabalho.

### 3.5.1 Kit de desenvolvimento nRF52833

O kit de desenvolvimento possui até 32 portas de entrada e saída de uso geral (General Purpose Inputs/Outputs - GPIOs), além de uma antena integrada na placa para sinais em 2.4GHz e um conector para acoplamento de antenas externas. O kit é construído em torno do (*System on Chip* (SoC) nRF52833 da empresa *Nordic*. Ele suporta os protocolos *Bluetooth* 5.3, *Bluetooth mesh*, 802.15.4, *Thread* e *Zigbee*. O nRF52833 tem memória flash de 512 KB e memória RAM de 128 KB. Ele foi utilizado para a realização da transmissão e recepção de sinal *bluetooth* durante os experimentos. A escolha desse kit ocorreu devido à versão do *bluetooth* 5.3 compatível com a funcionalidade de *Direction Finding* além de dispor de vasta documentação acerca das configurações a serem empregadas em seu *firmware*. Na Figura 3.17, é possível visualizar o kit de desenvolvimento supracitado.



Figura 3.17: Kit de desenvolvimento nRF52833. Fonte: Adaptado [8].

### 3.5.2 *Array* de antenas

A fim de realizar a amostragem do sinal, em várias antenas, conforme preconizado no documento técnico de *Direction Finding* [54] a partir do *bluetooth* versão 5.1, utilizou-se o *array* modelo PCA20054 com doze antenas da fabricante *Nordic Semiconductor*. Esse *array* emprega cinco *switches* de rádio frequência referência PE42442 a fim de chavear suas antenas para uma única entrada de rádio. O controle desse chaveamento se dá pelo acionamento de quatro sinais com entradas disponíveis em conector do tipo *header* disposto em sua parte inferior. Por meio desse mesmo conector, ocorre a alimentação elétrica da placa e o seu posicionamento mecânico é compatível para o acoplamento com o kit de desenvolvimento nRF52833. Por fim, para conectar a antena em um rádio receptor, há também um conector do tipo *Sub Miniature Version A* (SMA) fêmea. A Figura 3.18a mostra parte superior do *array* onde estão os *switches* de Rádio frequência e as antenas, e a Figura 3.18b é possível visualizar a parte inferior, onde estão o conector do tipo *header*, o conector SMA e o suporte mecânico que acompanha o *array* PCA20054.

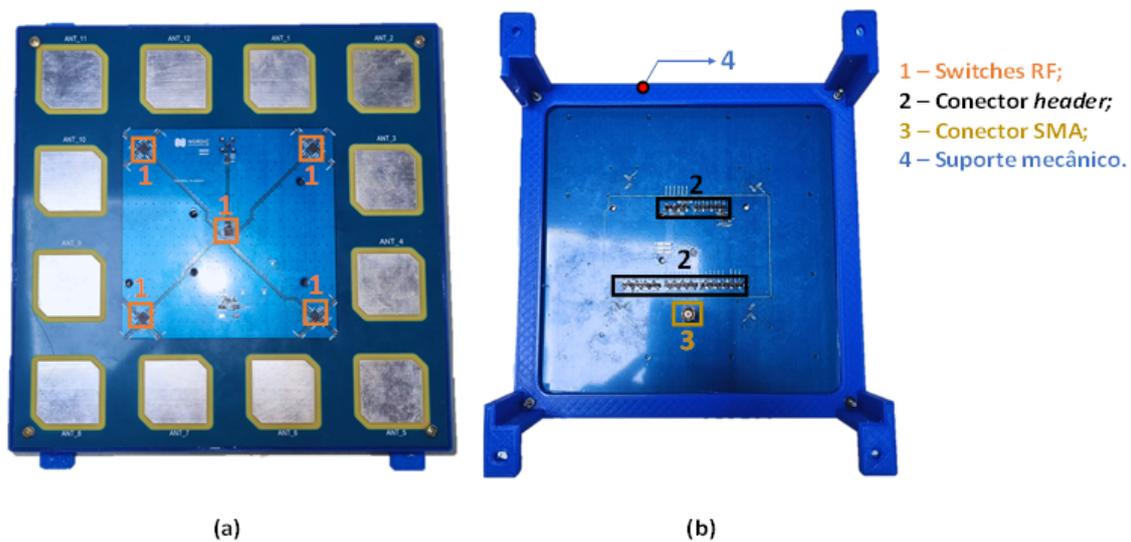


Figura 3.18: *Array* de antenas modelo PCA20054 do fabricante Nordic Semiconductor acoplado ao suporte. (a) Vista superior. (b) Vista inferior. Fonte: Própria.

A fim de melhor representar o papel do *array* e sua disposição no experimento, é possível considerá-lo como um elemento com entradas e saídas. As entradas do *array* são as GPIOs de controle do chaveamento das antenas enquanto a saída é um sinal de rádio captado na antena selecionada. Essa representação pode ser

visualizada na Figura 3.19.

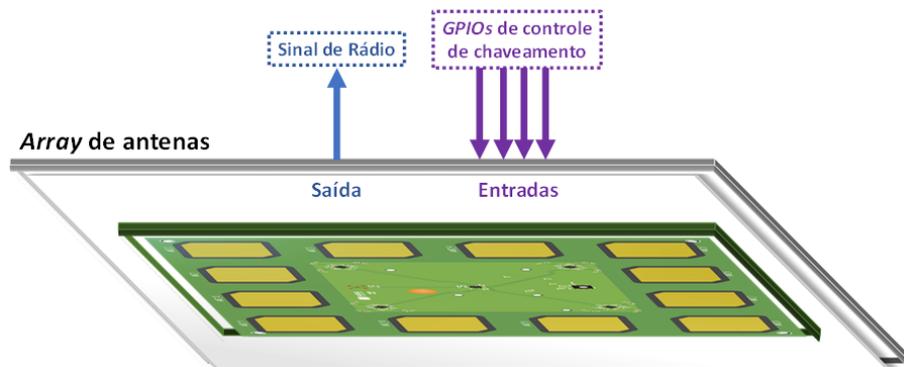


Figura 3.19: Representação das entradas e saída do *array* de antenas. Fonte: Própria.

# Capítulo 4

## Metodologia

Neste capítulo, serão apresentados os aspectos metodológicos da pesquisa realizada, abordando os procedimentos necessários para implementar um método baseado em *deep learning* e que emprega amostras IQ de sinais para prever o AoA de sinais de rádio bluetooth transmitidos em ambientes internos.

Essa investigação possui natureza aplicada, buscando utilizar conhecimentos teóricos em um contexto prático. A metodologia empregada para atingir os objetivos propostos envolve uma abordagem quantitativa, visando a coleta e análise de dados numéricos e estatísticos, essenciais para a compreensão do experimento em estudo.

Além disso, neste trabalho foi adotada uma abordagem explicativa que busca analisar as relações entre variáveis, permitindo-nos compreender a existência de padrões e tendências no processo de predição do AoA empregando *deep learning* com sinais de rádio bluetooth.

A Figura 4.1 ilustra, em um diagrama de blocos as duas grandes etapas utilizadas no desenvolvimento, validação e avaliação de desempenho deste trabalho chamadas de: i) etapa de aquisição de dados, subdividida em validação do array de antenas e criação de base de dados; ii) e, etapa de criação e validação do modelo, sendo dividida em 5 sub-etapas conforme ilustrado na figura.

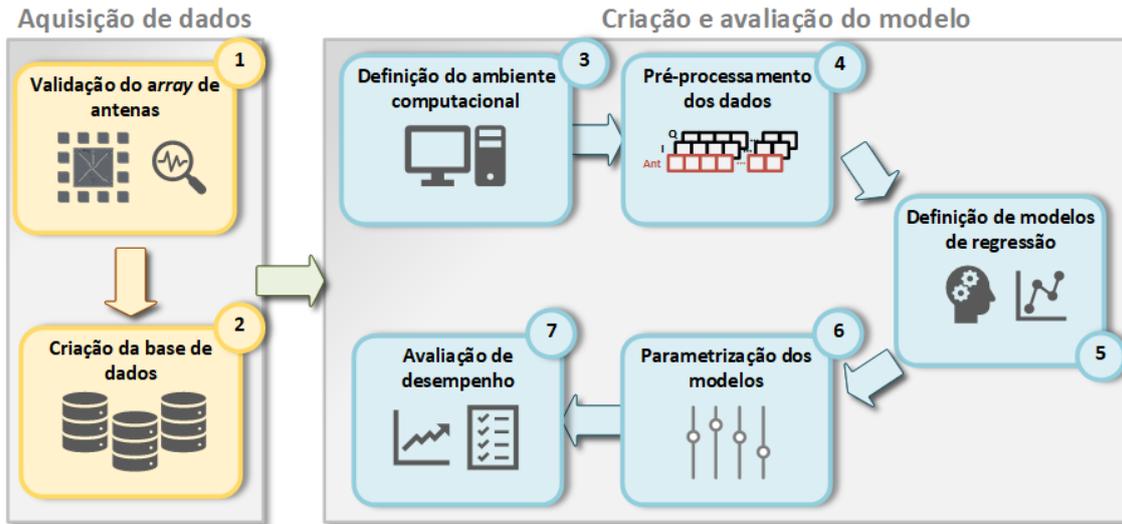


Figura 4.1: Etapas utilizadas no desenvolvimento, validação e avaliação de desempenho

As próximas seções deste capítulo abordam o detalhamento de cada sub-etape apresentada na Figura 4.1. A seção 4.1 mostra os passos para a validação do correto funcionamento do *array* utilizado; A seção 4.2 expõe os procedimentos utilizados para a criação da base de dados, incluindo as informações do cenário e metodologia para a realização da coleta de dados; Na seção 4.3 são expostos os procedimentos utilizados no pré-processamento dos dados coletados, desde sua limpeza até a formatação para inseri-los nos algoritmos avaliados. Na seção 4.4 são apresentadas as definições dos modelos de regressão implementados e avaliados no trabalho. A seção 4.5 expõe os procedimentos utilizados na parametrização dos modelos e, por fim, a seção 4.7 apresenta como foi realizada a avaliação de desempenho dos algoritmos gerados.

## 4.1 Validação do *array* de antenas

A validação do correto funcionamento do *array* de antenas foi necessária, pois houve apenas a disponibilização do *array*. Dessa forma, a montagem dos componentes no *array* foi realizada em laboratório, podendo acarretar em problemas nos processos subsequentes do experimento. A validação consistiu na verificação de recepção de um sinal de 2,4GHz em cada antena individualmente. Para executar a validação, foi utilizado: 1) Um notebook com *software* proprietário para configu-

ração de um Vector Network Analyzers (VNA); 2) O VNA denominado LibreVNA para a geração do sinal em 2,4GHz; 3) uma antena para transmissão do sinal; 4) o kit nRF52833 acoplado ao *array* para a acionamento de uma antena por vez; 5) um osciloscópio MDO4104-3 da Tektronix para leitura do sinal que chegava até a antena selecionada via *firmware* no *array* e suas respectivas conexões. A Figura 4.2 mostra um diagrama em bloco representando as conexões entre os dispositivos utilizados no processo de validação.

