



UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

# **APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA PREDIÇÃO DE RSSI E SNR EM AMBIENTE DE BOSQUE AMAZÔNICO.**

BRENDA SILVANA DE SOUZA BARBOSA

TD 11/2024

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém-Pará-Brasil

2024

UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

BRENDA SILVANA DE SOUZA BARBOSA

**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS PARA PREDIÇÃO  
DE RSSI E SNR EM AMBIENTE DE BOSQUE AMAZÔNICO.**

Tese submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da UFPA para obtenção do Grau de Doutor em Engenharia Elétrica na Área de Telecomunicações.

Orientador: Prof. Dr. Fabrício José Brito Barros.

Coorientadora: Profa. Dra. Jasmine Priscyla Leite de Araújo.

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém-Pará-Brasil

2024

UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

## **APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA PREDIÇÃO DE RSSI E SNR EM AMBIENTE DE BOSQUE AMAZÔNICO.**

**AUTOR: BRENDA SILVANA DE SOUZA BARBOSA.**

TESE DE DOUTORADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA APROVADA PARA OBTENÇÃO DO GRAU DE DOUTOR EM ENGENHARIA ELÉTRICA NA ÁREA DE TELECOMUNICAÇÕES.

**BANCA EXAMINADORA:**

---

**Prof. Dr. Fabrício José Brito Barros.**

(Orientador - PPGEE / UFPA)

---

**Profa. Dra. Jasmine Priscyla Leite de Araújo**

(Coorientadora - PPGEE / UFPA)

---

**Prof.Dr. Emérito Gervásio Protásio dos Santos  
Cavalcante**

(Avaliador Externo - PPGEE / UFPA)

---

**Profa. Dra. Leslye Estefania Castro Eras**

(Avaliador Externo -UNIFESSPA)

---

**Prof. Dr. Diego Kasuo Nakata Da Silva**

(Avaliador Externo -UNIFESSPA)

**VISTO:**

---

**Prof. Dr. Diego Lisboa Cardoso**

(Coordenador do PPGEE/ITEC/UFPA)

*Dedico este trabalho a Deus, a minha mãe, aos meus irmãos, a minha irmã do coração, meus afilhados e a todos meus amigos.*

# Agradecimentos

Primeiramente, a Deus por sempre estar presente, e colocando anjos para acalmar o meu coração ao longo da minha vida. A minha mãe Alba Maria de Souza Barbosa, pela educação, pelo amor e pelas orações, a minha irmã do coração, Glads Maria Serra, me dando força e me ajudando no cotidiano para ficar mais leve essa etapa, ao meu irmão, Victor Ainett, a minha cunhada Márcia Haydee, as minhas amigas: Denize Luz, Emanuelle Luz, Thamires Mota, Luiza Amador por sempre me motivarem e aos meus alunos da residência pedagógica, Alvares Santos, Alessandro Souza, José Junior, Manuela Alves e Kathleen Aguiar, pelo apoio nas atividades pedagógicas da escola. Aos meus amigos da vida e aos meus amigos que fiz no LCT, em especial, aos meus amigos Hugo Alexandre, Alex Sanches e Caio Mateus, pelo apoio e suporte nas medições, pela contribuição com ideias e com questionamentos, sem eles, essa trajetória seria muita mais difícil. Ao meu amigo Filipe Fernandes, pelas contribuições e ideias nos gráficos. A minha amiga e professora Leslye Eras, que desde quando entrei no LCT, sempre me acolheu e me direcionou muito bem, contribuindo para o meu desenvolvimento no estudo de propagação em ambientes com vegetação. A professora Josiane Rodrigues pela amizade, confiança, ensinamentos e ter me apresentado o LCT. Ao Professor Emérito Gervásio Cavalcante, pela sua humanidade, motivação, amizade, respeito, confiança e sabedoria. A Professora, Jasmine Araújo, pelos seus ensinamentos, pela sua amizade, pelas suas orações, por me orientar e acreditar em mim. Ao meu orientador Professor Fabrício Barros pela contribuição com ideias e questionamento a respeito da minha pesquisa. Aos pesquisadores, integrantes e amigos do Laboratório de Computação e telecomunicações (LCT). Aos professores do programa de pós-graduação, coordenadores e funcionários do PPGEE, em especial Socorro e Paula, da secretaria por sempre me orientarem sobre o programa e me alertarem dos prazos. Ao Instituto Nacional de Ciência e Tecnologia de Comunicações Sem Fio (INCT-CSF) e pelo CNPq pelo suporte financeiro prestado, contribuindo para a concretização deste trabalho. A Universidade Federal do Pará, pela oportunidade dada a mim para a realização desse trabalho.

*“Conheça todas as teorias, domine todas as técnicas, mas ao tocar uma alma humana, seja apenas outra alma humana.”*

*Carl Jung*

# Resumo

A presença de áreas verdes em cidades urbanizadas é crucial para reduzir os impactos negativos da urbanização. No entanto, essas áreas podem influenciar a qualidade do sinal de dispositivos IoT que utilizam comunicação sem fio, como a tecnologia LoRa. A vegetação atenua as ondas eletromagnéticas, interferindo na transmissão de dados entre dispositivos IoT, resultando na necessidade de modelagem de propagação de sinal que considere o efeito da vegetação em sua propagação. Neste contexto, esta pesquisa foi conduzida na Universidade Federal do Pará, utilizando medições em um ambiente arborizado composto pela espécie Pau-Mulato, típica da Amazônia. Dois modelos de propagação baseados em aprendizado de máquina, GRNN e MLPNN, foram desenvolvidos para considerar o efeito das árvores amazônicas na propagação, analisando diferentes fatores, como a altura do transmissor em relação ao tronco, o início da folhagem e o meio da copa da árvore, bem como o fator de espalhamento LoRa (SF) 12 e a copolarização das antenas do transmissor e do receptor. Os melhores modelos foram os de aprendizado de máquina, GRNN e MLPNN, que demonstraram maior precisão, alcançando valores de erro quadrático médio (RMSE) de 3,86 dB e 3,8614 dB, e desvio padrão (SD) de 3,8558 dB e 3,8564 dB, respectivamente. Por outro lado, comparando com modelos clássicos da literatura, o que teve melhor desempenho foi o modelo Floating Intercept (FI), com erro RMSE e SD em torno de 7,74 dB e 7,77 dB, respectivamente, enquanto o modelo FITU-R teve o maior erro RMSE e SD, em torno de 26,40 dB e 9,65 dB, respectivamente, para todas as alturas e polarizações. Além disso, a importância deste estudo reside em seu potencial para impulsionar as comunicações sem fio em ambientes arborizados, uma vez que, mesmo em distâncias curtas nas alturas de 12 m e 18 m, o SNR (relação sinal ruído) teve valores mais baixos devido à influência das folhagens, porém, foi possível enviar e receber dados. Por fim, foi mostrado que a polarização vertical foi a que obteve os melhores resultados para o ambiente de bosque amazônico.

**Palavras-chave:** Amazônia; Aprendizagem de Máquinas; LoRa; Modelos de Propagação; Vegetação Densa.

# Abstract

The presence of green areas in urbanized cities is crucial to reduce the negative impacts of urbanization. However, these areas can influence the signal quality of IoT devices that use wireless communication, such as LoRa technology. Vegetation attenuates electromagnetic waves, interfering with data transmission between IoT devices, resulting in the need for signal propagation modeling that considers the effect of vegetation on its propagation. In this context, this research was conducted at the Federal University of Pará, using measurements in a wooded environment composed of the Pau-Mulato species, typical of the Amazon. Two propagation models based on machine learning, GRNN and MLPNN, were developed to consider the effect of Amazonian trees on propagation, analyzing different factors such as the height of the transmitter relative to the trunk, the beginning of the foliage, and the middle of the tree canopy, as well as the LoRa spreading factor (SF) 12 and the copolarization of the transmitter and receiver antennas. The best models were the machine learning ones, GRNN and MLPNN, which demonstrated greater accuracy, achieving root mean square error (RMSE) values of 3.86 dB and 3.8614 dB, and standard deviation (SD) of 3.8558 dB and 3.8564 dB, respectively. On the other hand, compared to classical models in the literature, the best-performing model was the Floating Intercept (FI) model, with RMSE and SD errors around 7.74 dB and 7.77 dB, respectively, while the FITU-R model had the highest RMSE and SD errors, around 26.40 dB and 9.65 dB, respectively, for all heights and polarizations. Furthermore, the importance of this study lies in its potential to boost wireless communications in wooded environments, as it was observed that even at short distances at heights of 12 m and 18 m, the SNR (Signal-to-Noise Ratio) had lower values due to the influence of the foliage, but it was still possible to send and receive data. Finally, it was shown that vertical polarization achieved the best results for the Amazon forest environment.

**Keywords:** Amazon; Dense vegetation; LoRa; Machine Learning; Propagation Models.

# Lista de figuras

Figura 1 – Internet das Coisas. . . . .	16
Figura 2 – Classificação de tecnologias LPWAN. . . . .	17
Figura 3 – Ilustração das Camadas da Tecnologia LoRa. . . . .	18
Figura 4 – Protocolo de rede LoRaWAN. . . . .	21
Figura 5 – Classes de Dispositivos LoRa. . . . .	22
Figura 6 – Mecanismos de Radiopropagação. . . . .	24
Figura 7 – A funcionalidade comum na IoT e na inteligência artificial. . . . .	32
Figura 8 – Relação entre IA, ML e DL. . . . .	33
Figura 9 – Tipos de Técnicas Machine Learning. . . . .	34
Figura 10 – Ilustração de um neurônio natural e um neurônio artificial. . . . .	37
Figura 11 – Modelo de uma rede MLP . . . . .	38
Figura 12 – Arquitetura padrão de uma rede GRNN . . . . .	40
Figura 13 – Fluxograma da Metodologia Aplicada. . . . .	42
Figura 14 – Cénario de Medições Bosque Camilo Viana (UFPA) : <b>(a)</b> Vista área do Bosque de Floresta Amazônica. <b>(b)</b> Caminho de corredor de árvores interno do bosque percorrido para coleta de dados. . . . .	43
Figura 15 – Equipamentos de Transmissão e Recepção: <b>(a)</b> Arduino Uno Module + Dragino 915 MHz LoRa Module + Antena Omnidirecional. <b>(b)</b> Módulo Arduino Uno + Módulo de LoRa Dragino 915 Mhz + Antena Omnidirecional + GPS + smartphome. . . . .	44
Figura 16 – Cenário de metodologia de medições. . . . .	46
Figura 17 – RMSE em relação ao número de neurônios na camada oculta. . . . .	50
Figura 18 – Rede MLPNN implementada. . . . .	51
Figura 19 – Rede GRNN implementada. . . . .	52
Figura 20 – <b>a)</b> Dados de GPS coletados correspondentes aos níveis de RSSI versus distância no ambiente estudado. <b>(b)</b> Os dados de GPS coletados correspondentes aos níveis de SNR versus distância no ambiente estudado. . . . .	54
Figura 21 – Distribuição dos dados de RSSI medidos em relação à distância para SF12 em todas as alturas para as polarizações HH e VV. . . . .	55
Figura 22 – Distribuição dos dados de SNR medidos em relação à distância para SF12 em todas as alturas para as polarizações HH e VV. . . . .	56
Figura 23 – Análise dos valores médios e desvio padrão do RSSI para SF12 em todas as alturas e para as polarizações VV e HH. . . . .	57
Figura 24 – Análise dos valores médios e desvio padrão do SNR para SF12 em todas as alturas e para as polarizações VV e HH. . . . .	58
Figura 25 – Dados medidos e previsão da MLPNN e GRNN. . . . .	62



# Lista de tabelas

Tabela 1 – Comparativo entre trabalhos correlatos e esta pesquisa . . . . .	13
Tabela 2 – Relação entre os parâmetros LoRa para uma largura de banda de 125 KHz. .	20
Tabela 3 – Configuração dos parâmetros do setup de medição. . . . .	45
Tabela 4 – Configuração correspondentes a metodologia das medições. . . . .	46
Tabela 5 – Divisão do conjunto de dados. . . . .	49
Tabela 6 – Métricas estatísticas do sinal coletado . . . . .	59
Tabela 7 – Valores dos coeficientes ajustados para FI e CI. . . . .	60
Tabela 8 – Métricas de avaliação para as RNAs . . . . .	62
Tabela 9 – Comparação dos Resultados dos Modelos de Propagação. . . . .	64

# Lista de abreviaturas e siglas

3G	Terceira Geração
3GPP	3rd Generation Partnership Project, Projeto de Parceria de Terceira Geração
5G	Quinta Geração
ADR	Adaptive Data Rate, Taxa de Dados Adaptativa
ANATEL	Agência Nacional de Telecomunicações
ANN	Artificial Neural Network
BP	Back Propagation, Retropropagação
BS	Base Station, Estação Base
BW	Bandwidth, Largura de Banda
CI	Close-in
CPqD	Centro de Pesquisa e Desenvolvimento em Telecomunicações
CR	Code Rate, Taxa de Código
CSS	Chirp Spread Spectrum, Espalhamento de Espectro por Chirp
dB	Decibel
dBm	Decibel-miliwatt
DSM	Digital Surface Model, Modelagem de Superfície Digital
FI	Floating Intercept
FSPL	Free Space Path Loss, Perda de Percurso em Espaço Livre
GHz	Gigahertz
GPS	Global Positioning System, Sistema de Posicionamento Global
GRNN	General Regression Neural Network, Rede Neural de Regressão Geral
HH	Horizontal- Horizontal
IA	Inteligência Artificial