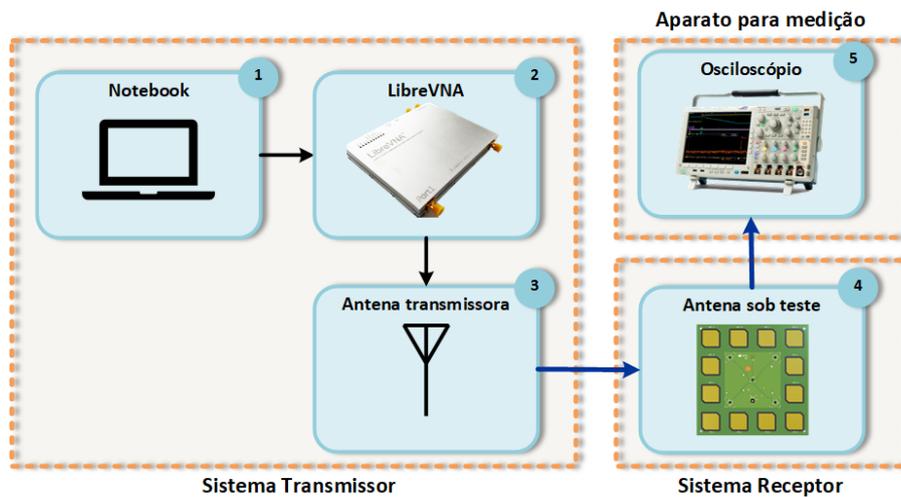


Figura 4.2: Configuração de conexões para validação do *array*

Foi utilizado o notebook e o software LibreVNA para configurar o VNA para geração de um sinal na banda de 2,4GHz do Bluetooth. Em seguida, aproximou-se a antena transmissora, acoplada ao VNA, de cada antena individualmente previamente selecionada via *firmware* no array. Por fim, foi utilizado o osciloscópio para ler e verificar a potência recebida pela antena do *array* sob teste. Esse processo foi realizado para cada antena do *array*. A Figura 4.3 apresenta a antena transmissora emitindo o sinal em 2,4GHz, enquanto a antena sob teste recebe o sinal e a potência do sinal recebido pela antena sob teste é mostrada na tela do osciloscópio.

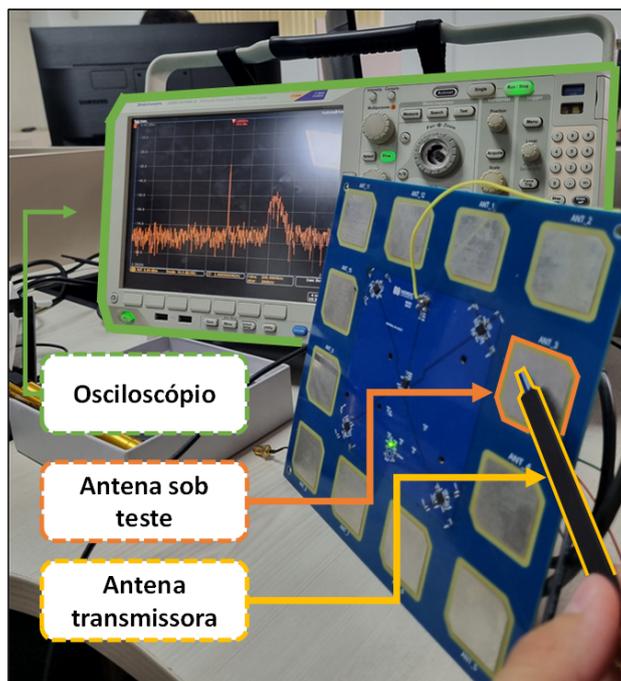


Figura 4.3: Realização da validação de uma antenna individual do *array*

## 4.2 Criação da base de dados

A criação da base de dados é essencial para a geração de modelos de regressão. Nesta seção, inicialmente serão abordadas as configurações de conexões entre os dispositivos utilizados no experimento, em seguida serão apresentadas as informações acerca do cenário de coleta e por fim a metodologia utilizada para sua realização.

### 4.2.1 Configuração de conexões dos dispositivos

Conforme a Figura 4.4, O transmissor se trata de um kit nRF52833 que funciona em modo *standalone*, utiliza a antenna integrada na placa para a realização da transmissão e possui uma bateria do tipo moeda conectada como fonte de energia.

O localizador, por sua vez, é composto por um kit nRF52833 que possui GPIOs para controle das antenas do *array* PCA20054. O kit nRF52833 também se conecta ao *array* por meio de um cabo coaxial de quinze centímetros para interconexão entre o *array* PCA20054 e o rádio do nRF52833. No lado do kit, o conector utilizado é do tipo *miniature surface-mount RF* para montagem em superfícies de placas e no *array* é do tipo SMA (SubMiniature version A) Fêmea. O elemento localizador possui como fonte de energia o cabo USB vindo do notebook. Ao receber o sinal de rádio encaminhado pelo transmissor, o localizador, de maneira cíclica,

realiza o chaveamento entre o rádio no kit nRF52833 e cada uma das antenas do *array* PCA20054. Após isso o nRF52833 encaminha as amostras I e Q dos sinais recebidos e o respectivo ID da antena de coleta ao notebook, através do cabo USB. No notebook, é utilizado o terminal serial do *software* Visual Studio Code para a recepção dessas amostras. A Figura 4.4 ilustra as conexões entre os elementos comentados.

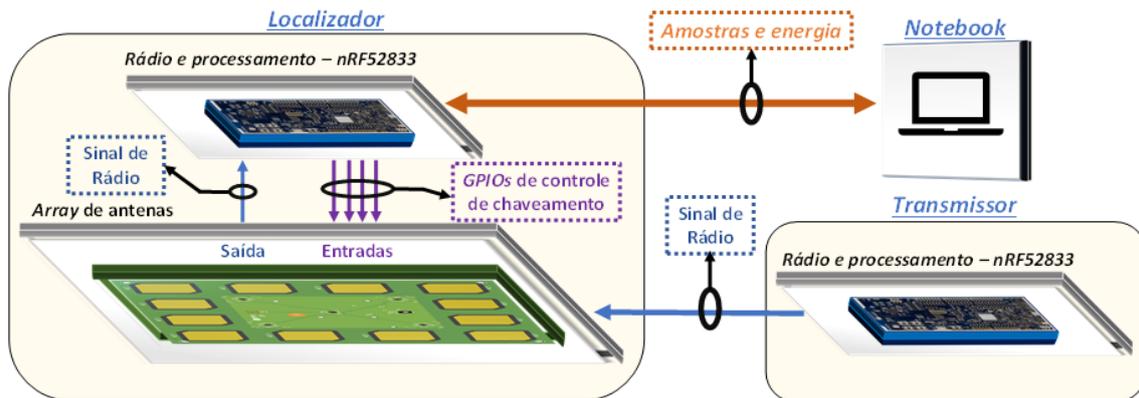


Figura 4.4: Diagrama de conexões entre os dispositivos

## 4.2.2 Cenário da coleta de dados

A coleta de dados para a realização dos experimentos ocorreram no laboratório B18 da Escola Superior de Tecnologia da Universidade do Estado do Amazonas (UEA-EST), localizado na cidade de Manaus no estado do Amazonas. A sala possui dimensões de 6,80x7,20x3,13m, totalizando aproximadamente 49 metros quadrados, e dispõe de mesas, cadeiras e armários. A Figura 4.5a mostra uma visão geral do laboratório B18, enquanto Figura 4.5b apresenta a disposição dos dispositivos durante uma das coletas.

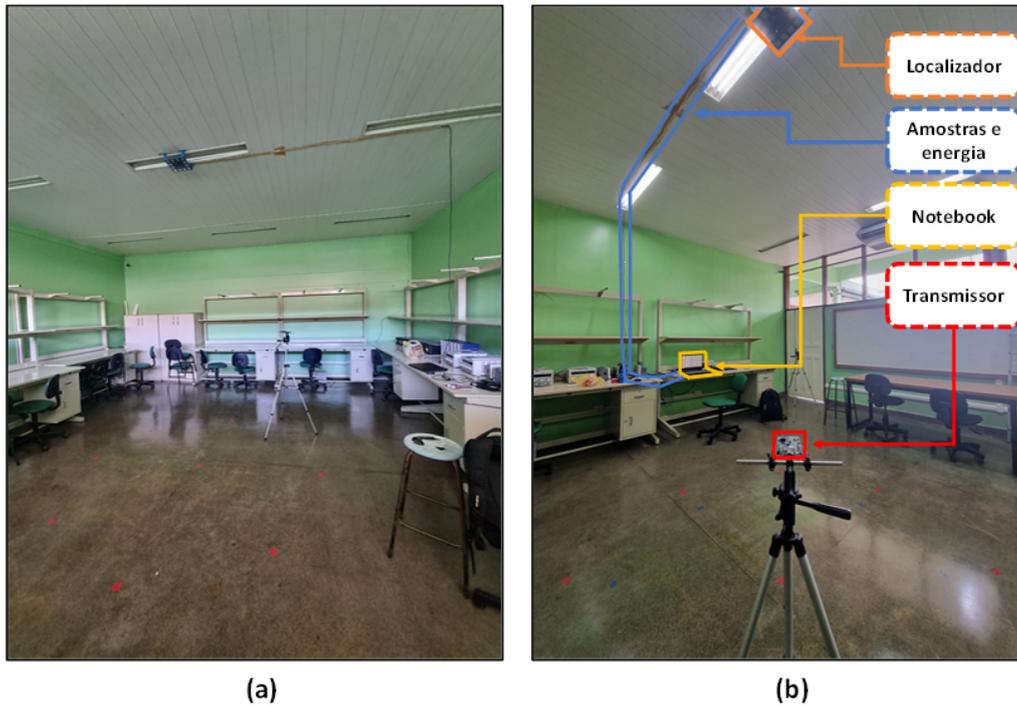


Figura 4.5: (a) Laboratório B18 da Escola Superior de Tecnologia. (b) Elementos utilizados e suas conexões.

A instalação do transmissor consistiu no seu acoplamento a um tripé a fim de se manter com posição fixa do transmissor durante a coleta de dados. A altura do chão até o kit nRF52833 transmissor foi de 1,05m e seu acoplamento ao tripé possibilitou que o kit permanecesse disposto de forma paralela ao chão durante toda a coleta. A Figura 4.6a, 4.6b e 4.6c apresentam as vistas laterais esquerda, direita e visão superior, respectivamente, do transmissor acoplado ao tripé.

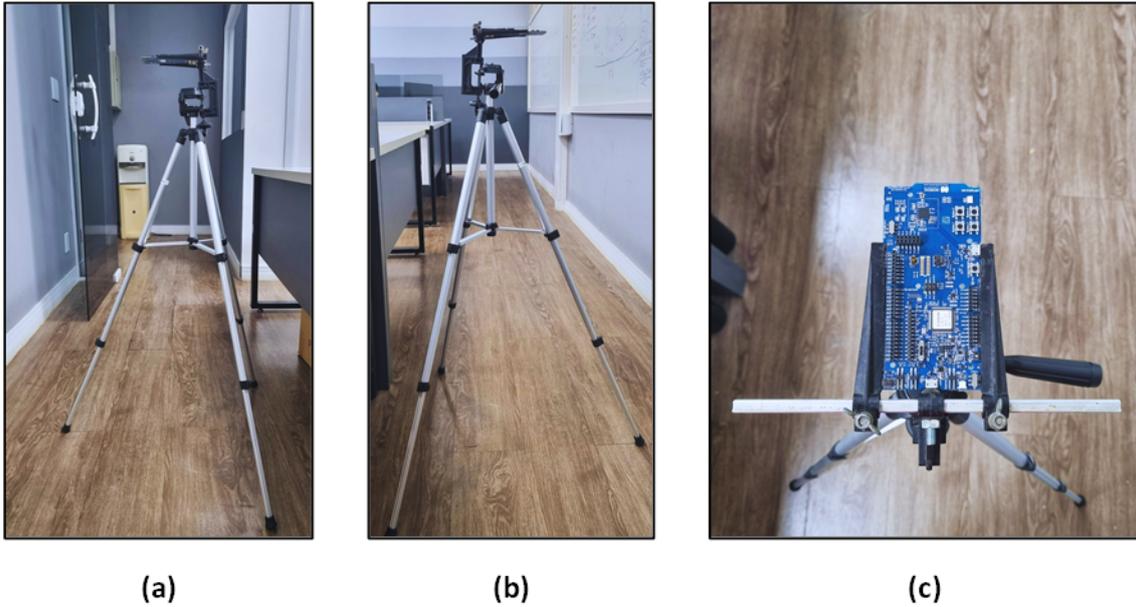


Figura 4.6: Vistas do Transmissor acoplado ao tripé. (a)Lateral esquerda. (b) Lateral direita. (c)Superior.

Quanto ao localizador, já acoplado ao seu suporte conforme mostrado na Figura 3.18, foi instalado no teto da sala a uma altura de 3,08m do chão.

Em seguida, conforme Figura 4.7, foi marcado no chão do laboratório B18 o ponto central do círculo de coleta alinhado com o centro da antena de número 11 do *array*. A partir desse ponto central marcado no chão, foram também marcados no piso, com um raio de 0,90m a partir do ponto central, os pontos de coleta correspondentes aos ângulos de  $0^{\circ}$ ,  $45^{\circ}$ ,  $90^{\circ}$ ,  $135^{\circ}$ ,  $180^{\circ}$ ,  $225^{\circ}$ ,  $270^{\circ}$  e  $315^{\circ}$  completando o círculo com um passo de  $45^{\circ}$ . A Figura 4.7 ilustra, em uma planta baixa, os pontos de coletas marcados em vermelho, o posicionamento do *array* de antena no laboratório e dimensionais da sala.

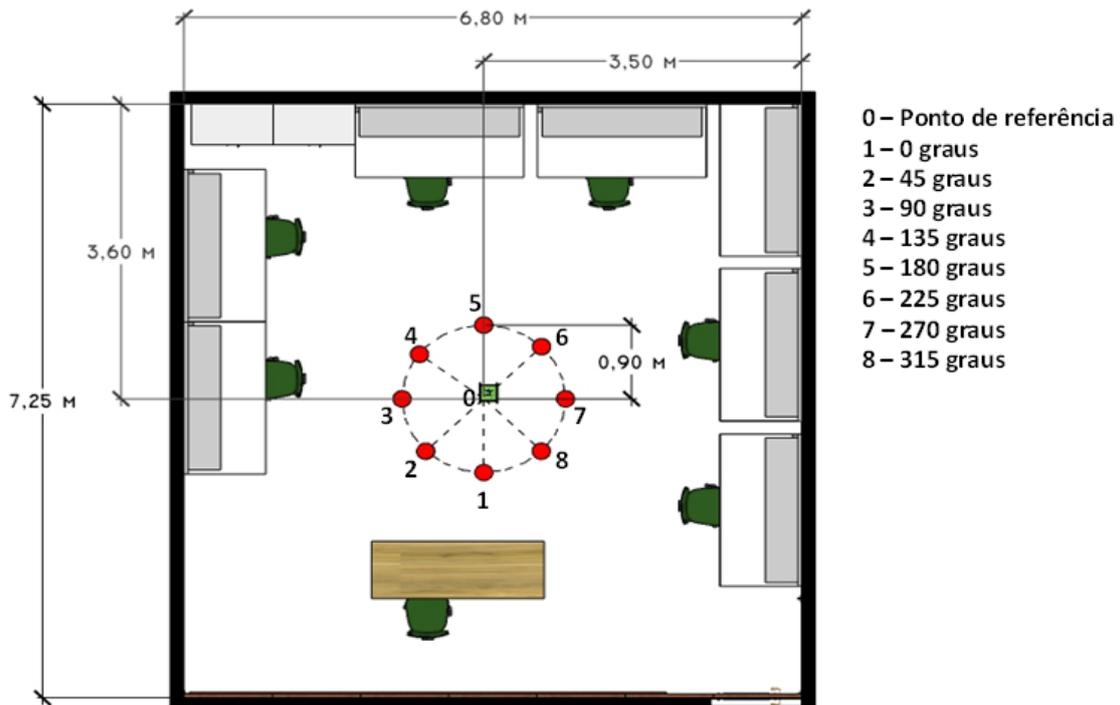


Figura 4.7: Planta baixa com indicações dos pontos de coleta e ponto central.

A Figura 4.8 apresenta uma vista em corte contendo as informações dimensionais sobre a altura em relação ao chão do localizador e do transmissor, 3,08m e 1,06m respectivamente, a altura/distância de separação entre o localizador e transmissor de 2,08m e posição do notebook no momento da realização da coleta de dados.

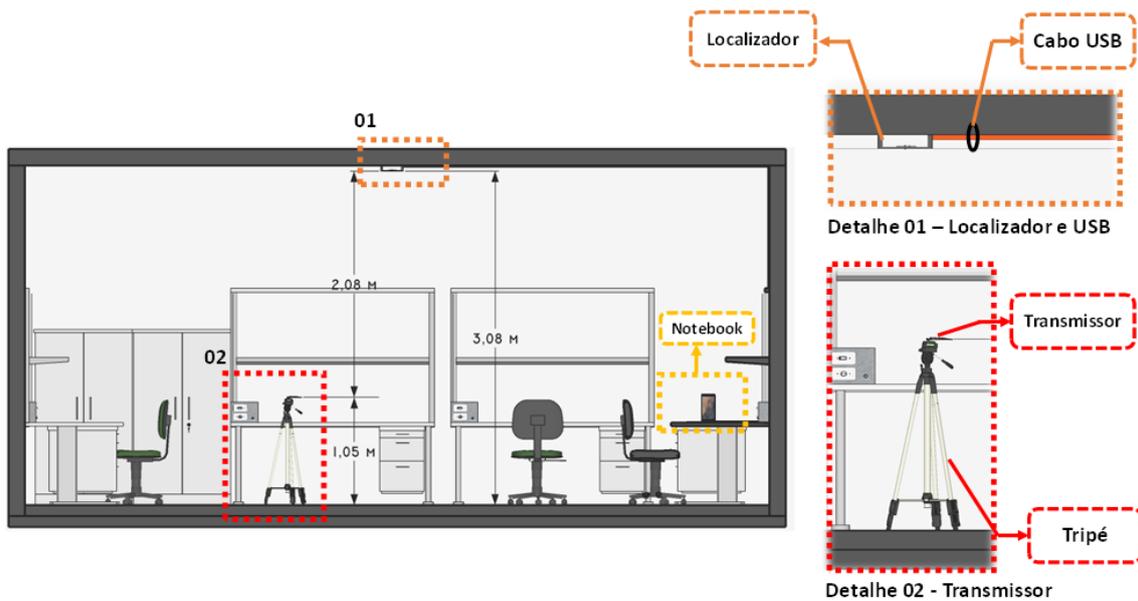


Figura 4.8: Vista do laboratório B18 com dispositivos de coleta.

Vale ressaltar também que no ambiente de coleta de dados, haviam redes de comunicação Wi-Fi comunicando na mesma faixa de frequência de 2,4GHz que o *bluetooth*. Na Tabela 4.1 são listadas essas redes e respectiva potência no ponto central do laboratório em questão.

Tabela 4.1: Redes Wi-Fi na faixa de 2,4GHz no laboratório

Rede Wi-Fi	Potência de recepção (dbm)	Canal (MHz)
STEM-NET	-47	2437
CTIC-FAST	-64	2462
DIRECT-jW-BRAVIA	-68	2457
UEA-CSTB	-68	2462
UEA-ENS	-68	2462
UEA-ESO	-68	2462
UEA-LCPM	-69	2422
UEA-EDU	-69	2412

### 4.2.3 Metodologia da coleta de dados

A etapa de coleta de dados, pressupõe a correta conexão dos dispositivos utilizados na Figura 4.4. Nos experimentos, posicionou-se o transmissor no primeiro ponto de coleta 7 correspondente à 0<sup>o</sup> medido a partir do ponto central do círculo da Figura 4.7. Após o correto posicionamento, verificou-se se os dados estavam chegando ao notebook através do terminal serial do *software* Visual Studio Code (VSCode), onde o tamanho máximo do *buffer* armazenado no terminal é de mil linhas. Após vinte segundos de coleta dos dados no terminal do *software* VSCode, realizou-se o salvamento dos dados do *buffer* do terminal. Esse processo foi repetido para cada um dos oito pontos.

Em cada um dos pontos do círculo foram coletados dez conjuntos de dados, resultando em dez arquivos no formato ".txt" para cada ponto de coleta. Sendo assim, para os oito pontos de coleta de dados, totalizaram oitenta arquivos com dados brutos coletados. Em cada um dos oitenta arquivos, a quantidade mínima e máxima de linhas geradas com a coleta de dados brutos (dados com informações das componentes I e Q dos sinais e informação da antena coletora do array) foi de novecentas e noventa e cinco e novecentas e noventa e sete linhas, respectivamente. Essa quantidade de linhas por arquivo para cada ponto de coleta pode ser visualizado na Tabela 4.2.