IoT	Internet of Things, Internet das Coisas
ISM	Industrial, Scientific, and Medical - Industrial, Científico e Médico
LoRa	Long Range, Longo Alcance
LoRaWAN	Long-Range Wide-Area Network, Rede de Longo Alcance de Área Ampla
LOS	Line-of-Sight, Linha de Visada
LPWAN	Low-Power Wide-Area Network, Redes de Área Ampla e Baixa Potência
MAE	Mean Absolute Error, Erro Absoluto Médio
MAPE	Mean Absolute Percentage Error, Erro Percentual Absoluto Médio
MHz	Megahertz
MED	Modified Exponential Decay,
ML	Machine Learning, Aprendizado de Máquina
MLP	Multilayer Perceptron, Perceptron de Múltiplas Camadas
MMSE	Minimum Mean Square Error, Erro Quadrático Médio Mínimo
NLOS	Non-Line-of-Sight, Não Linha de Visada
NB-IoT	Narrowband Internet of Things, Banda Estreita para Internet das Coisas
NS-3	Network Simulator 3, Simulador de Rede 3
PDR	Packet Delivery Ratio, Taxa de Entrega de Pacotes
PE	Earth Plane, Terra Plana
PLR	Packet Loss Rate, Taxa de Perda de Pacotes
PLE	Path Loss Exponent, Expoente de Perda de Propagação
$R^2$	Coefficient of Determination, Coeficiente de Determinação
RBFNN	Radial Basis Function Neural Network, Rede Neural de Função de Base Radial
RF	Radio Frequency, Rádio Frequência
RMSE	Root Mean Square Error, Erro Quadrático Médio da Raiz
RNA	Rede Neural Artificial

RSS	Received Signal Strength, Força do Sinal Recebido
RSSI	Receiving Signal Strength Indicator, Indicador de Intensidade do Sinal Recebido
SF	Spreading Factor, Fator de Espalhamento
SNR	Signal-to-Noise Ratio, Relação Sinal-Ruído
TX-RX	Transmissor-Receptor
ToA	Time of Arrival, Tempo de Chegada
UFPA	Universidade Federal do Pará
VV	Vertical-Vertical
Wi-Fi	Wireless Fidelity, Fidelidade sem Fio
WSN	Wireless Sensor Network, Rede de Sensores Sem Fio

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
1.1	CONTEXTUALIZAÇÃO	1
1.2	DEFINIÇÃO DO PROBLEMA	3
1.3	OBJETIVO GERAL	4
1.3.1	OBJETIVOS ESPECÍFICOS	4
1.4	CONTRIBUIÇÕES DA PROPOSTA	5
1.5	ORGANIZAÇÃO DO DOCUMENTO	7
<b>2</b>	<b>TRABALHOS CORRELATOS</b>	<b>8</b>
2.1	CONSIDERAÇÕES INICIAIS	8
2.2	DESCRIÇÃO DOS TRABALHOS CORRELATOS	8
2.3	COMPARATIVO ENTRE ESTE TRABALHO E OS CORRELATOS	12
2.4	SÍNTESE DO CAPÍTULO	14
<b>3</b>	<b>REFERENCIAL TEÓRICO</b>	<b>15</b>
3.1	CONSIDERAÇÕES INICIAIS	15
3.2	A INTERNET DAS COISAS ( <i>INTERNET OF THE THINGS– IoT</i> )	15
3.3	TECNOLOGIAS DE REDES DE ÁREA AMPLA DE BAIXA POTÊNCIA ( <i>LPWANs</i> )	17
3.3.1	TECNOLOGIA LoRa ( <i>LONG RANGE</i> ) E LoRaWAN	18
3.3.1.1	CAMADA FÍSICA - LoRa	19
3.3.1.2	CAMADA MAC - LoRaWAN	21
3.4	RÁDIOPROPAGAÇÃO	23
3.4.1	MECANISMO DE PROPAGAÇÃO	23
3.4.1.1	VISADA DIRETA ( <i>LOS - LINE-OF-SIGHT</i> )	24
3.4.1.2	REFLEXÃO	24
3.4.1.3	ESPALHAMENTO	25
3.4.1.4	DIFRAÇÃO	25
3.5	MODELOS DE PROPAGAÇÃO	26
3.5.1	CLASSIFICAÇÕES	26
3.5.1.1	CLASSIFICAÇÃO DOS MODELOS	26
3.5.1.2	CLASSIFICAÇÃO DOS AMBIENTES	26
3.5.2	MODELOS PARA AMBIENTES EXTERNOS USADOS	27
3.5.2.1	MODELO FLOATING-INTERCEPT (FI)	27
3.5.2.2	MODELO CLOSE-IN (CI)	28

3.5.3	MODELOS DE PROPAGAÇÃO EMPÍRICOS PARA VEGETAÇÃO USADOS . . . . .	29
3.5.3.1	MODELO WEISSBERGER . . . . .	30
3.5.3.2	MODELO ITU-R . . . . .	30
3.5.3.3	MODELO COST 235 . . . . .	31
3.5.3.4	MODELO FITTED ITU-R (FITU-R) . . . . .	31
3.6	INTELIGÊNCIA ARTIFICIAL (IA) . . . . .	31
3.6.1	TÉCNICAS DE APRENDIZAGEM DE MÁQUINA ( <i>MACHINE LEARNING - ML</i> ) . . . . .	33
3.6.2	REDES NEURAS ARTIFICIAIS-RNAs . . . . .	35
3.6.2.1	INTRODUÇÃO . . . . .	35
3.6.2.2	PERCEPTRONS DE MÚLTIPLAS CAMADAS ( <i>MULTILAYER PERCEPTRONS - MLPs</i> ) . . . . .	37
3.6.2.3	REDE NEURAL DE REGRESSÃO GERAL ( <i>GENERAL REGRESSION NEURAL NETWORK - GRNN</i> ) . . . . .	39
3.7	CONSIDERAÇÕES FINAIS . . . . .	41
<b>4</b>	<b>METODOLOGIA . . . . .</b>	<b>42</b>
4.1	CONSIDERAÇÕES INICIAIS . . . . .	42
4.2	MATERIAIS E MÉTODOS . . . . .	42
4.2.1	DESCRIÇÃO DA CAMPANHA DE MEDIÇÃO . . . . .	43
4.2.1.1	CENÁRIO . . . . .	43
4.2.1.2	SETUP DE MEDIÇÃO . . . . .	44
4.2.1.3	METODOLOGIA DE MEDIÇÃO . . . . .	45
4.2.2	TRATAMENTO DOS DADOS . . . . .	47
4.2.2.1	CÁLCULO DA DISTÂNCIA . . . . .	47
4.2.2.2	CÁLCULO DA PERDA DE PROPAGAÇÃO . . . . .	48
4.2.3	Métodos de Predição de RSSI e SNR . . . . .	48
4.2.3.1	CONJUNTO DE DADOS . . . . .	49
4.2.3.2	PERCEPTRONS DE MÚLTIPLAS CAMADAS ( <i>MULTILAYER PERCEPTRONS - MLPs</i> ) . . . . .	49
4.2.3.3	REDE NEURAL DE REGRESSÃO GERAL ( <i>GENERAL REGRESSION NEURAL NETWORK - GRNN</i> ) . . . . .	51
<b>5</b>	<b>RESULTADOS . . . . .</b>	<b>53</b>
5.1	ANÁLISE DA INFLUÊNCIA DE ALTURAS E POLARIZAÇÕES EM AMBIENTES COM VEGETAÇÃO Densa . . . . .	53
5.2	ANÁLISE DOS VALORES DE RSSI E SNR EM RELAÇÃO ÀS ALTURAS DO TRANSMISSOR (Tx) . . . . .	57
5.3	AJUSTES DOS MODELOS DE PROPAGAÇÃO CI e FI . . . . .	60

5.4	AVALIAÇÃO DOS MODELOS DE PROPAGAÇÃO PROPOSTOS BASEADOS EM REDES NEURAIS ARTIFICIAIS (RNAs)	60
5.5	COMPARAÇÃO COM MODELOS DE PERDA DE PROPAGAÇÃO DA LITERATURA	63
<b>6</b>	<b>CONCLUSÕES</b>	<b>65</b>
	<b>Referências</b>	<b>67</b>

# 1 INTRODUÇÃO

## 1.1 CONTEXTUALIZAÇÃO

A internet das coisas (*Internet of the Things-IoT*) já é uma realidade e afetará todos os setores, relacionados com a evolução das redes de telecomunicações que contribui para a evolução de numerosos casos de uso, como a *smart city*, o *smart campus* e a *smart agriculture*, através da utilização de informações das “coisas” conectadas para melhorar todos os tipos de processos e, conseqüentemente, economizar recursos financeiros e energia. A previsão é que o mercado total de *IoT* alcance USD 1,5 trilhão em 2030 (ALWIS et al., 2021).

Em resumo, a Internet das Coisas é uma tecnologia que já tem impactado e continuará impactando significativamente todos os aspectos da vida humana. No entanto, a maioria dos dispositivos utilizados em *IoT*, usará tecnologias sem fio não celulares, como *Bluetooth®*, *Wi-Fi*, *ZigBee*, *THREAD*, *EnOcean*, *Sigfox®*, *LoRa™*, entre outras (SCHAFFERS et al., 2011).

As técnicas de transmissão implementadas em dispositivos de *IoT* exercem uma influência significativa na modelagem do canal de propagação do sinal sem fio, uma vez que, esses dispositivos conectados, possuem diferentes requisitos de largura de banda, taxa de transmissão e potência de transmissão, juntamente com a presença de interferências de outras fontes de sinal sem fio, como atenuações devido a perdas de percursos, flutuações aleatórias devido a sombreamento e efeitos de desvanecimento sobre o canal e sem linha de visada (*NLoS*) devido a obstáculos no caminho de comunicação (WANG et al., 2019).

Em virtude disso, pode haver uma variação significativa na qualidade do sinal recebido, o que pode afetar a confiabilidade e o desempenho da comunicação sem fio. Por isso, são necessários que se tenham estudos a fim de garantir a confiabilidade na conectividade e a cobertura do sinal. Portanto, a elaboração de modelos de perda de propagação para esses tipos de ambientes e tecnologias são fundamentais (LORA™... , 2023).

Diversas pesquisas têm abordado a modelagem de canais de comunicação utilizados em tecnologias de medição sem fio. Entre essas tecnologias, a LoRa (*Long Range*) tem se destacado, como apontado por (ZOURMAND et al., 2019). Isso se deve ao fato de que o alcance da comunicação representa um dos desafios para os sistemas *IoT*, especialmente aqueles baseados em *Bluetooth®* e *Wi-Fi*.

A tecnologia LoRa se destaca ao permitir transmissões de longo alcance, ultrapassando 10 km em linha de visão direta, e ao mesmo tempo mantendo um baixo consumo de energia (Consultimer, 2023). Além disso, a adoção dessa tecnologia pode levar a melhorias significativas nos aplicativos da *IoT*. Isso ocorre devido à capacidade de um único receptor na rede LoRa de

gerenciar múltiplos nós distribuídos em diversos locais do ambiente. E ainda, contribui para reduzir os custos associados à implantação de um sistema IoT.

De outro lado, a modelagem do canal também varia de acordo com as características da área circundante, que têm impacto direto na propagação dos sinais sem fio. Isso representa uma tarefa difícil para os sistemas de planejamento projetarem e implantarem aplicações de *IoT* com eficiência sem entender o modelo de canal apropriado para analisar a cobertura e prever as configurações ideais de implantação.

Em (COTA et al., 2013), o modelo de predição Okumura-Hata foi usado para ajustar seus parâmetros à comunicação de sinais de controle de redes ferroviárias de Portugal, na faixa de frequência de 900 MHz, com intuito de que esse ajuste do modelo ajudasse no planejamento de cobertura dessas redes.

Sendo assim, em ambientes outdoors com vegetação heterogênea, têm a característica especial, de atuar como espalhadores de ondas eletromagnéticas. O espalhamento do sinal, ocorre devido um excesso de atenuação que pode limitar o desempenho da Internet das Coisas (*IoT*), previsto com altas taxas de dados e baixa latência, esperado para comunicações sem fio móveis 5G (LOPEZ-ITURRI et al., 2018).

Por outro lado, vem crescendo, progressivamente, o uso de técnicas de aprendizado de máquina (*machine learning*) para modelar o canal do sinal sem fio e melhorar a predição da perda de propagação em um determinado ambiente. Os trabalhos (MORETA; ACOSTA; KOO, 2019; ALIMPERTIS et al., 2019; THRANE; ZIBAR; CHRISTIANSEN, 2020), por exemplo, citam o uso de algumas técnicas de aprendizado de Máquina (*machine learning-ML*) para predizer essas perdas, mostrando que obtiveram resultados satisfatórios.

Outras pesquisas já foram conduzidas utilizando uma abordagem de campanha de medições para analisar a perda de propagação, empregando modelos fundamentados nas características da Região Amazônica. Um exemplo é o estudo apresentado por (CASTRO et al., 2011), o qual propõe um modelo ajustado, comparando-o com os modelos SUI e COST231-Hata.

No estudo conduzido por Carvalho (CARVALHO et al., 2021), uma abordagem metaheurística foi empregada para a determinação dos parâmetros ótimos de um modelo, visando a minimização do erro quadrático médio (*RMSE*), bem como a maximização do grau de relação cinza e do erro percentual absoluto médio (*GRG-MAPE*) em um cenário caracterizado pela coexistência de elementos urbanos e florestais. Adicionalmente, (ERAS et al., 2022) apresentaram um modelo específico para a faixa de frequência UHF (*Ultra High Frequency*), projetado para ambientes amazônicos que englobam áreas urbanas, rios e florestas. Da mesma forma, em (SILVA et al., 2018) propuseram o uso de funções diáticas de Green para a previsão do campo elétrico em trajetórias variadas (cidade-rio-floresta) em regiões da Amazônia, comparando os resultados obtidos com os modelos ITUR-P.1546-5.

Além de estudos recentes utilizando a tecnologia LoRa no cenário do campus universitário UFPA, a exemplo de (CRUZ et al., 2022), no qual os autores propõe uma metodologia empírica e estatística baseada em medições reais, aplicando ajuste aos coeficientes do modelo de propagação UFPA, proposto por (CASTRO et al., 2011). E em (CARDOSO et al., 2022), onde o trabalho compreende o uso de Veículos Aéreos Não Tripulados (*UAV's*) para auxiliar redes sem fio, ofertando uma melhoria na cobertura do sinal, atuando como repetidor e utilizando o protocolo de comunicação *Long Range Wide-Area Network- (LoRaWAN)* e os estudos foram realizados em ambiente suburbano com densa vegetação avaliando a relação sinal-ruído (SNR).