Tabela 4.2: Quantidade de linhas por arquivo de cada ponto de coleta da base de dados.

	0°	45°	90°	135°	180°	225°	270°	315°
<b>Arquivo 1</b>	996	996	996	996	996	997	997	996
<b>Arquivo 2</b>	996	995	995	996	995	996	997	997
<b>Arquivo 3</b>	997	996	996	995	997	996	997	996
<b>Arquivo 4</b>	997	996	997	995	996	996	996	996
<b>Arquivo 5</b>	995	997	995	995	997	996	996	996
<b>Arquivo 6</b>	996	995	997	995	996	996	996	995
<b>Arquivo 7</b>	995	996	995	996	997	995	996	997
<b>Arquivo 8</b>	996	996	997	995	997	996	997	996
<b>Arquivo 9</b>	997	996	997	996	996	997	997	995
<b>Arquivo 10</b>	996	995	996	997	996	996	997	996
<b>Subtotal:</b>	9.961	9.958	9.961	9.956	9.963	9.961	9.966	9.960
<b>Total:</b>	<b>79.686</b>							

### 4.3 Definição do ambiente computacional

O sistema computacional empregado nas experimentações consistiu em um processador do modelo Intel Core i5-11400H, com clock de 2.70GHz, 16 GB de memória RAM, GPU GeForce GTX 1650 de 4 GB e 500 GB de SSD.

O ambiente colaborativo Google Colab foi utilizado para a realização da modelagem do banco de dados, realização dos experimentos e análise de desempenho. Adotou-se a linguagem de programação python. Foram importados os pacotes Tensorflow v2.9.1, Keras v2.9.0, Pandas v1.3.5, Numpy v1.21.6 e Matplotlib v3.2.2.

### 4.4 Pré-processamento dos dados coletados

A etapa de pré-processamento teve como ponto de partida a avaliação dos arquivos gerados por meio do salvamento do terminal serial do *software* Visual Studio Code.

Cada arquivo de medição gerado nos 8 pontos de coleta, armazenava o identificador da amostra (ID\_amostra), variando de zero a trinta e cinco, um identificador da antena (ID\_antena) e o valor das componentes I e Q do sinal amostrado na antena. Além disso, possuía também caracteres e palavras de uso do *software* proprietário da Nordic. Inicialmente, tais caracteres e palavras foram retirados e

em seguida foram retiradas também as colunas correspondentes ao ID da amostra citado acima. Com isso, as informações a serem utilizadas para gerar a regressão deste trabalho consistiu no valor das amostras I e Q e o identificador da antena que realizou a respectiva amostra. Esse processo de remoção pode ser visualizado na Figura 4.9

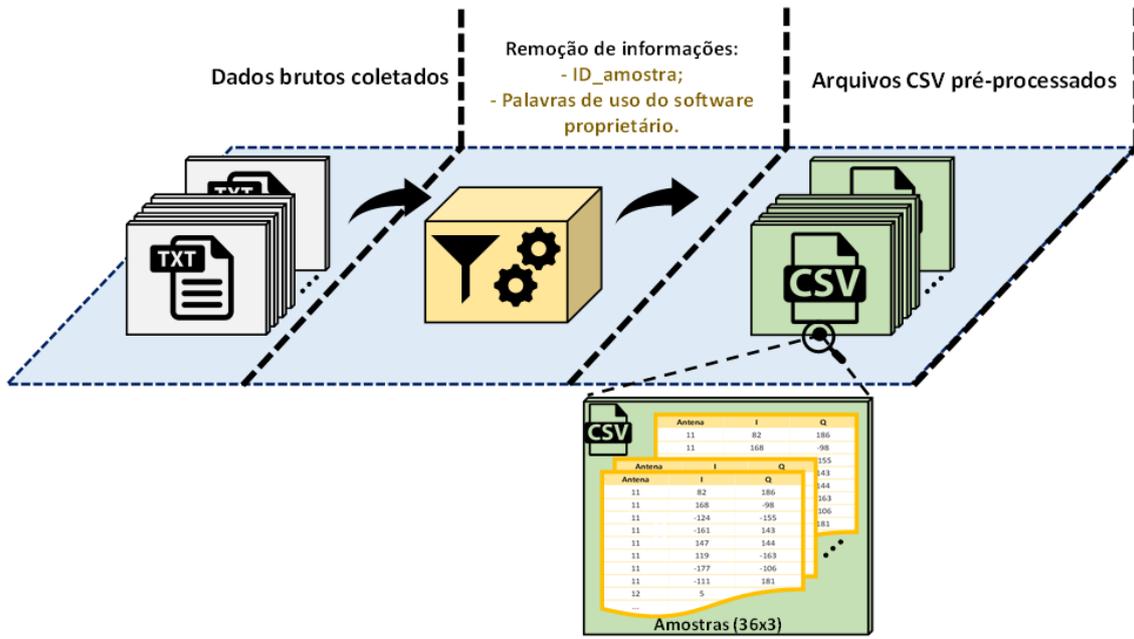


Figura 4.9: Pré-processamento da base de dados.

Assim, cada uma das trinta e seis amostras de um arquivo de dados coletados armazenou três colunas (Antena, I e Q) e trinta e seis linhas conforme apresentado é na Tabela 4.3.

Tabela 4.3: Parte das amostras IQ correspondente a um pacote *bluetooth*

Antena	I	Q
11	82	186
11	168	-98
11	-124	-155
11	-161	143
11	147	144
11	119	-163
11	-177	-106
11	-111	181
12	5	-112
...	...	...

Vale ressaltar que a resolução das amostras I e Q, segundo a folha de dados do nRF52833, é de doze bits sinalizados, enquanto a antena assume valores de um a

doze, devido o *array* ter sido configurado para coletar amostras de sinais utilizando todas as antenas presentes no equipamento. A fim de visualizar as amostras I e Q e suas características de defasagem, a Figura 4.10 mostra trinta e seis amostras que correspondem a um pacote *bluetooth* recebido.

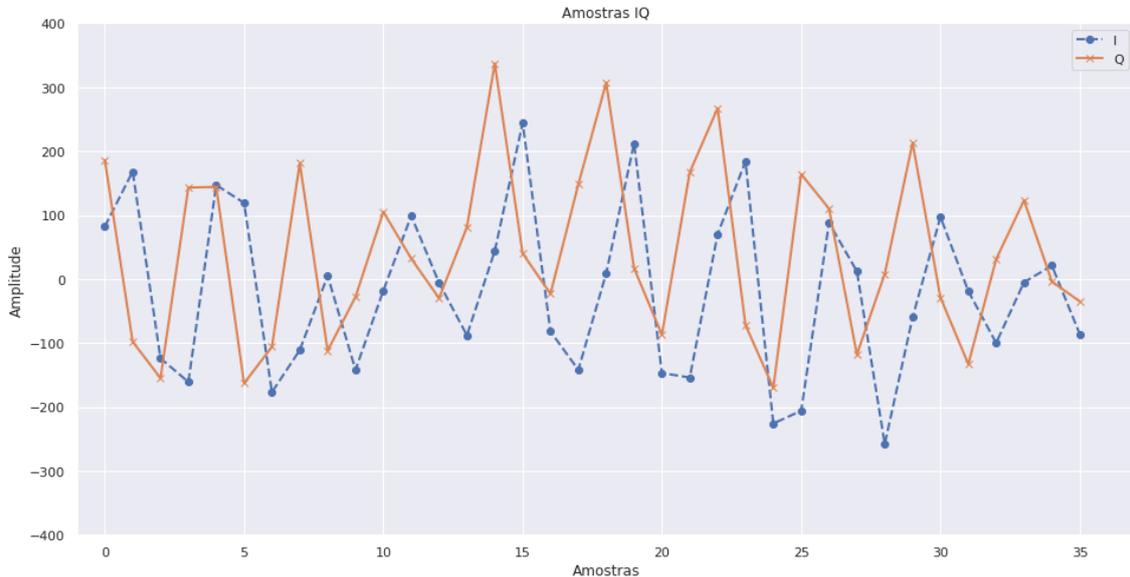


Figura 4.10: Representação gráfica das amostras I e Q.

Para o Modelo proposto, detalhado na próxima seção, o formato dos dados de entrada adotado possuía três canais, onde cada canal possuía uma linha com trinta e seis colunas, contendo cada canal informações das antenas, amostras I e amostras Q, respectivamente. Dessa forma, o formato de um conjunto de dados de entrada para o modelo de regressão proposto teve valores  $(1,36,3)$  para as dimensões de linha, coluna e canal conforme mostra a Figura 4.11.

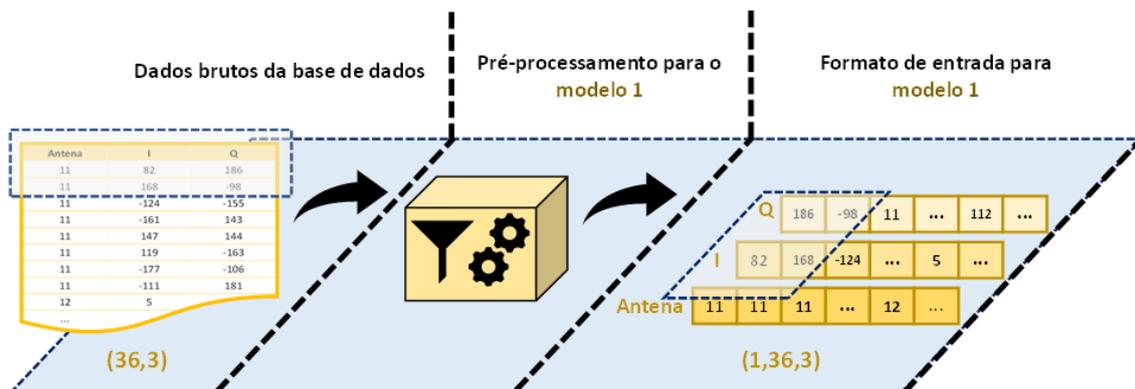


Figura 4.11: Formato dos dados de entrada do modelo de regressão proposto.

## 4.5 Definição do modelo de regressão

O Modelo de regressão proposto nesse estudo consiste em uma rede neural profunda para predição do ângulo de chegada de um sinal *Bluetooth* a um array de antenas.

Os dados de entrada da rede possuem trinta e seis características e três canais de entrada, resultando no formato de  $1 \times 36 \times 3$ . Na primeira arquitetura, uma rede neural convolutiva com duas camadas convolucionais de uma dimensão e função de ativação ReLU foram utilizadas para extração de características. A primeira camada convolucional possui dimensão de entrada de  $36 \times 64$ . Essa camada é seguida de uma camada de *average pooling* para subamostragem resultando em tamanho metade dos valores da informação dos valores resultantes da convolução da primeira camada. A terceira camada realiza novamente convolução com dimensão de  $18 \times 64$  e também é sucedida por outra camada de *average pooling*, finalizando a etapa de extração de características. Em seguida, é realizado o *flatten* ou a reformatação dos dados para uma dimensão de  $1 \times 576$  que são repassados por uma camada densa de  $1 \times 32$ , formando assim a rede densa. Por fim, a camada de saída é composta por um neurônio que irá realizar a regressão. Ressalta-se que os valores de subamostragem em todas as camadas de *pooling* foram variadas de maneira conjunta, onde a subamostragem para metade do valor de entrada foi a que obteve o melhor resultado. Após essa definição, a quantidade de filtros em cada camada de convolução foi selecionada por experimentação iniciando em 16 e chegando em 64, com um passo de 8 unidades, onde o melhor resultado encontrado foi no formato apresentado no modelo proposto que pode ser visualizado na Figura 4.12.

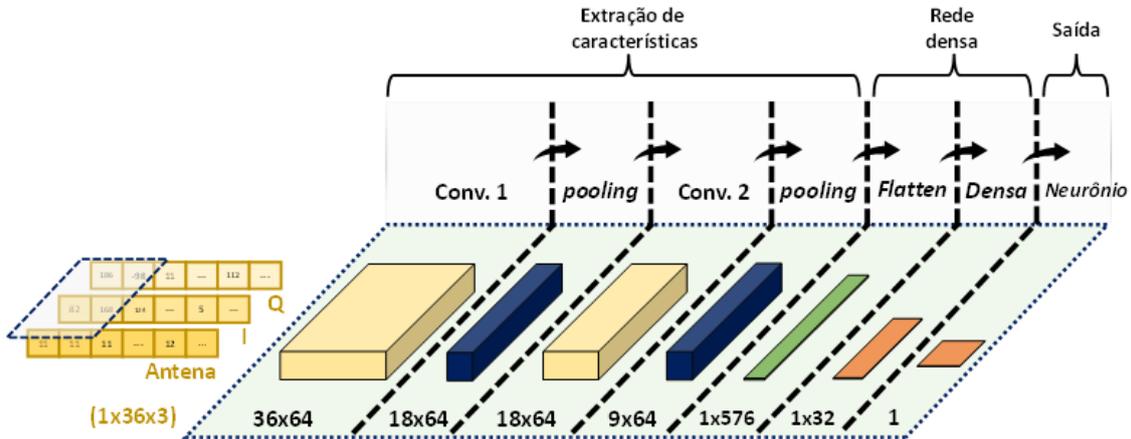


Figura 4.12: Arquitetura proposta.

## 4.6 Parametrização do modelo

O modelo e suas camadas possuem características configuráveis como quantidade de filtros, tamanho do kernel, passo da convolução, a realização de *padding*, normalização de dados e funções de ativação utilizadas. A Tabela 4.4 apresenta essas informações a fim de elucidar essas características.

Tabela 4.4: Detalhamento do Modelo 1

Modelo 1 - CNN			
Camada	Função	Características	Saída
Camada 1	Convolutiva	- Quantidade de filtros: 64; - Tamanho do Kernel: 8; - Passo da convolução:1; - Realização de padding: Sim.	36x64
Camada 2	Avarage pooling	- Tamanho do pool: 2	18x64
	Batch normalization	- Não se aplica	
	Função de ativação	- Relu	
Camada 3	Convolutiva	- Quantidade de filtros: 64; - Tamanho do Kernel: 8; - Passo da convolução:1; - Realização de padding: Sim.	18x64
Camada 4	Avarage pooling	- Tamanho do pool: 2	9x64
	Batch normalization	- Não se aplica	
	Função de ativação	- Relu	
Camada 5	Flatten	- Não se aplica	1x576
Camada 6	Densa	- Quantidade de neurônios:32	1x32
	Função de ativação	- Relu	
Saída	Densa	Quantidade de neurônios:1	1
	Função de ativação	Linear	

Além disso o modelo proposto detém os parâmetros de *learning rate* e ta-

manho do *batch*. A seleção do *learning rate* traz em seu processo a escolha entre velocidade de convergência e desempenho do modelo. Se o valor do *learning rate* for muito baixo, o processo de convergência pode ser muito lento, resultando em um treinamento demorado ou até mesmo em uma estagnação em mínimos locais. Por outro lado, um *learning rate* muito alto pode tornar o treinamento instável, impedindo que o modelo encontre uma solução ótima. Já o tamanho do *batch* se refere ao número de amostras de treinamento que são propagados pela rede em cada época durante o processo de treinamento. Após experimentações, o *learning rate* selecionado foi de 0,001, enquanto o tamanho do *batch* foi de 32.

## 4.7 Avaliação de desempenho

A avaliação de desempenho do modelo de predição do ângulo de chegada foi realizada para verificar a eficácia e precisão das previsões geradas pelo sistema. Para isso, utilizou-se a métrica MAE.

A primeira avaliação ocorreu durante o processo de criação do modelo. O desempenho do modelo foi avaliado em cada época do treinamento, observando o valor do MAE em cada iteração. Isso permitiu avaliar o progresso do modelo ao longo do tempo e identificar eventuais problemas de convergência ou *overfitting*.

Após o treinamento, o modelo foi utilizado para fazer previsões do ângulo de chegada utilizando os dados do conjunto de teste. Em seguida, foi calculado o MAE por cada ângulo e o MAE global das amostras para medir a diferença média absoluta entre as previsões e os valores reais do ângulo de chegada.

# Capítulo 5

## Resultados e Discussões

Esta seção apresenta resultados acerca da geração da base de dados e desempenho do modelo proposto. São mostrados os resultados obtidos da etapa de treinamento dos modelos, incluindo as validações e testes, utilizando o banco de dados gerado e, por fim, é discutida a importância e de cada contribuição exposta.

A geração de uma base de dados balanceada com as amostras IQs adquiridas utilizando um *array* de antenas retangular em um ambiente controlado é um resultado significativo obtido nesta dissertação. A Figura 5.1 mostra a quantidade de amostras em relação a cada ângulo de coleta, bem como a sua distribuição nas partições de treinamento, validação e teste. Especificamente, foram analisados os ângulos de 0°, 45°, 90°, 135°, 180°, 225°, 270° e 315°.

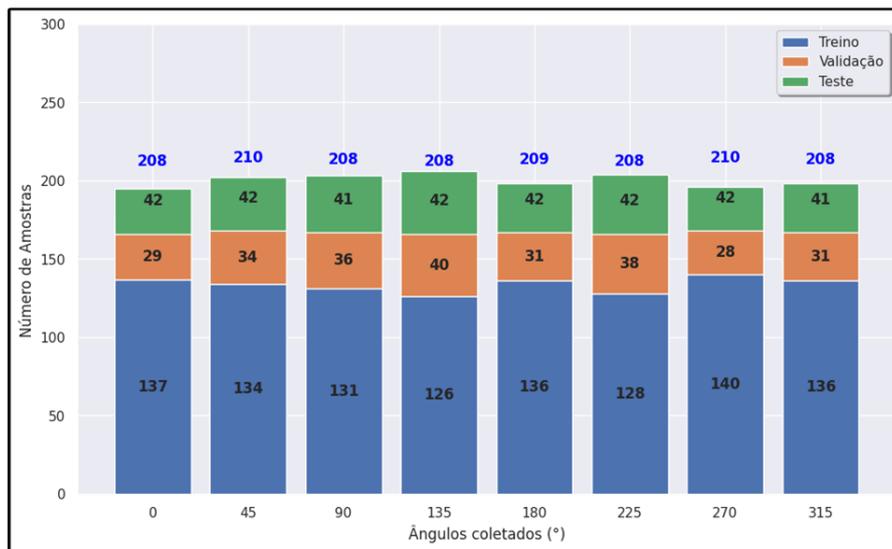


Figura 5.1: Balanceamento das amostras da base e separação para treino, validação e teste

Vale destacar que a metodologia empregada para a coleta levou em consideração a necessidade de manter balanceamento entre a quantidade de amostras para cada ângulo de coleta. É notável que todos os ângulos apresentam um número próximo de amostras, com 208, 210 ou 209 amostras em cada ângulo analisado. Esse equilíbrio é crucial para evitar vieses e garantir que o modelo seja treinado e avaliado de maneira apropriada.

Além disso, a figura também destaca a distribuição dessas amostras nas partições de treinamento, validação e teste. É fundamental que essas partições sigam a mesma proporção balanceada encontrada na base de dados completa. Isso significa que cada ângulo de coleta deve estar representado de forma similar nas três partições, permitindo que o modelo seja adequadamente treinado, validado e testado.

A etapa de treino e validação é um processo importante na geração de modelos. Para a avaliação desse processo, a Figura 5.2 exibe a evolução do erro médio absoluto (MAE) ao longo das épocas de treinamento do modelo proposto. A análise dessa curva é fundamental para avaliar o desempenho do modelo durante o processo de treinamento. Ao observar a Figura 5.2, verifica-se que não houve indícios de *overfitting*, uma vez que o MAE não apresentou uma tendência de diminuição exagerada nos dados de treinamento, enquanto aumentava nos dados de validação. Esse resultado mostra que o modelo foi capaz de generalizar bem os padrões aprendidos durante o treinamento para dados não vistos anteriormente.

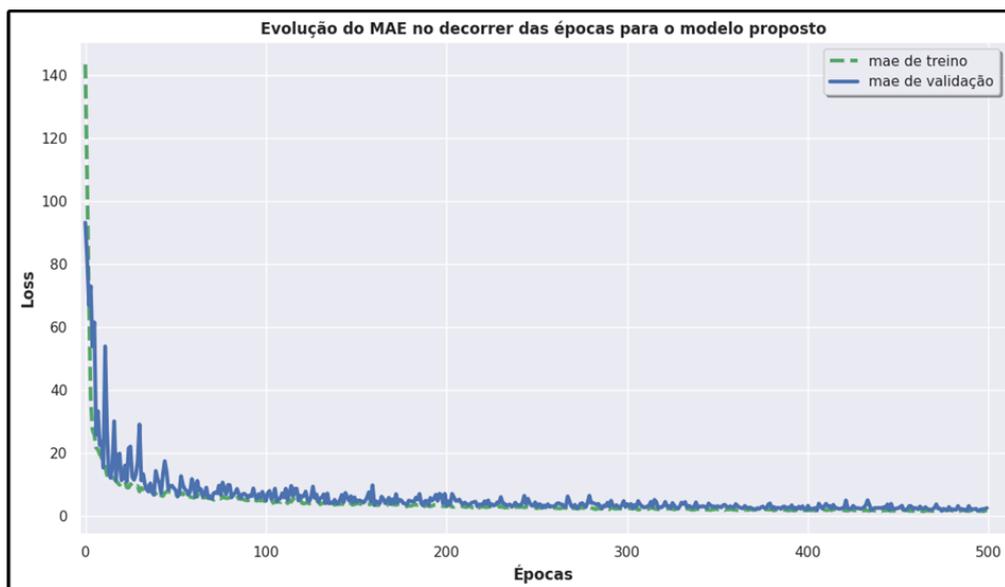


Figura 5.2: Evolução do MAE no decorrer das épocas para o Modelo proposto

Após a geração e avaliação do modelo, foi realizada uma comparação com, com os dados de teste, entre os valores preditos e valores esperados, conforme apresentado na Figura 5.3. Essa análise permite verificar a precisão do modelo na tarefa de predição.