Neste contexto, esta pesquisa tem como objetivo determinar a melhor configuração para transmissão no ambiente em estudo, utilizando técnicas de *machine learning* e comparando-as com modelos clássicos da literatura. A finalidade é modelar o canal de comunicação que melhor se ajusta a áreas com densa vegetação, na situação de *downlink*, na frequência de 915 MHz. Para isso, são considerados o fator de espalhamento (*Spreading Factor – SF*) 12, que define o espalhamento espectral, a variação da altura do transmissor (6 m, 12 m e 18 m) e as polarizações iguais (*co-polarized*) das antenas de transmissão e recepção.

Para isso, extensas campanhas de medição, utilizando de um drone ASPIRE ONE para auxiliar nas diversas alturas do transmissor, foram realizadas. Essas medições, foram realizadas no bosque Camilo Vianna, localizado dentro da Universidade Federal do Pará (UFPA), que contém 16.700  $m^2$  de extensão, de acordo com o inventário de arborização (PAIVA; LUZ; SILVA, 2022).

Por fim, devido a necessidade de mais estudos na região Amazônia, em relação aos fenômenos físicos de transmissão como reflexão, difração, espalhamento, polarização etc, em florestas. Este trabalho, estuda e avalia a propagação do sinal LoRa, em ambientes com vegetação densa, e com base em dados medidos em campo, propõe dois modelos redes neurais artificiais (RNAs) de propagação para este cenário.

Como resultado, este desafio tem atraído um interesse considerável nas comunidades acadêmica e industrial nos últimos anos. Portanto, essa proposta de tese apresenta propostas de modelos de propagação para *IoT-LoRa* baseados em campanhas de medição em ambientes arborizados e aprendizado de máquina. Um levantamento bem recente dos modelos de propagação para a tecnologia sem fio LoRa também é realizado.

## 1.2 DEFINIÇÃO DO PROBLEMA

A comunicação sem fio em ambientes com vegetação densa enfrenta grandes desafios, como a degradação da qualidade do link devido à absorção, dispersão e atenuação causadas pelas árvores e folhagens (BARRIOS-ULLOA et al., 2022b). Para enfrentar esse desafio, é necessário conduzir um amplo estudo da propagação do sinal LoRa em ambientes com vegetação densa, fazendo extensiva campanha de coleta de dados.

A partir desses dados, pode-se propor um modelo de propagação apropriado para esse ambiente, destacando a importância de modelar o canal de comunicação sem fio, uma vez que, que essa modelagem possibilita estimar e prever as perdas e flutuações aleatórias que ocorrem durante a transmissão de informações por meio de um link sem fio. Isso é fundamental para garantir uma conexão estável e confiável.

## 1.3 OBJETIVO GERAL

O objetivo principal da proposta de tese é implementar um modelo de radiopropagação sem fio através da tecnologia LoRa em 915 MHz e criar dois modelos através das técnicas de *Machine Learning* (ML) para ambientes com densa vegetação que leve em consideração ajustes para diferentes alturas de transmissão (6 m, 12 m e 18 m), polarização igual (VV e HH) e com espalhamento espectral (SF) em 12. Além disso, compará-los com modelos da literatura.

### 1.3.1 OBJETIVOS ESPECÍFICOS

São objetivos específicos desta proposta:

- Validar a metodologia de coletas de dados em ambientes de bosque;
- Realizar as medições em cenário outdoor com densa vegetação (Bosque Camilo Vianna -UFPa);
- Tratar os dados coletados;
- Analisar os dados pós tratamento;
- Utilizar técnicas de modelagem estatística dos mínimos quadrados nos dados tratados, para determinar os coeficientes dos modelos *Close-In* (CI) e *Floating Intercept* (FI);
- Analisar os modelos estatísticos e verificar qual se ajustou melhor aos dados medidos;
- Acrescentar aos modelos CI e FI fatores relacionados as diferentes alturas de transmissão (Tx), copolarizações das antenas do Transmissor (Tx) e receptor (Rx);
- Comparar o modelo obtido com modelos clássicos da literatura aplicados em ambientes com vegetação;
- Usar uma técnica de *machine learning*, como redes neurais, para modelar o canal LoRa através dos dados tratados.

## 1.4 CONTRIBUIÇÕES DA PROPOSTA

As contribuições do trabalho são extremamente importantes para o avanço da tecnologia de redes sem fio em ambientes de vegetação densa. A obtenção de um grande volume de dados relevantes para estudos de modelagem de canal sem fio é crucial para a criação de modelos de propagação mais precisos e eficientes. Ao coletar dados no local estudado, é possível ter uma visão mais abrangente e precisa do comportamento do sinal em ambientes de vegetação densa.

A previsão da perda de propagação em ambientes com vegetação, levando em consideração as diferentes alturas de transmissão, diferentes polarizações das antenas do transmissor e receptor, e fator de espalhamento, é um desafio complexo. Existem modelos de propagação para essa finalidade, porém ainda não tem um modelo na literatura levando em consideração todas essas variantes e acrescentando a utilização de técnicas de *machine learning*, que podem aprimorar ainda mais a precisão desses modelos, levando em conta padrões de comportamento que não seriam capturados por modelos estatísticos convencionais.

Ao aprender padrões a partir de dados coletados em campo, é possível criar modelos de propagação mais precisos e eficientes. Esses modelos podem ser usados para otimizar as configurações de altura e de polarização das antenas de transmissão e recepção e, assim, melhorar o desempenho da rede em ambientes de vegetação densa.

A comparação entre modelos empíricos estatísticos e técnicas de aprendizado de máquina (*machine learning*) é fundamental para a seleção do modelo mais adequado para uma determinada aplicação ou ambiente. Uma vez que, os modelos baseados em *machine learning* usam algoritmos de aprendizado para construir um modelo de canal com base em dados experimentais. Eles são capazes de aprender padrões complexos a partir dos dados, sem a necessidade de conhecimentos prévios sobre as propriedades do canal. O modelo é treinado com dados coletados a partir de medições reais do canal, e é capaz de capturar características específicas do canal que não são facilmente descritas por modelos empíricos estatísticos.

Essa comparação também pode ajudar a identificar as limitações dos modelos estatísticos e os benefícios das técnicas de *machine learning* na modelagem do canal sem fio em ambientes com vegetação densa.

Portanto, essa comparação pode levar a uma melhor compreensão do comportamento do sinal nesse tipo de ambiente e, conseqüentemente, uma melhora na configuração e no desempenho de uma rede de IoT em ambientes com vegetação densa, garantindo um desempenho confiável e consistente da rede. Além de, possibilitar a maximização do desempenho de um determinado ambiente, para garantir uma comunicação eficiente e confiável entre os dispositivos.

Em resumo, as principais contribuições desta pesquisa são:

- Extensivas medições em ambiente Amazônico com o transmissor em diferentes alturas: 6 m (nível do tronco das árvores), 12 m (início da copa das árvores), e 18 m (meio da copa

das árvores);

- Análise da propagação do sinal em ambiente Amazônico considerando diferentes polarizações de transmissão e recepção das antenas, vertical-vertical (VV) e horizontal-horizontal (HH);
- Análise da variação do RSSI (*Received Signal Strength Indication*) e SNR (*Signal-to-Noise Ratio*) para ambientes Amazônicos;
- Cálculo dos coeficientes, *Alpha* e *Beta*, para o modelo *Floating Intercept* (FI) e o expoente de perda (*Path Loss Exponent-PL*) para o modelo *Close-In* (CI) considerando a frequência de 915 MHz para ambientes heterogêneos e com vegetação densa;
- Desenvolvimento de dois modelos de aprendizagem de máquinas (*Machine Learning-ML*), usando (*General Regression Neural Network-GRNN*) e (*MultiLayer Perceptron Neural Network-MLPNN*), baseados em dados medidos em um cenário densamente arborizado.

- **Publicações:**

1. Application of Artificial Neural Networks for Prediction of Received Signal Strength Indication and Signal-to-Noise Ratio in Amazonian Wooded Environments by Brenda S. de S. Barbosa, Hugo A. O. Cruz, Alex S. Macedo, Caio M. M. Cardoso, Filipe C. Fernandes, Leslye E. C. Eras, Jasmine P. L. de Araújo, Gervásio P. S. Calvacante and Fabrício J. B. Barros. *Sensors* 2024, 24, 2542. <https://doi.org/10.3390/s24082542>
2. Análise de Modelos de Propagação por Meio de RNA em Ambiente de Aeroporto para 3,5 GHz Guilherme H. M. Silva, Alex S. Macedo, Caio M.M. Cardoso, Brenda S. de S. Barbosa, Hugo A. O. Cruz, Miércio C. de A. Neto, Jasmine P. L. Araújo e Fabrício J. B. Barros. In: Anais da XIII Conferência Nacional em Comunicações, Redes e Segurança da Informação – Encom 2023.
3. Análise da implantação da HDTV na Amazônia por meio de RNA: estudo de caso do Estado do Amapá Kleysson S. de Oliveira, Alex S. Macedo, Brenda S.S. Barbosa, Caio M. M. Cardoso, Fábio F. Ribeiro, Miércio C. de A. Neto, Jasmine P. L. Araújo e Fabrício J. B. Barros. In: Anais da XIII Conferência Nacional em Comunicações, Redes e Segurança da Informação – Encom 2023.
4. BARBOSA, B. S. S.; Trindade, I. ; Leslye Eras, ; Klautau junior, A. ; Barros, f. J. B. ; Araujo, j. P. L. . Metodologia para Obtenção de Perfil de Potência e Retardo na Faixa de 10 GHz. In: VIII Conferência Nacional em Comunicações, Redes e Segurança da Informação, 2018, Salvador, BA.

## 1.5 ORGANIZAÇÃO DO DOCUMENTO

Este documento está dividido como segue:

- Capítulo 2: serão apresentados os principais trabalhos relevantes e atuais a respeito do tema de modelagem de canal em áreas densamente arborizadas para redes IoT utilizando a tecnologia LoRa.
- Capítulo 3: serão visto os conceitos fundamentais de *IOT*, sobre a tecnologia LoRa, radiopropagação e redes neurais artificiais.
- Capítulo 4: abordará a metodologia adotada no trabalho e a proposta para tese, descrevendo as campanhas de medições realizadas, bem como, a posterior análise dos dados coletados e as implementações já efetuadas.
- Capítulo 5: apresentará os resultados obtidos acompanhados de análises e projeções de experimentos futuros.
- Capítulo 6: apresentará as considerações finais referentes a tese e as sugestões de melhorias para trabalhos futuros.

## 2 TRABALHOS CORRELATOS

### 2.1 CONSIDERAÇÕES INICIAIS

Neste capítulo, é realizado o levantamento das pesquisas que estão sendo propostas sobre modelagem de canal em ambientes externos com vegetação densa, sobretudo, que abordem assuntos sobre o uso da tecnologia LoRa em sistemas *IoT* e com o uso de técnicas de *Machine Learning*.

### 2.2 DESCRIÇÃO DOS TRABALHOS CORRELATOS

O desempenho da tecnologia LoRa, tanto em ambientes interno quanto externo, tem sido alvo de várias pesquisas, embora ainda se tenha poucos artigos com LoRa em ambientes com vegetação. O artigo ([ANZUM, 2021](#)) apresenta o desempenho da tecnologia LoRa em um ambiente localizado no Campus ISTAC-IIUM, composto por uma linha de cinco palmeiras. Utilizando diferentes fatores de espalhamento (SF7-SF12), na frequência de 868 MHz, largura de banda de 125 KHz e potência de transmissão de 14 dBm, o estudo mediu o RSSI (*Received Signal Strength Indication*). O artigo destaca vários fatores que podem impactar o desempenho da propagação LoRa através da vegetação, incluindo difrações, espalhamento e reflexão da folhagem, além das configurações dos parâmetros físicos da própria tecnologia. Conclui-se que, ao levar esses fatores em consideração, é possível otimizar o desempenho da tecnologia LoRa em ambientes com vegetação e superar algumas das limitações e desafios associados a essa abordagem.

O artigo ([ALMUHAYA et al., 2022](#)) analisa de forma detalhada as tecnologias LPWAN, oferecendo uma visão geral das características e limitações, enfatizando as vantagens da LoRa/LoRaWAN e da SigFox em termos de vida útil do dispositivo, capacidade de rede, taxa de dados adaptativa e custo. Além disso, o artigo aborda a tecnologia LoRa/LoRaWAN como uma tendência emergente para aplicações *IoT*, realizando uma análise técnica detalhada da LoRa/LoRaWAN e comparando as principais ferramentas de simulação para investigar seu desempenho. A tecnologia apresenta várias vantagens, como padrão aberto, baixo consumo de energia, transmissão de longo alcance, segurança incorporada, possibilidade de implantações privadas e geolocalização sem GPS. O artigo também discute suas aplicações potenciais em áreas como cidades inteligentes, agricultura e monitoramento ambiental.

Com base nesses pressupostos, o artigo ([OJO; ADAMI; GIORDANO, 2021](#)) apresenta uma pesquisa sobre o LPWAN para aplicações de agricultura inteligente, avaliando o desempenho da tecnologia de transmissão LoRa operando nas faixas de 433 MHz e 868 MHz, destinada

ao monitoramento da vida selvagem em uma área de vegetação florestal. Para isso, utilizaram principalmente a relação sinal-ruído (SNR), indicador de intensidade do sinal recebido (RSSI) e a taxa de entrega de pacotes (PDR), mostrando que a estabilidade do sinal LoRa depende muito do ambiente e é mais estável em ambientes florestais não tão densos do que em altamente densos. Além disso, sugere como pesquisa futura com relação ao estudo do impacto do ambiente, em termos de condições atmosféricas (umidade do ar, pressão, chuva, etc.), do desempenho do LoRa e de se propor um modelo de propagação adequado para ambientes florestais com base nos resultados obtidos.

Nesse contexto, de se obter um modelo de propagação adequado para ambientes com vegetação, o artigo (SABRI et al., 2018) investiga o uso de modelos empíricos de propagação na agricultura de precisão, como o modelo de larga escala perda de percurso no espaço livre (*Free Space - FSPL*) e o modelo terra plana (*Earth Plane- PE*) e modelos para vegetação como *Weissberger*, *ITU-R*, *FITU-R* e *COST235*, em uma simulação que assume uma estufa de terreno plano de 100 m × 100 m de área, na frequência de 2,5 GHz, para prever a perda de propagação do sinal sem fio analisando a variação das alturas das antenas, a distância entre os transceptores e a profundidade da vegetação. As simulações demonstram que as perdas de propagação diminuem com o aumento da altura das antenas, mas aumentam com o aumento da distância entre os transceptores e com a profundidade da vegetação. Além disso, a perda total é calculada somando a perda no espaço livre e a perda na vegetação em ambientes semelhantes a estufas.

Já o artigo (MYAGMARDULAM et al., 2021), propõe um método para melhorar a precisão da perda de percurso para comunicação sem fio em uma área florestal montanhosa, chamada Takakuma na Universidade de Kagoshima, cidade de Tarumizu, sul do Japão, de 2000 m onde espécies das árvores dominantes eram o cedro japonês e o cipreste japonês. Usaram informações de tempo, latitude, longitude, altitude, velocidade, direção e a intensidade do sinal, utilizando dois *Drone Mapper* com LoRa, um como transmissor e outro como receptor, na frequência de 920 MHz, SF12, potência de transmissão de 13 dBm, largura de banda de 400 KHz e antenas monopolo nas alturas de 2 m e 2,5 m, para receptor e transmissor, respectivamente, com polarização vertical. Esse método divide a distância total entre o transmissor e o receptor em duas partes: a distância de transmissão através da floresta e a distância de transmissão em espaço livre. Em seguida, calcula as perdas de percurso para a área florestal e para a área de espaço livre, somando-as para obter a perda de percurso total. Para determinar essas distâncias de transmissão em espaço livre e em floresta, foram utilizados modelos digitais de superfície 3D (*DSM*) com informações de elevação da superfície, incluindo vegetação e altura dos objetos. Isso permitiu identificar se o caminho de transmissão estava na floresta ou em espaço livre, utilizando um simples método de análise espacial do perfil. Por fim, compara com cinco modelos da literatura, *Weissberger*, *ITU-R*, *FITU-R*, *LITU-R* e *COST235*, e conclui que o método proposto tem um nível razoável de precisão da perda de percurso em ambientes montanhosos com florestas e pode potencialmente melhorar a precisão da comunicação sem fio nesses tipos ambientes.

Em (WU; ZHANG; MIAO, 2017), é investigado o comportamento dos canais sem fio nas frequências de 433 MHz e 2,4 GHz, considerando os efeitos da distância e da altura da antena, na intensidade do sinal e na taxa de perda de pacotes, em áreas agrícolas, comparando, com modelos modificados de decaimento exponencial para ambientes com vegetação, *Weissberger*, *ITU-R* e *COST235* e modelo logarítmico linear, em simulações Matlab, obtendo um modelo de ajuste ideal, ou seja, o modelo de decaimento exponencial paramétrico (*OFPED*). As medições são realizadas em um campo de plantação de trigo, usando a tecnologia *Zigbee* nos sensores sem fio, com potência de transmissão de 0 dBm, e o ganho da antena omnidirecional de 4 dB, os transmissores e receptores, são colocados na mesma altura e na mesma direção para evitar a perda de polarização das antenas. O *RSSI* e o *PLR* (*Packet Loss Rate*) são obtidos em diferentes distâncias dos transceptores, e várias alturas das antenas transmissora e receptora, levando em consideração três estágios da plantação de trigo. Com isso, descobriram que, o *RSSI* diminui conforme a distância do transceptor aumenta, e o *PLR* aumenta conforme a distância do transceptor aumenta. Além disso, a perda de percurso diminui com o aumento da altura das antenas, e a perda de percurso em 2.4 GHz é maior do que em 433 MHz. Por fim, os resultados da validação mostram que os modelos *MED* (*Modified Exponential Decay*) podem ser usados como limites superiores e inferiores conservadores de perda de percurso, pelo menos para o campo de trigo.

No (ALSAYYARI; ALDOSARY, 2018), o estudo é sobre a implantação de redes de sensores sem fio (*WSN*) em ambientes de grama alta. Medidas de intensidade do sinal recebido (*RSS*) foram coletadas em uma fazenda com área de 80 m x 80 m de grama alta, em que o transmissor e o receptor estavam sempre em visada direta (*LOS*). A antena de transmissão foi colocada no centro da área da grama, e as antenas receptoras colocadas em oito distâncias diferentes, essas antenas tinham 20 cm de altura com padrões de radiação omnidirecional. A coleta dos dados foi feita na frequência de 1925 MHz, em um total de 128 pontos de medição, com 300 amostras de *RSS* coletado em cada ponto. Com isso, foi possível propor um modelo empírico de perda de propagação para esse tipo de cenário, que foi comparado com modelos clássicos, espaço livre (*FSPL*) e dois raios, os quais foram mais imprecisos na previsão de *RSS* em ambientes com grama alta.

Por fim, o artigo (BARRIOS-ULLOA et al., 2022a), apresenta uma revisão sistemática da literatura de modelos de propagação para redes de sensores sem fio (*WSN*) em ambientes com vegetação, inclusive cita os artigos (ANZUM, 2021; SABRI et al., 2018; MYAGMARDULAM et al., 2021; WU; ZHANG; MIAO, 2017; ALSAYYARI; ALDOSARY, 2018), e mostra que nos anos de 2011 a 2021 a preferência era pela tecnologia *Zigbee* para esses ambientes, e que atualmente, o uso da tecnologia LoRa vem crescendo. Além disso, sugere usar técnicas que não foram usadas em estudos de propagação de comunicação sem fio nesses cenários, como aprendizado de máquina.

Em vista disso, o artigo (SERETIS; SARRIS, 2022) fornece uma visão geral dos desenvolvimentos recentes na modelagem da propagação de ondas de rádio usando algoritmos de aprendizado de máquina (*ML*). O artigo destaca a importância da escolha do tipo de método de *ML* a ser utilizado para a precisão do modelo de propagação. Além disso, mostra o número significativo de artigos de modelagem de propagação que utilizaram redes neurais artificiais (*ANNs*) e prevê que essa tendência continue a crescer. O artigo também destaca os desafios, as perspectivas e os problemas em aberto nesta linha de pesquisa.

Alguns artigos relacionados citados, o (WU et al., 2020) utiliza a rede neural *Backpropagation* (*BP*) para prever a potência do sinal recebido em um ambiente suburbano, este modelo é baseado em medições de campo obtidas da estação base (*BS*) e do receptor (*Rx*), incluindo informações da topografia, frequência, potência transmitida, do ângulo da antena e a potência recebida em todas as localizações, os resultados mostram que o modelo proposto é capaz de prever com precisão a potência do sinal recebido para este tipo de ambiente.

O (JO et al., 2020) usa a combinação de três técnicas, a regressão multidimensional baseada em redes neurais artificiais (*ANN*), análise de variância baseada em processo gaussiano e a seleção de características auxiliada pela análise de componentes principais (*PCA*), são utilizados dados de perda de percurso medidos em uma área suburbana na Coreia. O estudo mostra que o modelo combinado proposto de perda de percurso e sombreamento é mais preciso e flexível em comparação com o modelo convencional de perda de percurso log-normal. O estudo de (MORETA; ACOSTA; KOO, 2019) apresenta uma pesquisa sobre a previsão da cobertura de televisão digital terrestre (*DTT*) utilizando técnicas de regressão de aprendizado de máquina. Através de medições de intensidade do campo elétrico em oito canais *DTT* que operam na cidade de Quito, no Equador, o estudo demonstra a eficiência do uso de *ML* nesta aplicação.

Já o artigo (OJO; IMOIZE; ALIENYI, 2020), realizou medições em Chipre, em seis estações base transceptoras (*BTS*), nas frequências 433 MHz e 2,4 GHz, e os equipamentos móveis utilizados nestas medições de campo foram o telefone Sony Z2, que possui o *TEMS* instalado para medir a potência recebida e outras informações de indicadores-chave de desempenho (*KPI*) da rede investigada. O móvel foi mantido em uma altura de 1,5 m, e distância média de propagação percorrida em torno de 3,0 km, e o tempo de medição especificado é de cerca de 60 s em média, com o intuito de investigar o impacto da altura da planta e a altura da antena em vários estágios de crescimento da plantação, na propagação de sinal, analisando o *RSSI* e a taxa de perda dos pacotes (*PLD*). A partir desses dados propõe dois modelos *ML*, a rede neural de função de base radial (*RBFNN*) e a rede neural de percepção multicamada (*MLPNN*), comparando com os seguintes modelos empíricos: espaço livre, COST231 Hata, ECC-33, Ericsson e o ITU-R, através das métricas RMSE, MAPE, MAE, and  $R^2$ , mostrando que a *RBFNN* teve um desempenho melhor que a *MLPNN* e prevê a perda de propagação mais próxima dos dados medidos com erro muito baixo.

Portanto, a partir deste panorama de trabalhos correlatos, nota-se que esta pesquisa introduz uma abordagem original, pois apresenta dois modelos de rede neural, *GRNN* e *MLPNN*, usando a tecnologia LoRa, na frequência de 915 MHz e considerando a co-polarização das antenas, transmissora e receptora, em ambientes arborizados amazônicos, para prever com maior precisão o *RSSI* e o *SNR*.

## 2.3 COMPARATIVO ENTRE ESTE TRABALHO E OS CORRELATOS

A comparação da presente pesquisa com trabalhos relacionados é apresentada na Tabela 1. De acordo com o mostrado na Tabela 1, nenhum trabalho abordou a análise da correspondência de polarizações das antenas de transmissão e recepção. Além disso, os trabalhos não analisam as diferentes alturas do transmissor em ambientes com vegetação densa, relacionando a altura do transmissor com diferentes partes das árvores. E mais, embora alguns já empreguem técnicas de aprendizado de máquina, nenhum deles utiliza uma rede neural de regressão geral (GRNN).

Tabela 1 – Comparativo entre trabalhos correlatos e esta pesquisa

CORRELATOS	TECNOLOGIA FREQUÊNCIA AMBIENTE	TÉCNICA DE ML	DIFERENCIAL DO TRABALHO	DIFERENÇA EM RELAÇÃO A TESE
(WU; ZHANG; MIAO, 2017)	Sinal RF 433 MHz e 2.4 GHz Campo de trigo	Não	Investigar a propagação do sinal RF em campos de trigo, considerando a influência da altura das plantas e das antenas em diferentes estágios de crescimento.	Cenário específico em um campo de trigo, avaliam com modelos baseados MED. Não utiliza a frequência de 915MHz e nem técnicas de ML para modelagem do canal.
(ALSAYYARI; ALDOSARY, 2018)	WSN 1925 MHz Ambiente de grama alta em uma fazenda	Não	Modelo proposto para o ambiente de grama alta será comparado com modelos empíricos de outros ambientes externos, bem como com modelos teóricos, como o modelo de perda de espaço livre (FSPL) e o modelo de perda de dois raios.	Cenário rasteiro de grama alta, com frequências de 1925 MHz.
(SABRI et al., 2018)	WSN 2.245 GHz Simulação de uma estufa 100 m x 100 m	Não	Faz análise dos modelos de perda de percurso em larga escala, como o modelo de perda de espaço livre (FSPL) e o modelo de perda de terra plana (PE), juntamente com modelos de vegetação como o modelo Weissberger e o modelo ITU-R.	O trabalho aborda um ambiente de estufa na faixa de 2.5GHz, avalia vários modelos de propagação para vegetação, mas nenhum relacionado a ML.
(MORETA; ACOSTA; KOO, 2019)	Televisão digital terrestre (DTT) na faixa de VHF e UHF Zona localizada em Quito, Equador	Random Forest, AdaBoost, KNN	Uso de algoritmos de regressão de aprendizado de máquina, para prever a cobertura de televisão digital terrestre.	Modelo baseado no Log normal para estimar perda de propagação, para TV digital.
(OJO; IMOIZE; ALIENYI, 2020)	WSN de até 2600 MHz Áreas urbanas, suburbanas e rurais	RBFNN, MLPNN	Introdução de algoritmos de aprendizado de máquina para previsões de perda de percurso, visando superar as limitações dos modelos empíricos e determinísticos existentes.	Utiliza frequências de 433 MHz e 2400 MHz e cria dois modelos de perda de propagação baseados em RNA, e os compara com modelos clássicos da Literatura.
(JO et al., 2020)	WSN 877.26 MHz, 2127.6 MHz e 5.8 GHz X	BPNN, SVR, Árvore de Decisão, Random Forest, KNN, Adaboost	Abordagem de expansão de dados para prever perdas de percurso em novas frequências, utilizando modelos clássicos e algoritmos de aprendizado de máquina.	Desenvolve um modelo baseado em RNA contemplando o efeito de sombreamento.
(WU et al., 2020)	Survey / Ambientes suburbanos	Retropropagação (BP)	Prever com precisão a potência recebida, simplificando a modelagem do ambiente 3D e analisando o impacto das características ambientais nas previsões.	Cria um modelo utilizando vários parâmetros geométricos do ambiente, como a topografia e ângulos de transmissão.
(ANZUM, 2021)	LoRa 868 MHz Área de vegetação do campus da ISTAC-IIUM	Não	Revisão dos fatores que impactam na propagação de LoRa em meio vegetativo e análise de desempenho de LoRa utilizando SF7-SF12 na frequência de 868 MHz	Utiliza uma frequência diferente ao do trabalho proposto, não avalia outras métricas além do RSSI, como o SNR. Não utiliza nenhuma técnica de ML.
(OJO; ADAMI; GIORDANO, 2021)	LoRa (433 e 868 MHz) Simulação	Não	Faz uma análise da comunicação LoRa em ambientes florestais, destacando a influência da vegetação na qualidade do canal de comunicação.	Utiliza rede LoRa só que em frequências diferentes (433 e 868 MHz), não homologadas no Brasil, utiliza também métricas como RSSI e SNR além de emprega a perda de pacote, não aplicando nenhuma técnica de ML.
(MYAGMARDULAM et al., 2021)	LoRa 920 MHz Floresta Experimental Takakuma, Universidade de Kagoshima, Japão	Não	Desenvolver um modelo simples e preciso baseado na combinação de um modelo empírico de perda de percurso e um modelo de perda de percurso em espaço livre (FSPL) para melhorar a precisão geral da previsão em um ambiente florestal.	O trabalho aborda um ambiente florestal na faixa de 920 MHz, desenvolve um modelo de propagação para vegetação, mas nenhum relacionado a ML.
(BARRIOS-ULLOA et al., 2022)	Zigbee (870 MHz, 902-928 MHz e 2.4 GHz) e LoRaWAN (433 MHz e 868 MHz) Ambientes agrícolas e de vegetação	Não	Faz uma análise detalhada de modelos de propagação de ondas de rádio em ambientes agrícolas e de vegetação, com foco na eficácia e validação desses modelos.	Survey a respeito das LPWAN, demonstra o crescimento da rede LoRa.
(ALMUHAYA et al., 2022)	LPWAN (ênfase LoRa/LoRaWAN) Não há uma área específica	Não	Análise de forma detalhada as tecnologias LPWAN, enfatizando as vantagens da LoRa/LoRaWAN e da SigFox em termos de vida útil do dispositivo, capacidade de rede, taxa de dados adaptativa e custo.	Uma survey sobre a Tecnologia LoRaWAN, tendências recentes, ferramentas de simulação e direções futuras e não aborda nenhuma técnica de ML.
(SERETIS; SARRIS, 2022)	WSN 900 MHz e 2.4 GHz Ambientes urbanos e túneis	k-NN, SVM, k-means, GMM, Random Forests, Adaboost, ANNs	Aborda a modelagem de propagação de ondas de rádio utilizando diferentes algoritmos de aprendizado de máquina. Considera a complexidade do ambiente, como densidade de copa e complexidade do terreno, ao projetar o modelo de ML.	Implementação de novas técnicas, como ML para aumentar precisão da predição da perda de propagação em ambientes adversos.