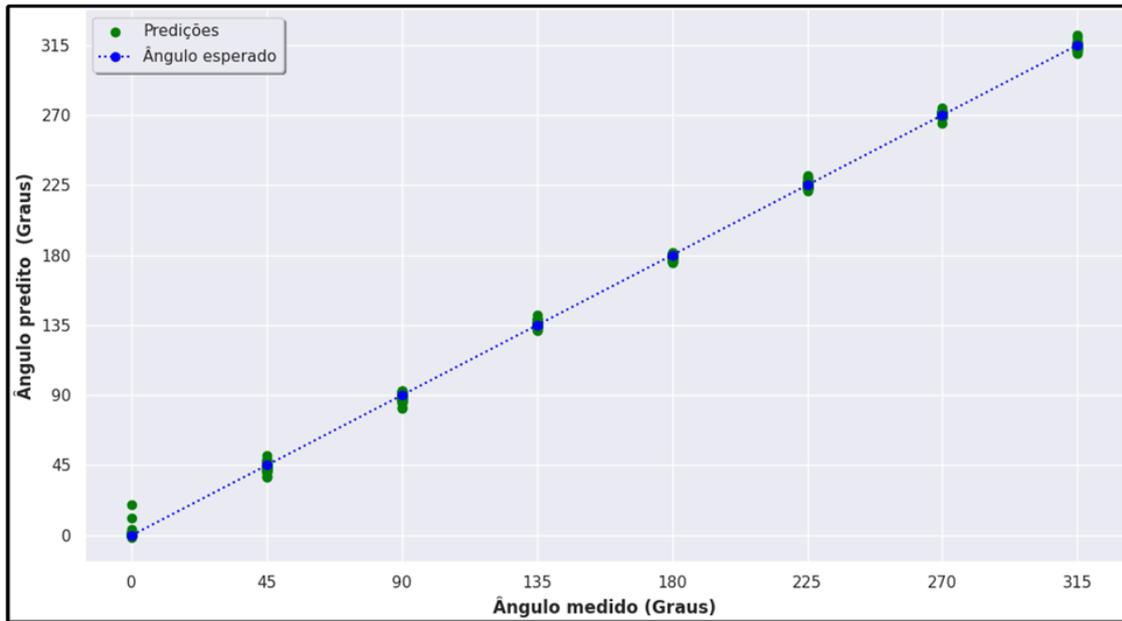


Figura 5.3: Comparativo entre as Predições do modelo e valores esperados

Ao analisar a Figura 5.3, nota-se que para o ângulo de  $0^\circ$ , são apresentadas as predições que possuem maior discrepância dos valores esperados. Além disso, para os ângulos de  $90^\circ$  a maioria das amostras preditas mostram uma tendência para valores menores que o esperado. Em suma, é possível observar uma boa correspondência entre as predições e os valores esperados, indicando um desempenho satisfatório do modelo. Essa semelhança entre as predições e os valores esperados reforça a capacidade do modelo em capturar os padrões subjacentes nos dados e realizar predições precisas.

A fim de detalhar a análise dessas predições realizadas pelo modelo, a Figura 5.4 apresenta as características estatísticas das amostras preditas como média, mediana, quartis e predições discrepantes por meio de *boxplot* de cada ângulo.

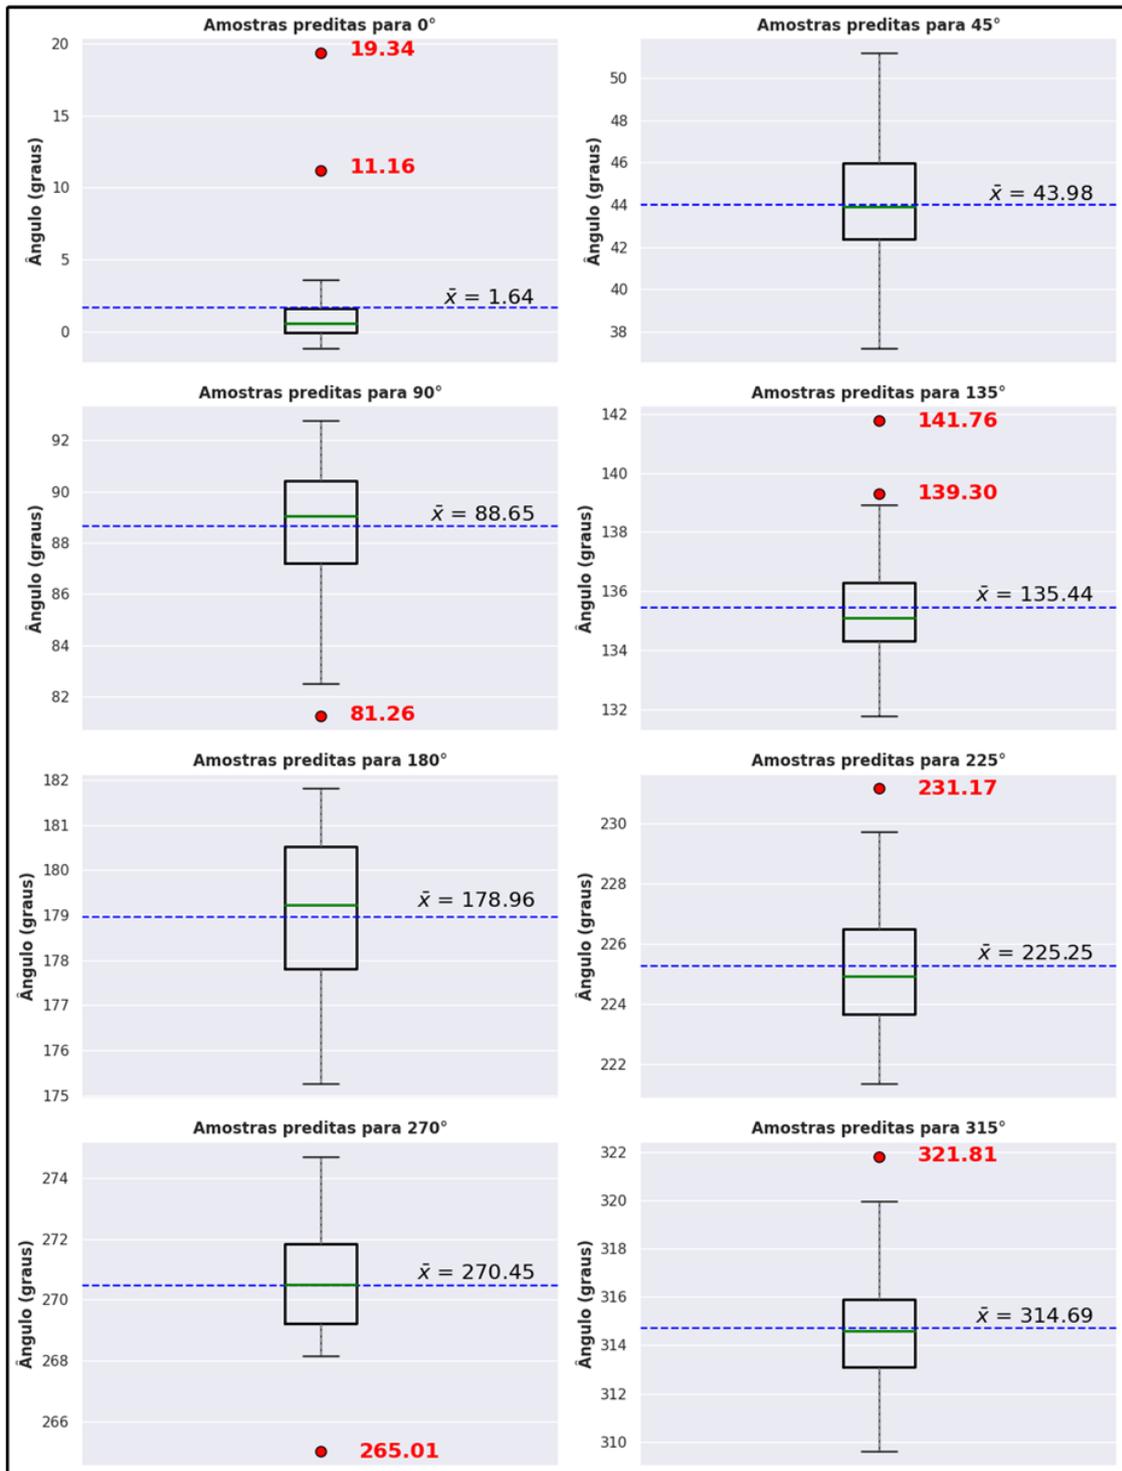


Figura 5.4: Características das amostras previstas

Ao analisar os *boxplots* das características das amostras previstas, observou-se que as amostras para os ângulos de 0°, 90°, 135°, 225°, 270° e 315° apresentaram valores que ultrapassaram os limites das caudas dos *boxplots*. O valor máximo registrado foi de 19,34° acima do valor esperado, observado no *boxplot* das amostras

preditas para  $0^\circ$ . Nos demais ângulos mencionados, A diferença absoluta entre os valores fora da calda e valores esperados não ultrapassaram  $7^\circ$ .

Esses resultados sugerem que, para o ângulo de coleta de  $0^\circ$ , ocorreram algumas predições que se distanciaram consideravelmente da mediana. Esse valor máximo de  $19,34^\circ$  indica a presença de discrepâncias entre algumas das predições realizadas e a tendência central do conjunto de dados. No entanto, é importante ressaltar que, para os demais ângulos de coleta, os valores fora da calda foram menores, evidenciando uma maior consistência entre as predições e a mediana.