## 2.4 SÍNTESE DO CAPÍTULO

Este capítulo apresentou 13 pesquisas que compartilham pontos em comum. Cada pesquisa foi brevemente descrita e, por fim, foi elaborada uma tabela comparando essas publicações à pesquisa atual bem como descrevendo o percentual de cada tema na totalidade dos trabalhos correlatos. Observou-se também a complementariedade dos temas analisados na Tabela 1.

## 3 REFERENCIAL TEÓRICO

### 3.1 CONSIDERAÇÕES INICIAIS

Neste capítulo serão apresentados os fundamentos básicos necessários para o entendimento do conceito de internet das coisas (*IoT*), sobre a tecnologia LoRa, radiopropagação e redes neurais artificiais.

### 3.2 A INTERNET DAS COISAS

#### *(INTERNET OF THE THINGS– IoT)*

Em junho de 2009, Kevin Ashton comentou que o termo "Internet das Coisas" foi primeiramente utilizado em seu trabalho intitulado "*I made at Procter & Gamble*" em 1999 (ASHTON, 1999). No entanto, o termo não era amplamente pesquisado. Por volta de 2005, um termo bastante procurado, tanto pela academia quanto pela indústria, e relacionado à IoT, era "Redes de Sensores Sem Fio" (do inglês *Wireless Sensor Networks - WSN*), essas redes trouxeram avanços na automação residencial e industrial (KELLY; SURYADEVARA; MUKHOPADHYAY, 2013; XU; HE; LI, 2014), bem como técnicas para lidar com as várias limitações dos dispositivos, como memória, energia, escalabilidade e robustez da rede (LOUREIRO et al., 2003). Nos anos seguintes, entre 2008 e 2010, o termo "Internet das Coisas" rapidamente ganhou popularidade devido ao amadurecimento das Redes de Sensores Sem Fio e às crescentes expectativas em relação à *IoT*. Em termos reais, a origem semântica da expressão Internet das Coisas é composta por duas palavras e conceitos: em "Internet", tem-se o protocolo de comunicação, e em "Coisas", objetos não identificáveis com precisão. À vista disso, semanticamente, "Internet das Coisas" significa uma rede mundial de objetos interligados, com base em protocolos de comunicação (BASSI; HORN, 2008).

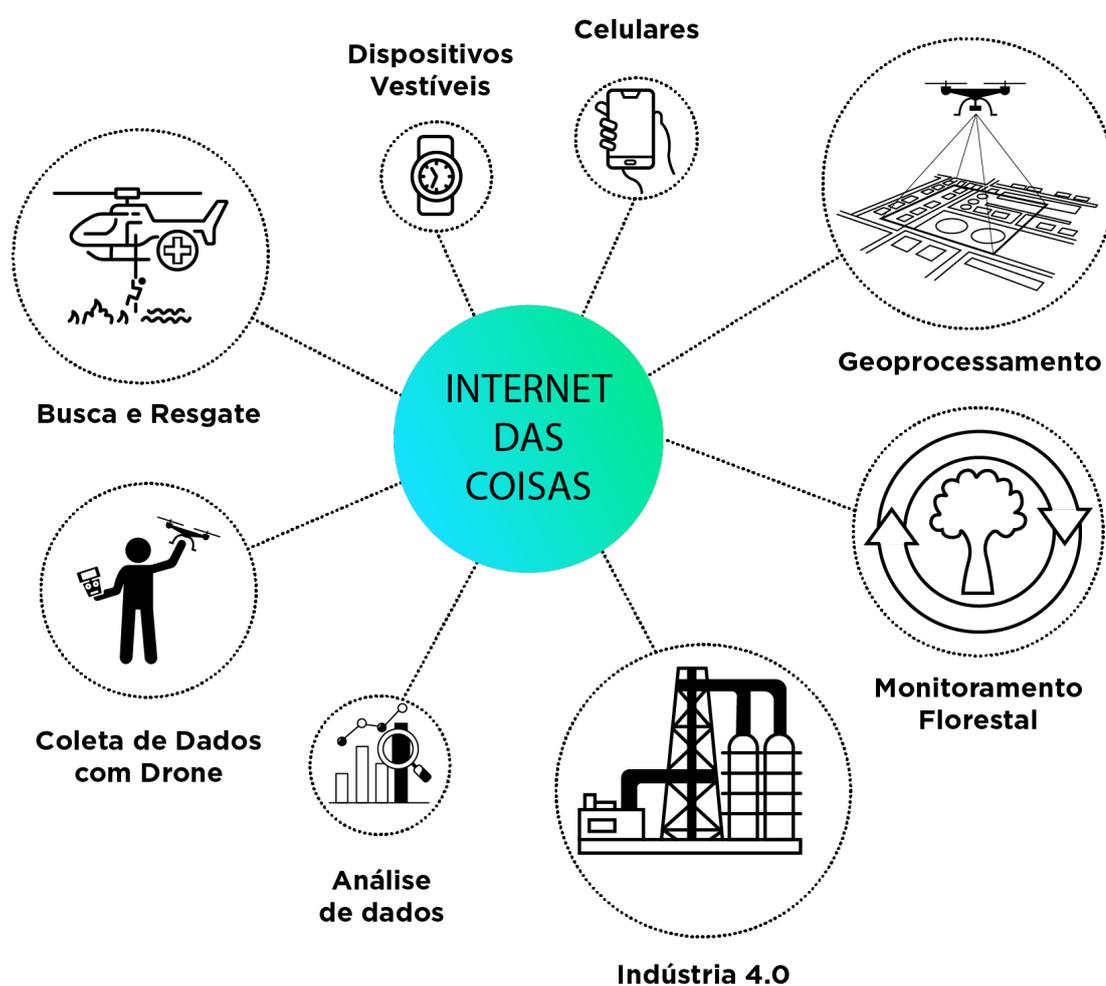


Figura 1 – Internet das Coisas.

Fonte: A autora.

Para viabilizar a conectividade dos dispositivos *IoT* (Figura 1), são necessárias redes de comunicação eficientes e escaláveis. Nesse contexto, as redes *LPWAN* (*Low-Power Wide-Area Networks*) desempenham um papel crucial, uma vez que, foram projetadas para oferecer conectividade de longo alcance e baixo consumo de energia, tornando-as ideais para implantações em larga escala de dispositivos *IoT*. Entre as tecnologias *LPWAN*, destacamos o *LoRa* (*Long Range*), que utiliza a modulação de rádio de espalhamento espectral para comunicações de longo alcance em frequências não licenciadas (CENTENARO et al., 2016).

Para que haja essa comunicação entre os dispositivos *LoRa*, foi projetado um protocolo de comunicação chamado *LoRaWAN*, que define como os dispositivos se comunicam com as redes e como os dados são transmitidos entre os dispositivos, os gateways e os servidores de rede. O *LoRaWAN* oferece recursos como segurança avançada, eficiência de energia e escalabilidade, tornando-o adequado para implantações em larga escala de dispositivos *IoT* em diversas aplicações (LORAWAN..., 2022).

### 3.3 TECNOLOGIAS DE REDES DE ÁREA AMPLA DE BAIXA POTÊNCIA (LPWANs)

As tecnologias de redes de área ampla de baixa potência (LPWAN) caracterizam-se por baixo consumo energético e oferecem cobertura para vastas áreas geográficas. Elas fornecem conectividade a dispositivos e aplicativos que demandam pouca mobilidade, baixas velocidades e transferência esporádica de dados, como sensores. As LPWANs preenchem a lacuna entre redes celulares móveis (3G, LTE) e redes sem fio de curto alcance (por exemplo, *Bluetooth*, *Wi-Fi* e *Zigbee*), sendo desenhadas para comunicações máquina a máquina. Os dispositivos LPWAN possuem longa duração da bateria, já que transmitem apenas pequenos pacotes de dados em intervalos espaçados. As soluções LPWAN garantem uma ampla cobertura que não está limitada pela distância entre os pontos de acesso (tais como estações base ou torres), fazendo uso de novas técnicas de modulação e escolhas de frequência. Além disso, não requerem, normalmente, comunicação em linha de visão, reduzindo significativamente o número de pontos de acesso por unidade de área em comparação com as tecnologias celulares sem fio tradicionais. (CHERUVU et al., 2020)

Não há um padrão único para as LPWANs, havendo várias tecnologias, de acordo com a Figura 2 concorrentes que oferecem diferentes níveis de cobertura e capacidade. Nesta tese, abordaremos a tecnologia LoRa.

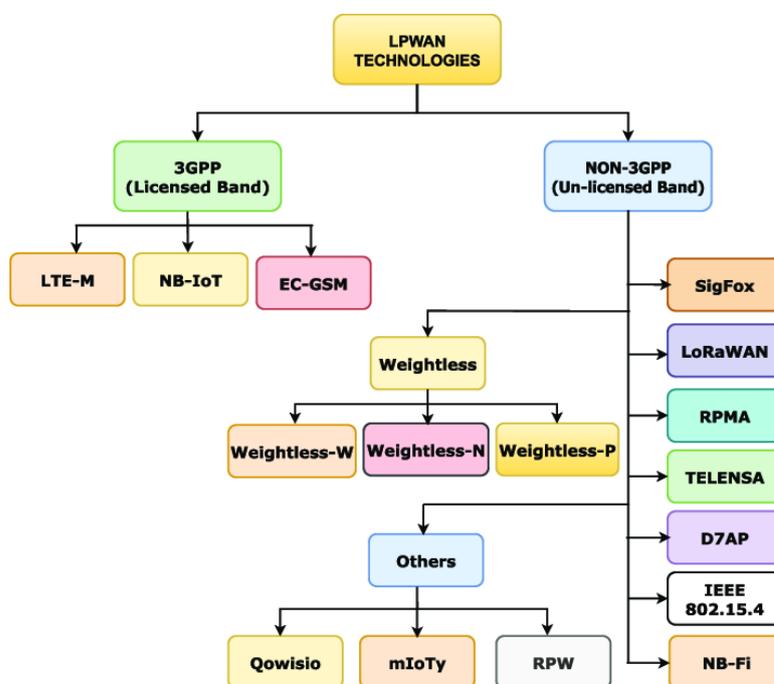


Figura 2 – Classificação de tecnologias LPWAN.

Fonte: (CHILAMKURTHY et al., 2022).