A análise das médias dos valores preditos que mais se distanciaram da mediana reforça essa observação. Para o ângulo de coleta de  $0^\circ$ , a média dos valores preditos que apresentaram maior afastamento em relação à mediana foi significativamente maior do que nos demais ângulos. Isso indica uma maior dispersão e variação nas predições para esse ângulo específico. Por outro lado, nos demais ângulos analisados, tanto a média quanto a mediana apresentaram valores próximos, indicando uma distribuição mais consistente e simétrica dos dados preditos. Dessa forma, de modo geral, as predições foram consistentes com a mediana e a média nos demais ângulos, o que indica um bom alinhamento entre as estimativas e os valores esperados.

Por fim, a Figura 5.5 mostra o erro absoluto de cada amostra e o erro absoluto médio por ângulo. Essa análise permite avaliar o desempenho do modelo em diferentes ângulos.

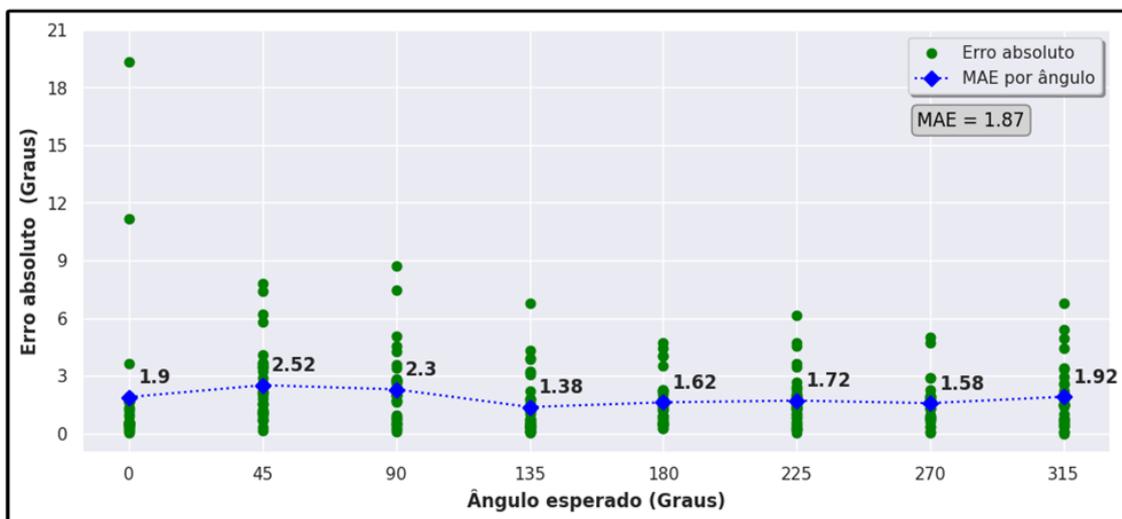


Figura 5.5: Erro absoluto e erro absoluto médio por ângulo

Ao examinar essas métricas, foi constatado que o ângulo de  $135^\circ$  apresentou o menor erro médio absoluto de  $1,38^\circ$ , indicando que as predições nesse ângulo tiveram erros relativamente pequenos em comparação aos valores esperados. Isso sugere uma boa capacidade do modelo em estimar corretamente os valores nesse ângulo específico.

Todavia, o ângulo de  $0^\circ$ , apesar de possuir poucos erros que se distanciaram significativamente dos valores esperados, apresentou predições que estavam consideravelmente distantes dos valores esperados. As predições com grandes desvios dos valores esperados podem afetar negativamente o erro médio absoluto, mesmo que o número de erros significativos seja reduzido. Assim, esse fato acarretou em um aumento do erro médio absoluto para esse ângulo.

O erro médio absoluto supracitado foi obtido a partir das amostras da base de dados que foram separadas para teste, que totalizaram 334 matrizes com as amostras I, Q e identificador da antena. Então foi avaliado o tempo para a predição de todas as 334 amostras. Para isso, o processo de predição do conjunto de teste foi realizado cinquenta vezes e a média de tempo obtida foi de 0,3214s.

Além disso, ao analisar o maior erro médio absoluto, constatou-se que corresponde ao ângulo de  $45^\circ$ . Nesse caso, muitas amostras contribuíram para o aumento desse erro médio, indicando uma maior dispersão e variação nas predições para esse ângulo específico.

Por fim, o erro absoluto médio geral do modelo foi calculado em  $1,87$  graus. Essa métrica representa a média dos erros absolutos para todas as amostras preditas, indicando o desempenho médio do modelo em estimar os valores esperados. Ao transformar esse erro absoluto médio angular de  $1,87^\circ$  para erro absoluto médio linear em um raio de  $0,9\text{m}$  de  $3,26\text{cm}$ . O trabalho [21], que utiliza RSSI com o WiFi chega a um melhor resultado de  $50\text{cm}$  de precisão. Já no trabalho [29], ao utilizar FTM combinado com o RSSI, o autor apresenta um desempenho na faixa de metro em ambientes internos. O trabalho [30], o autor, utilizando o RSSI do bluetooth, apresenta um melhor resultado de  $50\text{cm}$ . Já, em [37], o autor apresenta uma metodologia utilizando múltiplos beacons BLE 5.0 empregando RSSI e alcança uma precisão de  $10\text{cm}$  quando os dispositivos em questão se encontram em um mesmo plano. Por fim, os trabalhos [38] e [22] apresentam a estimação do ângulo de

chegada empregando diferentes métodos. Em [38], o erro médio absoluto alcançado foi de cerca de  $9^\circ$  usando o MUSIC,  $3,5^\circ$  usando rede neural,  $3^\circ$  usando processo Gaussiano e  $3,5^\circ$  empregando Árvore de decisão. Já em [22], emprega mínimos quadrados, filtro de Kalman e filtro gaussiano e consegue alcançar um erro menor que  $10^\circ$ . Dessa forma, ao fazer o comparativo em valores lineares, o trabalho com menor erro absoluto foi de 50 cm, enquanto método proposto na dissertação atinge erro médio absoluto de 3,26cm considerando o raio de 0,9m. Além disso, ao realizar o comparativo angular, verifica-se que o menor erro é de  $3^\circ$  utilizando processo gaussiano para a estimação do ângulo, enquanto o modelo aqui apresentado chega a 1,87 graus de erro médio absoluto. Logo, um MAE de 1,87 graus sugere um bom nível de precisão nas predições realizadas pelo modelo em relação aos valores esperados.

# Capítulo 6

## Conclusões

O presente trabalho apresentou um método que emprega o uso de *deep learning* no contexto de IPSs para a predição do ângulo de chegada de um sinal de rádio *bluetooth*. Um dos pontos principais desta pesquisa e que possibilitou o desenvolvimento do modelo aqui proposto foi a construção de uma base de dados de amostras IQ de sinais Bluetooth reais. A construção dessa base de dados se mostra como uma contribuição que endereça a atual carência de disponibilidade desses dados em repositórios online. Isso não apenas reforça a relevância do trabalho, mas também o torna uma fonte para futuras pesquisas na área. Ao preencher essa lacuna na literatura, o estudo adiciona um componente experimental fundamental às técnicas de estimação de AoA, e possibilita resultados promissores ao gerar a base de dados reais para sinais de rádio *bluetooth*.

Além disso, a presente pesquisa propôs uma alternativa aos métodos matemáticos lineares tradicionais ao empregar *deep learning* na análise de sinais transmitidos por dispositivos *Bluetooth* para a estimação do ângulo de chegada. Adiciona-se que, o presente trabalho introduz uma abordagem não encontrada na literatura, onde informações sobre os sinais recebidos, incluindo as amostras IQ e a respectiva antena de recepção, são utilizadas como dados de entrada para a estimação do ângulo de chegada. Esta foi uma característica que diferenciou o estudo de outras obras na literatura e possibilitou o estudo de uma informação até então não explorada nos demais trabalhos.

Por fim, destaca-se que, em comparação com outras abordagens de localização, esta proposta se mostra relevante devido à sua capacidade de oferecer um erro

médio absoluto baixíssimo na estimação do AoA dos sinais quando comparado com outros trabalhos da literatura. Esse desempenho ratifica a importância do conteúdo aqui exposto para a literatura.

Dessa forma, verifica-se que a presente pesquisa apresentou contribuições relevantes ao estado da arte através da criação da base dados, emprego da informação da antena de amostragem como dado relevante, utilização de método alternativo às abordagens mais utilizados para a estimação de AoA e, por fim, um desempenho na estimação superior aos trabalhos encontrados na literatura. Assim, conclui-se que o método aqui proposto se mostra promissor, pois proporcionou melhorias na estimação do AoA, e, assim, apresenta-se como alternativa aplicável ao contexto dos sistemas de posicionamento *indoor*.

# Referências Bibliográficas

- [1] WOOLLEY, M., *Bluetooth Direction Finding: A technical overview*, Tech. rep., Bluetooth Special Interest Group, 13 October 2021.
- [2] TOWNSEND, K., CUFÍ, C., DAVIDSON, R., et al., *Getting started with Bluetooth low energy: tools and techniques for low-power networking*. "O'Reilly Media, Inc.", 2014.
- [3] BLUETOOTH SPECIAL INTEREST GROUP (SIG), *Bluetooth Core Specification Version 5.1*, Technical Specification CSSv5.1, Bluetooth SIG, 2019, Acesso em: 08/05/2023.
- [4] PAU, G., ARENA, F., GEBREMARIAM, Y. E., et al., “Bluetooth 5.1: An analysis of direction finding capability for high-precision location services”, *Sensors*, v. 21, n. 11, pp. 3589, 2021.
- [5] ZHANG, A., LIPTON, Z. C., LI, M., et al., “Dive into deep learning”, *arXiv preprint arXiv:2106.11342*, 2021.
- [6] “A Comprehensive Introduction to Different Types of Convolutions in Deep Learning”, Accessed: 2023-03-05.
- [7] AGGARWAL, C. C., OTHERS, “Neural networks and deep learning”, *Springer*, v. 10, pp. 978–3, 2018.
- [8] TOWARDS DATA SCIENCE, “nRF52833 DK”, .
- [9] CIABATTONI, L., FORESI, G., MONTERIÙ, A., et al., “Real time indoor localization integrating a model based pedestrian dead reckoning on smartphone and BLE beacons”, *Journal of Ambient Intelligence and Humanized Computing*, v. 10, pp. 1–12, 2019.

- [10] HAYWARD, S., VAN LOPIK, K., HINDE, C., et al., “A survey of indoor location technologies, techniques and applications in industry”, *Internet of Things*, pp. 100608, 2022.
- [11] BARBIERI, L., BRAMBILLA, M., TRABATTONI, A., et al., “UWB localization in a smart factory: Augmentation methods and experimental assessment”, *IEEE Transactions on Instrumentation and Measurement*, v. 70, pp. 1–18, 2021.
- [12] BASIRI, A., LOHAN, E. S., MOORE, T., et al., “Indoor location based services challenges, requirements and usability of current solutions”, *Computer Science Review*, v. 24, pp. 1–12, 2017.
- [13] RÖBESAAT, J., ZHANG, P., ABDELAAL, M., et al., “An improved BLE indoor localization with Kalman-based fusion: An experimental study”, *Sensors*, v. 17, n. 5, pp. 951, 2017.
- [14] VALES, V. B., FERNÁNDEZ, O. C., DOMÍNGUEZ-BOLAÑO, T., et al., “Fine Time Measurement for the Internet of Things: A Practical Approach Using ESP32”, *IEEE Internet of Things Journal*, v. 9, n. 19, pp. 18305–18318, 2022.
- [15] BOORANAWONG, A., THAMMACHOTE, P., SASIWAT, Y., et al., “Real-time tracking of a moving target in an indoor corridor of the hospital building using RSSI signals received from two reference nodes”, *Medical & Biological Engineering & Computing*, v. 60, n. 2, pp. 439–458, 2022.
- [16] SAMBU, P., WON, M., “An experimental study on direction finding of bluetooth 5.1: Indoor vs outdoor”. In: *2022 IEEE Wireless Communications and Networking Conference (WCNC)*, pp. 1934–1939, 2022.
- [17] DE PALMA, A., VOSOUGH, S., LIAO, F., “An overview of effects of COVID-19 on mobility and lifestyle: 18 months since the outbreak”, *Transportation Research Part A: Policy and Practice*, 2022.

- [18] FARAHSARI, P. S., FARAHZADI, A., REZAZADEH, J., et al., “A survey on indoor positioning systems for iot-based applications”, *IEEE Internet of Things Journal*, v. 9, n. 10, pp. 7680–7699, 2022.
- [19] ZHOU, D., XIA, Y., YU, C., “Adaptive Maximum Correntropy Unscented Kalman Filter Based on IMU and UWB Data”. In: *2022 IEEE International Conference on Unmanned Systems (ICUS)*, pp. 1569–1574, 2022.
- [20] HUANG, C., LIU, H., WANG, W., et al., “A compact and cost-effective ble beacon with multiprotocol and dynamic content advertising for iot application”, *IEEE Internet of Things Journal*, v. 7, n. 3, pp. 2309–2320, 2019.
- [21] YANG, C., SHAO, H.-R., “WiFi-based indoor positioning”, *IEEE Communications Magazine*, v. 53, n. 3, pp. 150–157, 2015.
- [22] HAJIAKHONDI-MEYBODI, Z., SALIMIBENI, M., PLATANIOTIS, K. N., et al., “Bluetooth low energy-based angle of arrival estimation via switch antenna array for indoor localization”. In: *2020 IEEE 23rd International Conference on Information Fusion (FUSION)*, pp. 1–6, 2020.
- [23] GIL-MARTÍNEZ, A., POVEDA-GARCÍA, M., GARCÍA-FERNÁNDEZ, J., et al., “Direction finding of RFID tags in UHF band using a passive beam-scanning leaky-wave antenna”, *IEEE Journal of Radio Frequency Identification*, v. 6, pp. 552–563, 2022.
- [24] YE, H., YANG, B., LONG, Z., et al., “A method of indoor positioning by signal fitting and PDDA algorithm using BLE AOA device”, *IEEE Sensors Journal*, v. 22, n. 8, pp. 7877–7887, 2022.
- [25] BLUETOOTH SPECIAL INTEREST GROUP (SIG), *Bluetooth Direction Finding: A Technical Overview*, Technical Overview DIRv1.1, Bluetooth SIG, 2020, Acesso em: 08/05/2023.
- [26] HAJIAKHONDI-MEYBODI, Z., SALIMIBENI, M., MOHAMMADI, A., et al., “Bluetooth low energy and CNN-based angle of arrival localization in presence of Rayleigh fading”. In: *ICASSP 2021-2021 IEEE International*

- Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 7913–7917, 2021.
- [27] ZHU, W., ZHANG, M., LI, P., et al., “Two-Dimensional DOA Estimation via Deep Ensemble Learning”, *IEEE Access*, v. 8, pp. 124544–124552, 2020.
- [28] ZHU, D., YAN, J., “A Deep Learning Based Bluetooth Indoor Localization Algorithm by RSSI and AOA Feature Fusion”. In: *2022 International Conference on Computer, Information and Telecommunication Systems (CITS)*, pp. 1–6, 2022.
- [29] YU, Y., CHEN, R., CHEN, L., et al., “Precise 3-D indoor localization based on Wi-Fi FTM and built-in sensors”, *IEEE Internet of Things Journal*, v. 7, n. 12, pp. 11753–11765, 2020.
- [30] ALLETTO, S., CUCCHIARA, R., DEL FIORE, G., et al., “An indoor location-aware system for an IoT-based smart museum”, *IEEE Internet of Things Journal*, v. 3, n. 2, pp. 244–253, 2015.
- [31] LIN, Q., SON, J., “Analysis of Bluetooth RSSI for Proximity Detection of Ship Passengers”, *Applied Sciences (Switzerland)*, v. 12, 1 2022.
- [32] BOORANAWONG, A., THAMMACHOTE, P., SASIWAT, Y., et al., “Real-time tracking of a moving target in an indoor corridor of the hospital building using RSSI signals received from two reference nodes”, *Medical and Biological Engineering and Computing*, v. 60, pp. 439–458, 2 2022.
- [33] PUŠNIK, M., GALUN, M., ŠUMAK, B., “Improved bluetooth low energy sensor detection for indoor localization services”, *Sensors (Switzerland)*, v. 20, 4 2020.
- [34] KHAN, F. U., AWAIS, M., RASHEED, M. B., et al., “A Comparison of Wireless Standards in IoT for Indoor Localization Using LoPy”, *IEEE Access*, v. 9, pp. 65925–65933, 2021.
- [35] FARAGHER, R., HARLE, R., “Location fingerprinting with bluetooth low energy beacons”, *IEEE journal on Selected Areas in Communications*, v. 33, n. 11, pp. 2418–2428, 2015.

- [36] ZHANG, Q., D'SOUZA, M., BALOGH, U., et al., "Efficient BLE fingerprinting through UWB sensors for indoor localization". In: *2019 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBDCCom/IOP/SCI)*, pp. 140–143, 2019.
- [37] RAMIREZ, R., HUANG, C.-Y., LIAO, C.-A., et al., "A practice of BLE RSSI measurement for indoor positioning", *Sensors*, v. 21, n. 15, pp. 5181, 2021.
- [38] KHAN, A., WANG, S., ZHU, Z., "Angle-of-arrival estimation using an adaptive machine learning framework", *IEEE Communications Letters*, v. 23, n. 2, pp. 294–297, 2018.
- [39] XIANG, H., CHEN, B., YANG, M., et al., "A Novel Phase Enhancement Method for Low-Angle Estimation Based on Supervised DNN Learning", *IEEE Access*, v. 7, pp. 82329–82336, 2019.
- [40] GOODMAN, J., SALMOND, D., DAVIS, C., et al., "Ambiguity Resolution in Direction of Arrival Estimation using Mixed Integer Optimization and Deep Learning; Ambiguity Resolution in Direction of Arrival Estimation using Mixed Integer Optimization and Deep Learning", 2019.
- [41] SHI, B., MA, X., ZHANG, W., et al., "Complex-Valued Convolutional Neural Networks Design and Its Application on UAV DOA Estimation in Urban Environments", 2020.
- [42] XIANG, H., CHEN, B., YANG, T., et al., "Phase enhancement model based on supervised convolutional neural network for coherent DOA estimation", *Applied Intelligence*, v. 50, pp. 2411–2422, 8 2020.
- [43] WAHAB, N. H. A., SUNAR, N., ARIFFIN, S. H., et al., "Indoor Positioning System: A Review", *International Journal of Advanced Computer Science and Applications*, v. 13, n. 6, 2022.

- [44] ZHUANG, Y., YANG, J., LI, Y., et al., “Smartphone-based indoor localization with bluetooth low energy beacons”, *Sensors (Switzerland)*, v. 16, 4 2016.
- [45] DANIŞ, F. S., CEMGİL, A. T., “Model-based localization and tracking using bluetooth low-energy beacons”, *Sensors (Switzerland)*, v. 17, 11 2017.
- [46] HOU, X., ARSLAN, T., “Monte Carlo localization algorithm for indoor positioning using Bluetooth low energy devices”. In: *2017 International Conference on Localization and GNSS (ICL-GNSS)*, pp. 1–6, 2017.
- [47] ČABARKAPA, D., GRUJIĆ, I., PAVLOVIĆ, P., “Comparative analysis of the bluetooth low-energy indoor positioning systems”. In: *2015 12th International Conference on Telecommunication in Modern Satellite, Cable and Broadcasting Services (TELSIKS)*, pp. 76–79, 2015.
- [48] CERRUELA GARCÍA, G., LUQUE RUIZ, I., GÓMEZ-NIETO, M. Á., “State of the art, trends and future of bluetooth low energy, near field communication and visible light communication in the development of smart cities”, *Sensors*, v. 16, n. 11, pp. 1968, 2016.
- [49] NORDIC SEMICONDUCTOR, *NRF52833 Product Specification*, Tech. rep., 2019, Acesso em: 20/05/2023.
- [50] LECUN, Y., BOTTOU, L., BENGIO, Y., et al., “Gradient-based learning applied to document recognition”, *Proceedings of the IEEE*, v. 86, n. 11, pp. 2278–2324, 1998.
- [51] GOODFELLOW, I., BENGIO, Y., COURVILLE, A., *Deep learning*. MIT press, 2016.
- [52] BOCK, S., GOPPOLD, J., WEISS, M., “An improvement of the convergence proof of the ADAM-optimizer”, *arXiv preprint arXiv:1804.10587*, 2018.
- [53] QI, J., DU, J., SINISCALCHI, S. M., et al., “On mean absolute error for deep neural network based vector-to-vector regression”, *IEEE Signal Processing Letters*, v. 27, pp. 1485–1489, 2020.
- [54] BLUETOOTH, F., “ANT and Bluetooth®”, 2010.

- [55] TOWARDS DATA SCIENCE, “A Comprehensive Introduction to Different Types of Convolutions in Deep Learning”, .
- [56] AHMED, F., PHILLIPS, M., PHILLIPS, S., et al., “Comparative study of seamless asset location and tracking technologies”, *Procedia Manufacturing*, v. 51, pp. 1138–1145, 2020.
- [57] JONDHALE, S. R., DESHPANDE, R. S., “GRNN and KF framework based real time target tracking using PSOC BLE and smartphone”, *Ad Hoc Networks*, v. 84, pp. 19–28, 2019.
- [58] HODSON, T. O., “Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not”, *Geoscientific Model Development*, v. 15, n. 14, pp. 5481–5487, 2022.