### 3.3.1 TECNOLOGIA LoRa (LONG RANGE) E LoRaWAN

A Figura 3 mostra como são as camadas da tecnologia LoRa. LoRa é uma modulação de rádio frequência (RF) e corresponde à camada física no modelo de referência OSI, contitui-se como um protocolo patenteado e desenvolvido pela Semtech. Enquanto isso, LoRaWAN é é um protocolo de camada MAC que tem como objetivo resolver questões de gerenciamento do meio e congestão de rede. Qualquer nó que utilize o protocolo LoRaWAN pode se beneficiar das seguintes características fornecidas pelo padrão: gerenciamento de canais, eficiência energética, taxa de dados adaptativa, segurança e geolocalização sem GPS, e diferente do protocolo LoRa, ele é de código aberto. (HAXHIBEQIRI et al., 2018)

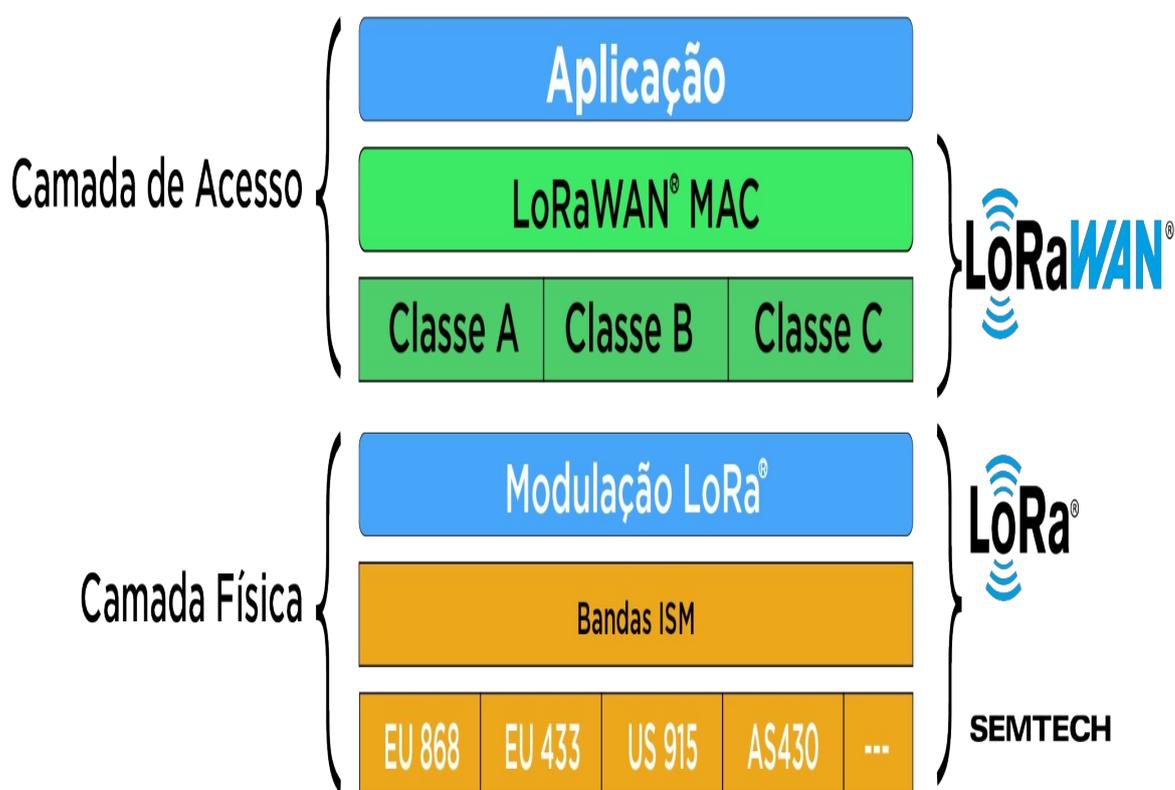


Figura 3 – Ilustração das Camadas da Tecnologia LoRa.

Fonte: adaptado (CHILAMKURTHY et al., 2022)

### 3.3.1.1 CAMADA FÍSICA - LoRa

A tecnologia LoRa, solução proprietária da Semtech, é uma das principais tecnologia usadas em redes de baixo consumo e longa distância (*Low Power Wide Area Network- LPWAN*), que usa faixas de frequência de rádio ISM (*Industrial Scientific and Medical*) não licenciadas, ou seja, 868 MHz na Europa, 915 MHz na América do Norte/sul e 433 MHz na Ásia. Utiliza modulação do tipo (*Chirp Spread Spectrum-CSS*) e correção de erro (*Forward Error Correction-FEC*). Pode operar mesmo com uma baixa relação sinal ruído ([LORA™. . . , 2023](#)), e isso tudo pode ser determinado a partir de quatro parâmetros de configuração da LoRa: a frequência da portadora, que define a frequência central para a banda de transmissão; a largura de banda (*Bandwidth- BW*), que define o tamanho da faixa de frequências utilizada; a taxa de código (*Code Rate- CR*), que define a taxa de FEC e o fator de espalhamento (*Spreading Factor- SF*), que define o espalhamento espectral ([BOR; VIDLER; ROEDIG, 2016](#)). A frequência da portadora é definida de acordo com a região de operação dos equipamentos. Esse parâmetro não é, em geral, ajustável de acordo com a aplicação.

A largura de banda, por sua vez, possui três valores programáveis: 125 kHz, 250 kHz e 500 kHz. O SF, principal parâmetro de ajuste da modulação LoRa, define a razão entre a taxa de bits e a taxa de chirps. A especificação LoRa define seis valores diferentes para o parâmetro fator de espalhamento: SF7, SF8, SF9, SF10, SF11 e SF12 ([AUGUSTIN et al., 2016](#)), admitindo formar canais ortogonais, fazendo com que enlaces com fatores de espalhamento diferentes não tenham colisões entre si. Um maior SF aumenta a sensibilidade do limiar de recepção em termos de potência, porém, aumenta o tempo de duração de símbolos e diminui a taxa de transmissão do enlace ([RAZA; KULKARNI; SOORIYABANDARA, 2017](#)). A taxa de bits, então, é dada por:

$$R_b = SF \times \frac{BW}{2^{SF}} \times CR \quad (3.1)$$

Em que:

- $R_b$  é a taxa de transmissão de dados (em bits por segundo, bps).
- $SF$  é o fator de espalhamento (*Spreading Factor*).
- $BW$  é a largura de banda (*Bandwidth*, em Hz).
- $CR$  é a taxa de codificação (*Coding Rate*).

A CR define quantos bits são utilizados para redundância na mensagem, a fim de realizar a recuperação de erros.

$$CR = \frac{4}{4 + n}, \quad n \in \{1, 2, 3, 4\} \quad (3.2)$$

Também é especificada uma taxa de transmissão  $R_b$  teórica, definida em função do fator de espalhamento e da taxa de código, representando a taxa de bits efetiva como:

$$R_b = SF \times \frac{T_c \times BW}{2^{SF}}, SF \in \{7, 8, 9, 10, 11, 12\} \quad (3.3)$$

Isso significa que, para uma largura de banda fixa, aumentar o fator SF em um, resultará em uma duplicação da duração de um símbolo. Da mesma forma, quanto maior a largura de banda, maior será a taxa de chirps (símbolos) transmitidos. No entanto, à medida que o SF aumenta, cresce também a probabilidade de ocorrer erros de símbolo, assim como a probabilidade de colisões. Por essas razões, a seleção do SF também influencia a sensibilidade de recepção, que é expressa em dB pela equação a seguir (NETO, 2020):

$$S = -174 + \log_{10}(BW) + NF + SNR \quad (3.4)$$

Em que, o primeiro termo se deve ao ruído térmico no receptor em 1 Hz de largura de banda, NF é a figura de ruído no receptor, e SNR é a relação sinal-ruído exigida pelo esquema de modulação subjacente. A Tabela 2 para uma largura de banda fixa de 125 KHz apresenta a relação entre taxa de bits, tempo de um chirp no ar e sensibilidade *versus* SF e Largura de banda, e também mostra as variações das sensibilidades teóricas de SNR e RSSI, onde é possível visualizar que aumentar o fator de espalhamento permite uma melhor sensibilidade.

Tabela 2 – Relação entre os parâmetros LoRa para uma largura de banda de 125 KHz.

SF	Chirps/ Símbolo	Tempo no Ar (ms)	Carga útil (byte)	Taxa de Transmis- são (bits/s)	SNR (dB)	RSSI (dBm)
SF7	128	41	242	5468	-7,5	-123
SF8	256	72	242	3125	-10	-126
SF9	512	144	115	1752	-12,5	-129
SF10	1024	288	51	976	-15	-132
SF11	2048	577	51	537	-17,5	-135
SF12	4096	991	51	293	-20	-137

Fonte: A autora.

Na tabela 2, pode-se observar que uma mudança no SF também resulta em uma mudança no Tempo no Ar da informação enviada. Reduzir o SF implica em aumentar a taxa de dados, o que por sua vez reduz o tempo no ar (ToA). Se um nó necessita de menos ToA, esse tempo fica disponível para outros nós transmitirem. Com um ToA menor, há economia no consumo de bateria. A capacidade de ajustar o SF, e consequentemente a taxa de dados e o Tempo no Ar, é conhecida como Taxa de Dados Adaptativa (ADR). O ADR opera com condições de uplink e downlink simétricas (NETO, 2020).

### 3.3.1.2 CAMADA MAC - LoRaWAN

A configuração da rede LoRaWAN exibe uma estrutura de estrela, onde os dispositivos finais só podem interagir com os gateways LoRaWAN e não entre si diretamente. Múltiplos gateways estão ligados a um servidor de rede central. Os gateways LoRaWAN têm a tarefa exclusiva de rotear pacotes de dados brutos dos nós finais para o servidor de rede, encapsulando-os em pacotes UDP/IP. O servidor de rede é responsável por enviar pacotes de downlink e comandos MAC para os dispositivos finais, se necessário. Adicionalmente, a comunicação é concluída nos servidores de aplicativos, os quais podem ser de propriedade de terceiros, conforme ilustrado na Figura 4 abaixo.

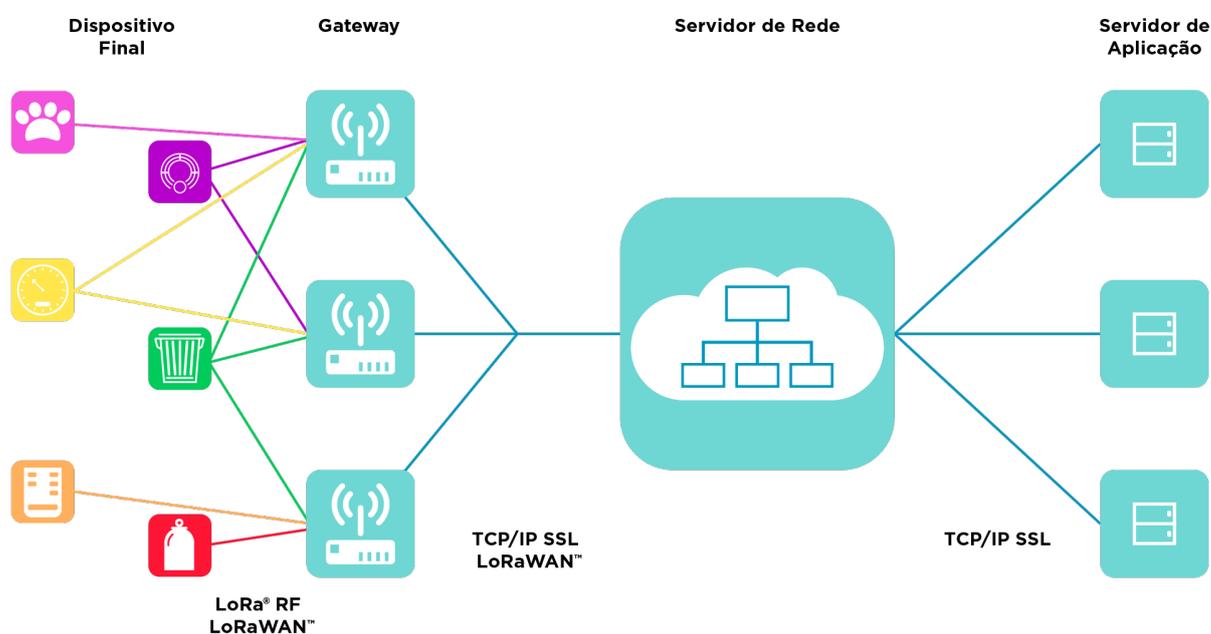


Figura 4 – Protocolo de rede LoRaWAN.

Fonte: adaptado ([ALLIANCE, 2015](#))

o LoRaWAN descreve o protocolo de comunicação e a arquitetura do sistema para a rede. Devido à sua influência sobre o protocolo de comunicação e a arquitetura de rede, o LoRaWAN é principalmente responsável pela vida útil da bateria do dispositivo, capacidade da rede, qualidade de serviço, segurança e pela variedade de aplicações atendidas pela rede ([ALLIANCE, 2015](#)).

O foco da padronização está na implementação generalizada de um ecossistema econômico com ciclo de vida prolongado de bateria, comunicação bidirecional, taxas de dados ajustáveis e estratégias de segurança ([ALLIANCE, 2015](#)). O LoRaWAN opera em um espectro não licenciado, embora também seja viável operar no espectro licenciado ([GAMBIROŽA et al., 2019](#)).

LoRaWAN estabelece três classes A, B e C de dispositivos com distintas habilidades, de acordo com a Figura 5. Cada classe possui características únicas para atender diversas exigências de aplicação. Cada classe opera com um equilíbrio entre a duração da bateria e a latência da comunicação do downlink da rede (MEKKI et al., 2019).

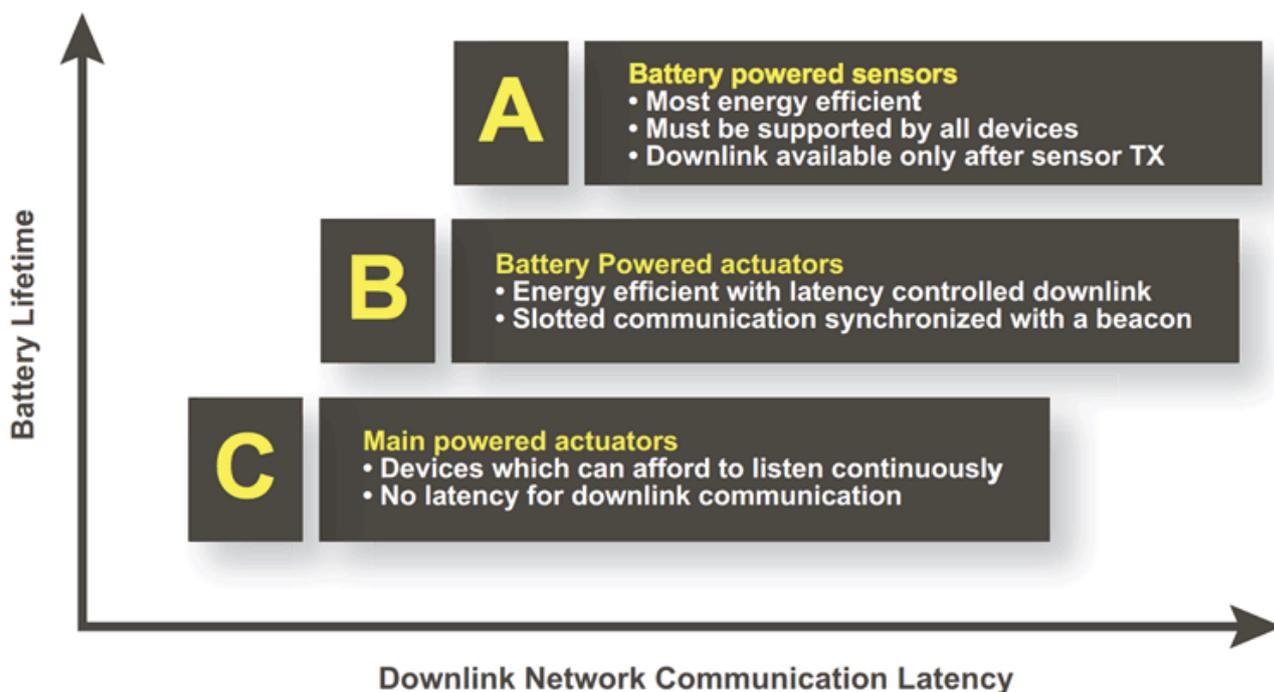


Figura 5 – Classes de Dispositivos LoRa.

Fonte: (ALLIANCE, 2015)

- Classe A: formada por sensores que funcionam com baterias de baixo consumo. A comunicação é bidirecional e a recepção dos pacotes de dados provenientes do *gateway* só é possível após a transmissão de informações pelo módulo.
- Classe B: composta por atuadores que operam com bateria. Neste caso, a recepção dos pacotes de dados vindos do *gateway* ocorre de maneira programada (recebimento programado), ou seja, são trocadas informações entre o módulo e o *gateway* indicando se o módulo está pronto para receber o pacote de dados.
- Classe C: constituída por dispositivos com alto consumo de energia que geralmente operam conectados a uma rede elétrica. Realizam comunicação bidirecional e estão sempre prontos para receber dados provenientes do *gateway*.

As três classes podem existir simultaneamente na rede e os dispositivos podem transitar de uma classe para outra, sendo assim, todos esses dispositivos devem ser compatíveis com todos os modos operacionais da classe mais baixa. Em outras palavras, todos os dispositivos devem ser capazes de operar como dispositivos Classe A; dispositivos Classe B devem suportar tanto os modos Classe A quanto Classe B; e dispositivos Classe C devem suportar os três modos de operação. A diferenciação entre os três tipos de dispositivos está relacionada à maneira como o dispositivo se comunica com a rede (SPADACCINO; CRINÓ; CUOMO, 2022).

## 3.4 RÁDIOPROPAGAÇÃO

Nos sistemas de tecnologia sem fio, a transmissão de informações ocorre através de ondas eletromagnéticas. Durante o processo de propagação, ocorre interação entre as ondas e o ambiente, resultando na atenuação do sinal. Essa atenuação acarreta perda do sinal ao longo do percurso, o que acaba por limitar a área de cobertura. Para o planejamento inicial da rede, é fundamental ter uma previsão precisa da perda do sinal. A capacidade de determinar a localização ideal para os pontos de acesso, obter taxas de dados adequadas e estimar a cobertura pode ser alcançada através de estudos empíricos, de uma série de medidas de propagação do sinal no ambiente de estudo e modelos de propagação.

### 3.4.1 MECANISMO DE PROPAGAÇÃO

Um resumo dos principais mecanismos de propagação de ondas de rádio para redes de sensores sem fio é apresentada nesta tese. Os mecanismos que regem a propagação de rádio são complexos e diversos, e geralmente podem ser atribuídos a três mecanismos básicos de propagação: reflexão, difração e espalhamento ou dispersão. conforme a Figura 6.

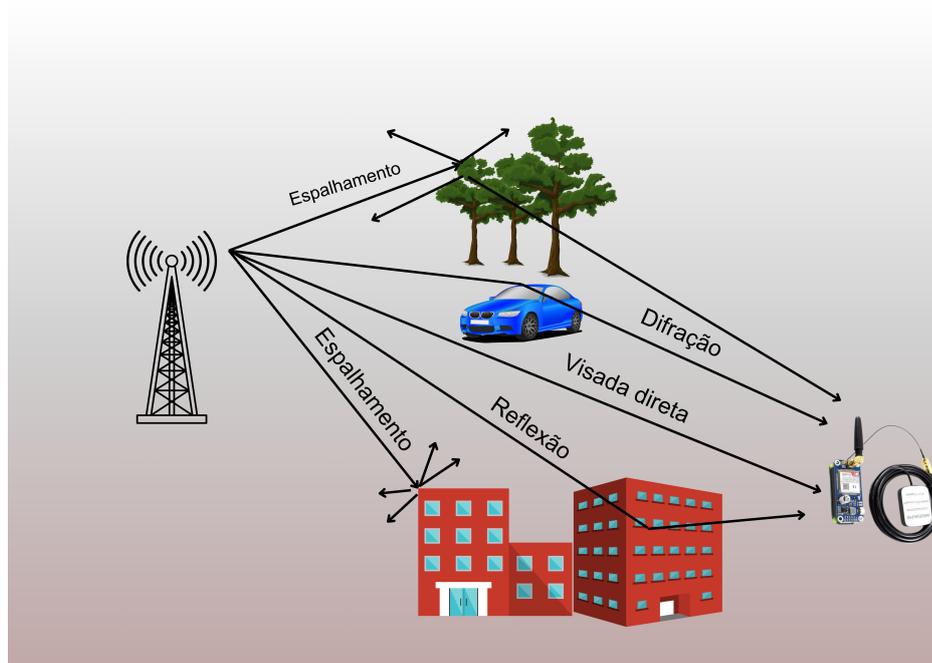


Figura 6 – Mecanismos de Radiopropagação.

Fonte: A autora.

#### 3.4.1.1 VISADA DIRETA (*LOS - LINE-OF-SIGHT*)

Nesse tipo de propagação, as ondas viajam diretamente da antena transmissora para a antena receptora sem serem refletidas ou difratadas por obstáculos no caminho, ou seja, não há obstáculos entre o transmissor e o receptor, permitindo uma linha reta de comunicação. Esse tipo de propagação é mais frequente em áreas rurais e suburbanas, onde a presença de obstáculos é menor em comparação aos ambientes urbanos densamente povoados, tanto em quantidade quanto em tamanho (RAPPAPORT, 2009).

#### 3.4.1.2 REFLEXÃO

O fenômeno ocorre quando uma onda eletromagnética encontra um obstáculo, como um prédio ou uma montanha, cujas dimensões são significativamente maiores do que o comprimento de onda do sinal que está sendo propagado. Ao incidir em um material dielétrico perfeito, parte da energia da onda é transferida para o meio adjacente, enquanto outra porção é refletida de volta ao meio original, sem dissipação de energia por absorção. Se o meio adjacente for um condutor perfeito, toda a energia incidente é refletida de volta sem perdas. Em comparação com a teoria óptica, a intensidade do campo elétrico das ondas refletidas e transmitidas pode ser relacionada à onda original incidente no meio por meio do coeficiente de reflexão de Fresnel  $\Gamma$ . Esse coeficiente é influenciado pelas características do material e geralmente varia de acordo com a polarização da onda, ângulo de incidência e frequência da onda em propagação. Esse processo pode gerar multipercursos, onde várias versões da mesma onda chegam ao receptor em momentos ligeiramente diferentes (RAPPAPORT, 2009).

### 3.4.1.3 ESPALHAMENTO

Esse fenômeno ocorre quando as ondas de rádio interagem com obstáculos de dimensões menores em relação ao comprimento de onda do sinal de rádio, e há um grande número desses obstáculos dentro de um determinado volume. Em condições típicas de comunicação móvel por rádio, é comum que o sinal efetivamente recebido seja mais intenso do que o esperado simplesmente considerando-se os fenômenos de reflexão e difração. Isso ocorre porque as ondas se dispersam devido a superfícies rugosas, pequenos objetos e outras irregularidades presentes no canal de comunicação. Normalmente, em ambientes urbanos, estes objetos são compostos de folhagens, postes e fios que têm a tendência de dispersar a energia em múltiplas direções, resultando em um aumento da energia de rádio disponível para o receptor (FREITAS, 2021).

### 3.4.1.4 DIFRAÇÃO

Trata-se de um fenômeno observado nas ondas de rádio quando se propagam em um determinado ambiente e encontram uma borda afiada de um obstáculo, conseguindo contorná-lo e alterar a direção de sua propagação. Isso ocorre porque os pontos da frente de onda acima do obstáculo se comportam como fontes adicionais e continuam irradiando. Através desse mecanismo, é possível que um receptor receba uma parte, às vezes significativa, da energia do sinal transmitido, mesmo diante de uma obstrução considerável (RAPPAPORT, 2009).

A difração, fenômeno explicado pelo Princípio de Huygens, descreve como cada ponto em uma frente de onda pode ser considerado uma fonte que emite pequenas ondas secundárias, as quais, quando combinadas, formam uma nova frente de onda (RAPPAPORT, 2002). Essa combinação dos modos de propagação resulta em diferentes caminhos percorridos pelo sinal transmitido, com comprimentos variados, até chegar ao receptor. Esses caminhos apresentam amplitudes e fases diferentes, o que pode influenciar de forma construtiva ou destrutiva. Esse fenômeno é conhecido como multipercurso.

Além disso, o movimento relativo entre o transmissor e o receptor faz com que os canais de propagação apresentem variações temporais e espaciais, resultando em flutuações do sinal em torno de seu valor médio, conhecido como desvanecimento. Existem dois tipos de desvanecimento identificáveis. As oscilações rápidas do sinal são denominadas de desvanecimento de pequena escala, estando conectadas ao fenômeno de multipercurso. Já as variações mais graduais e lentas são referidas como desvanecimento de larga escala, sendo relacionadas ao efeito de sombreamento causado por obstáculos, como montanhas ou edifícios (CAVALCANTI, 2017).

## 3.5 MODELOS DE PROPAGAÇÃO

Os modelos de propagação desempenham um papel fundamental no planejamento, implantação e otimização de redes LoRa conectadas a dispositivos IoT. Esses modelos permitem prever com precisão a cobertura do sinal e a qualidade da comunicação em diferentes ambientes e condições de operação.

Nesta seção, serão descritos os modelos empíricos da literatura utilizados neste trabalho, com o intuito de comparar com modelos de *machine learning* propostos, MLPNN e GRNN.

### 3.5.1 CLASSIFICAÇÕES

#### 3.5.1.1 CLASSIFICAÇÃO DOS MODELOS

Geralmente, os modelos de propagação incluem modelos determinísticos e modelos empíricos ([RAPPAPORT, 2002](#)).

- Modelos determinísticos: são muito complexos, pois requerem conhecimento detalhado da localização, dimensão e parâmetros físicos de todos os obstáculos na área, asseguram uma maior exatidão na previsão do sinal, embora exijam um tempo de processamento mais prolongado, resultando em custos computacionais mais elevados.
- Modelos empíricos: são fundamentados em dados de medição, o que diminui a complexidade da modelagem e geralmente proporciona uma precisão satisfatória. Esses modelos permitem ajustes com base em medições ou técnicas de computação inteligente, onde os valores dos parâmetros são derivados ao ajustar os dados de medição a uma função apropriada para um ambiente específico. Isso resulta em um modelo mais genérico que pode ser utilizado por sistemas operando em áreas semelhantes.

#### 3.5.1.2 CLASSIFICAÇÃO DOS AMBIENTES

Os ambientes de propagação de rádio foram amplamente categorizados em rural, suburbano e urbano ([RAPPAPORT, 2002](#)). Essa classificação é importante para entender as características de propagação de sinais de rádio em diferentes cenários, considerando fatores como densidade populacional, estruturas físicas presentes e obstáculos à propagação do sinal.

- Rural: são caracterizadas pela escassez de construções, a área é dominada por espaços abertos, como campos, fazendas, áreas não desenvolvidas e pela presença abundante de vegetação, a densidade populacional é geralmente baixa e a propagação do sinal de rádio nesses ambientes pode ser relativamente direta, com poucos obstáculos físicos para interferir no caminho do sinal. No entanto, a cobertura de sinal pode ser limitada em áreas remotas devido à distância entre transmissores e receptores, bem como à presença de relevo acidentado;

- Suburbano: estão localizados nas áreas periféricas das cidades, consistem principalmente por uma mistura de áreas residenciais, comerciais e industriais apresentando uma densidade vegetal e populacional moderada. A propagação do sinal nesses ambientes pode ser afetada por edifícios, árvores e outras estruturas físicas presentes na paisagem urbana e a presença de obstáculos podem resultar em atenuação e reflexão do sinal, afetando a qualidade da comunicação sem fio;
- Urbano: são definidas como regiões que abrigam uma grande quantidade de edifícios, estruturas urbanas e infraestrutura densamente agrupada, dispersos de forma aleatória, porém com uma densidade populacional elevada. A propagação do sinal em ambientes urbanos pode ser desafiadora devido à presença de obstáculos físicos, como arranha-céus, prédios comerciais e veículos. A atenuação do sinal devido ao bloqueio de obstáculos e reflexões múltiplas pode causar áreas de sombra e interferências, levando a problemas de conectividade em redes sem fio.

Essas classificações são essenciais para projetar e otimizar redes de comunicação sem fio, adaptando-as às características específicas de cada ambiente para garantir uma cobertura confiável e eficaz.

### 3.5.2 MODELOS PARA AMBIENTES EXTERNOS USADOS

Nesta pesquisa foram empregados dois modelos para ajustar os coeficientes do ambiente: o modelo *Close-In* e o modelo *Floating Intercept*, podem ser aplicados em ambientes tanto internos quanto externos ([RAPPAPORT, 2002](#)).

#### 3.5.2.1 MODELO FLOATING-INTERCEPT (FI)

O modelo de propagação Floating-Intercept (FI), também conhecido como modelo *Alpha-Beta* (AB), não possui parâmetros baseados em fundamentos físicos, ele utiliza fatores de ajuste de curva, calculados pelo método *minimum mean square error* (MMSE). Ele foi adotado pelo projeto 3GPP (*3rd Generation Partnership Project*) e pela associação *WINNER II*, que fornecem modelos de propagação padrões. Os modelos do 3GPP e *WINNER II* são amplamente utilizados na indústria, pois abrangem diversos tipos de cenários, no entanto, eles são usados somente para frequências inferiores a 6 GHz e precisam ser aprimorados para a faixa de frequências superiores ([SUN et al., 2016](#)).

Por esse motivo, o FI vem sendo amplamente estudado. Ele pode ser usado para caracterizar frequências de comprimento de onda milimétrico, onde os canais podem estar em ambientes com visada direta ou não ([SUN et al., 2016](#); [MACCARTNEY et al., 2015](#)). A equação do modelo FI é dada em (3.5):

$$PL_{FI(dB)} = \alpha + 10\beta \log_{10} \left( \frac{d}{d_0} \right) - X_{\sigma FI} \quad (3.5)$$

Em que,  $\alpha$  é o coeficiente de interceptação flutuante em dB, conhecido como offset,  $\beta$  é a inclinação da reta,  $d$  é a distância entre as antenas em metros,  $d_0$  distância de referência, que é uma distância fixa e conhecida onde a perda de percurso é medida ou calculada, e  $X_{\sigma FI}$  é a variável de desvanecimento lento, que descreve as flutuações de sinal em grande escala sobre a perda de percurso médio, com média zero e desvio padrão  $\sigma$ . Os valores de  $\alpha$ ,  $\beta$  são calculados por MMSE, de modo a minimizar o valor de  $X_{\sigma FI}$ . É necessário um conjunto de dados obtido em medições para computar os valores do *path loss*. Os coeficientes são então obtidos através desses valores, usando as fórmulas estabelecidas (SUN et al., 2016) que minimizam o desvio padrão.

O modelo FI pode ser expandido ainda em outro modelo, conhecido como ABG (*Alpha-Beta-Gamma*), que acrescenta mais um parâmetro de ajuste na frequência. Assim como o FI, ele não possui nenhuma ancoragem física e é um modelo que provê uma curva de melhor ajuste de acordo com o conjunto de dados em diversas frequências simultaneamente.

### 3.5.2.2 MODELO CLOSE-IN (CI)

Este modelo de perda de percurso tem como referencial o espaço livre de perda de percurso (CI) fornecido na equação e parametrizado pelo parâmetro do modelo “n”, também conhecido como o *path loss exponent (PLE)* (MACEDO et al., 2023). Neste modelo, expoente de perda de percurso (*PLE*), é modelado através *minimum mean square error (MMSE)*, visando minimizar o desvio padrão ( $\sigma$ ) entre o *Path Loss* e os dados medidos. Esse modelo vem sendo usado para frequências na ordem dos *Giga-Hertz (GHz)*, ele é baseado nos princípios fundamentais de propagação e está ligado as fórmulas de Friis e Bullington relacionado a perda inicial (*FSPL*) (SUN et al., 2016). Enquanto, o modelo FI usa constantes baseadas no ajuste de curvas, o CI possui uma ancoragem física com a perda no espaço livre, que garante uma relação fixa e contínua entre a potência transmitida sobre a distância. Sua equação é dada em (3.6):

$$PL^{CI}(f, d) = FSPL(f, d_0) + 10n \log_{10} \left( \frac{d}{d_0} \right) + X_{\sigma}^{CI} \quad (3.6)$$

Em que,  $d$  é a distância entre as antenas em metros,  $n$  é o expoente de perda de percurso, que costuma ter valores inferiores a 2 em ambientes indoors com visada direta, e  $X_{\sigma}$  é sombreamento em larga escala e o  $FSPL(f, d_0)$  é definido como:

$$FSPL(f, d) = 10n \log_{10} \left( \frac{4\pi d_0}{\lambda} \right)^2 \quad (3.7)$$

Em que,  $\lambda$  é o comprimento de onda e a distância  $d_0$  é igual a 1 metro, pois é uma referência adotada em diversos modelos capaz de fornecer uma abordagem padronizada de

modelagem. O modelo CI também pode ser expandido em outro modelo, o CIF, que possui um expoente de atenuação baseado na distância. Ele é aplicado para o caso de transmissão em múltiplas frequências e passa a ser revertido no CI ao se utilizar uma frequência única.

Para ajustar os modelos 3.5.2.1 e 3.5.2.2 foi utilizado a técnica dos mínimos quadrados lineares (MMSE) para estimar o expoente de perda de propagação (*PLE - Path Loss Exponent*) para o modelo CI e os coeficientes Alpha e Beta para o modelo FI. O cálculo do ajuste desses valores por meio do método de MMSE (RAPPAPORT et al., 2015), o qual tem como objetivo minimizar as diferenças entre os valores medidos ( $V_m$ ) e os valores preditos ( $V_p$ ) pelo modelo, para obtenção do melhor ajuste possível da Equação (3.8) em relação aos dados medidos.

$$f_{(obj)} = \sum_{i=1}^n (V_m + V_p)^2 \quad (3.8)$$

Para ajustar os parâmetros MQL formamos o seguinte sistema linear:

$$A = \begin{bmatrix} 1 & V_1 \\ \cdot & \cdot \\ \cdot & \cdot \\ \cdot & \cdot \\ 1 & V_m \end{bmatrix} x = \begin{bmatrix} \alpha \\ \beta \end{bmatrix} B = \begin{bmatrix} V_p \\ V_1 \end{bmatrix} \quad (3.9)$$

A partir da Equação 3.9 temos a seguinte solução matricial:

$$x = (A^T A)^{-1} A^T B \quad (3.10)$$

### 3.5.3 MODELOS DE PROPAGAÇÃO EMPÍRICOS PARA VEGETAÇÃO USADOS

O artigo (T.S.RAPPAPORT, 2002; NDZI D., 2012), mostra os modelos de propagação mais usados em ambiente com vegetação para planejamento e instalação de redes de sensores sem fio (*Wireless Sensor Networks-WSNs*). Tais modelos possuem uma alta eficiência na estimativa de perda de percurso, além de sua baixa complexidade matemática, estes modelos são conhecidos como “*Modified Exponential Decay Model (MED)*” pois têm o formato:

$$Att_{MED} = x f^y d^z \quad (3.11)$$

Em que,  $Att_{MED}$  é a atenuação em dB que é adicionada pela vegetação sobre a atenuação do espaço livre (*Free Space Path Loss - FSPL*),  $f$  é a frequência em GHz para o modelo Weissberger e em MHz para os demais modelos,  $d$  é a distância de profundidade na vegetação

em metros e  $x$ ,  $y$  e  $z$  são parâmetros que devem ser ajustados a partir das medições feitas em cada cenário em que seu uso é necessário, conforme (SUN et al., 2016), temos:

### 3.5.3.1 MODELO WEISSBERGER

Este modelo é aplicável em situações em que a propagação do sinal sem fio ocorre em ambientes arborizados, e em que a distância entre a antena de transmissão e a de recepção deve ser até 400 m, na faixa de frequência de 230 MHz a 96 GHz (SILVA; SIQUEIRA; CASTELLANOS, 2018). A sua equação para o cálculo da perda em excesso, que deverá ser adicionada à perda no espaço livre, é dada por:

$$Att_{WEIS} = \begin{cases} 1,33 \times f^{0,284} \times d^{0,588}, & se \quad 14m < d < 400m \\ 0,45 \times f^{0,284} \times d, & se \quad 0m < d < 14m \end{cases} \quad (3.12)$$

Em que,

- $Att_{WEIS}$  é a atenuação em excesso segundo o modelo de Weissberger (dB);
- $d$  é a distância entre a antena transmissora e a antena receptora (m);
- $f$  é a frequência de operação do sistema (MHz).

### 3.5.3.2 MODELO ITU-R

Este modelo ficou conhecido como modelo *Early* ITU, foi proposto pela Organização Internacional de Telecomunicações (ITU) a partir de campanhas de medições em 1988, e é válido para as frequências entre 200 MHz e 95 GHz e para distância entre antena transmissora e receptora inferior a 400 m (CARVALHO; MATOS; CATALDO, 2020). A sua equação para o cálculo da perda em excesso, que deverá ser adicionada à perda no espaço livre, é dada por (3.13):

$$Att_{ITU} = 0,2 \times f^{0,3} \times d^{0,6}, d < 400m \quad (3.13)$$

- $Att_{ITU-R}$  é a atenuação em excesso segundo o modelo da ITU-R (dB);
- $d$  é a distância entre a antena transmissora e a antena receptora (m);
- $f$  é a frequência de operação do sistema (MHz).

### 3.5.3.3 MODELO COST 235

Este modelo faz a diferença entre o ambiente arborizado com a presença de folhas e sem a presença de folhas. Nesse trabalho, considera-se a equação com presença de folhas (SILVA; SIQUEIRA; CASTELLANOS, 2018). As equações para o cálculo da perda em excesso adicionada à perda no espaço livre, são dadas por:

$$Att_{COST} = \begin{cases} 26,6 \times f^{-0,2} \times d^{0,5}, & \text{se sem folhas} \\ 15,6 \times f^{-0,009} \times d^{0,26}, & \text{se com folhas} \end{cases} \quad (3.14)$$

- $Att_{COST}$  é a atenuação em excesso segundo o modelo da COST235 (dB);
- $d$  é a distância entre a antena transmissora e a antena receptora (m);
- $f$  é a frequência de operação do sistema (MHz).

### 3.5.3.4 MODELO FITTED ITU-R (FITU-R)

Este modelo originou como um aprimoramento do modelo ITU-R. Nele apareceu o conceito de diferenciar as equações do modelo de predição, de acordo com a sazonalidade sofrida pela vegetação (SILVA; SIQUEIRA; CASTELLANOS, 2018). Nesse trabalho, considera-se a equação com presença de folhas. As equações para o cálculo da perda em excesso, que deverá ser adicionada à perda no espaço livre, são as seguintes:

$$Att_{FITUR} = \begin{cases} 0,37 \times f^{-0,18} \times d^{0,59}, & \text{se sem folhas} \\ 0,39 \times f^{-0,39} \times d^{0,25}, & \text{se com folhas} \end{cases} \quad (3.15)$$

- $Att_{FITUR}$  é a atenuação em excesso segundo o modelo da FITU-R (dB);
- $d$  é a distância entre a antena transmissora e a antena receptora (m);
- $f$  é a frequência de operação do sistema (MHz).

## 3.6 INTELIGÊNCIA ARTIFICIAL (IA)

A Inteligência Artificial (IA) é um campo da ciência da computação que busca desenvolver sistemas capazes de realizar tarefas que normalmente requerem inteligência humana. Esses sistemas são projetados para aprender, raciocinar, reconhecer padrões, resolver problemas e tomar decisões de forma autônoma. A IA desempenha um papel fundamental na evolução da Internet das Coisas (IoT), fornecendo capacidades avançadas de processamento e análise de dados que ampliam as possibilidades de aplicação e eficiência dos dispositivos conectados (RUSSELL; NORVIG, 2016).

A Figura 7 explica que a tecnologia emergente está ajudando a melhorar a taxa de precisão e também a eficiência operacional.

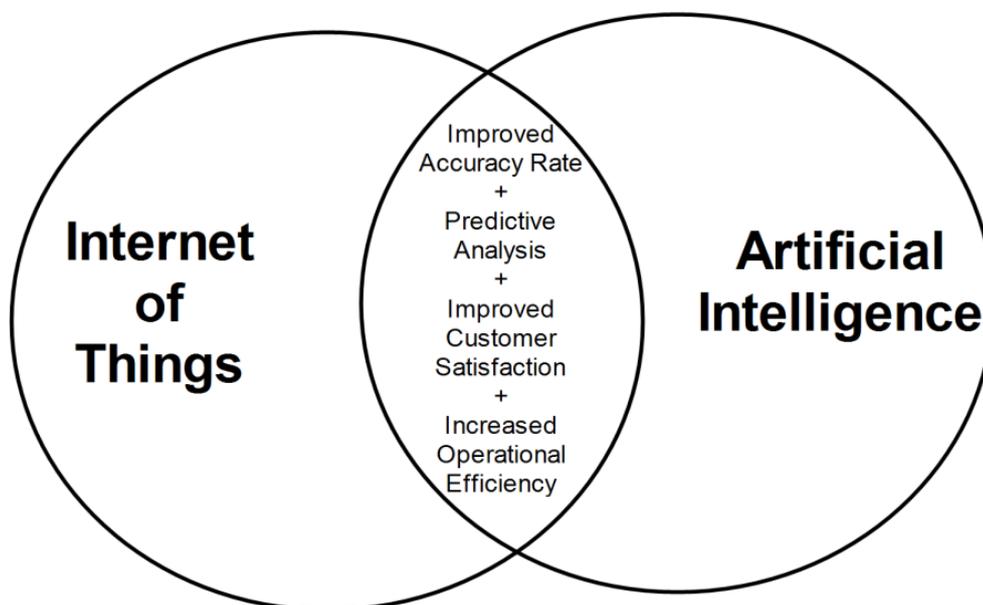


Figura 7 – A funcionalidade comum na IoT e na inteligência artificial.

Fonte: (AMIN et al., 2022)

Dentro do escopo da IA, o aprendizado de máquina (*Machine Learning*) é uma das abordagens mais proeminentes. O aprendizado de máquina permite que os sistemas aprendam padrões a partir de dados e melhorem seu desempenho ao longo do tempo sem a necessidade de programação explícita. Algoritmos de aprendizado de máquina são amplamente utilizados em uma variedade de aplicações de IoT.

Em síntese, a Figura 8 mostra que a inteligência artificial abrange um amplo campo dedicado à criação de sistemas inteligentes, enquanto o aprendizado de máquina (ML) se concentra em aprender com dados e o aprendizado profundo utiliza redes neurais profundas (DL) para compreender e representar informações complexas. Cada uma dessas áreas desempenha um papel crucial no avanço da tecnologia e na solução de desafios do mundo real.

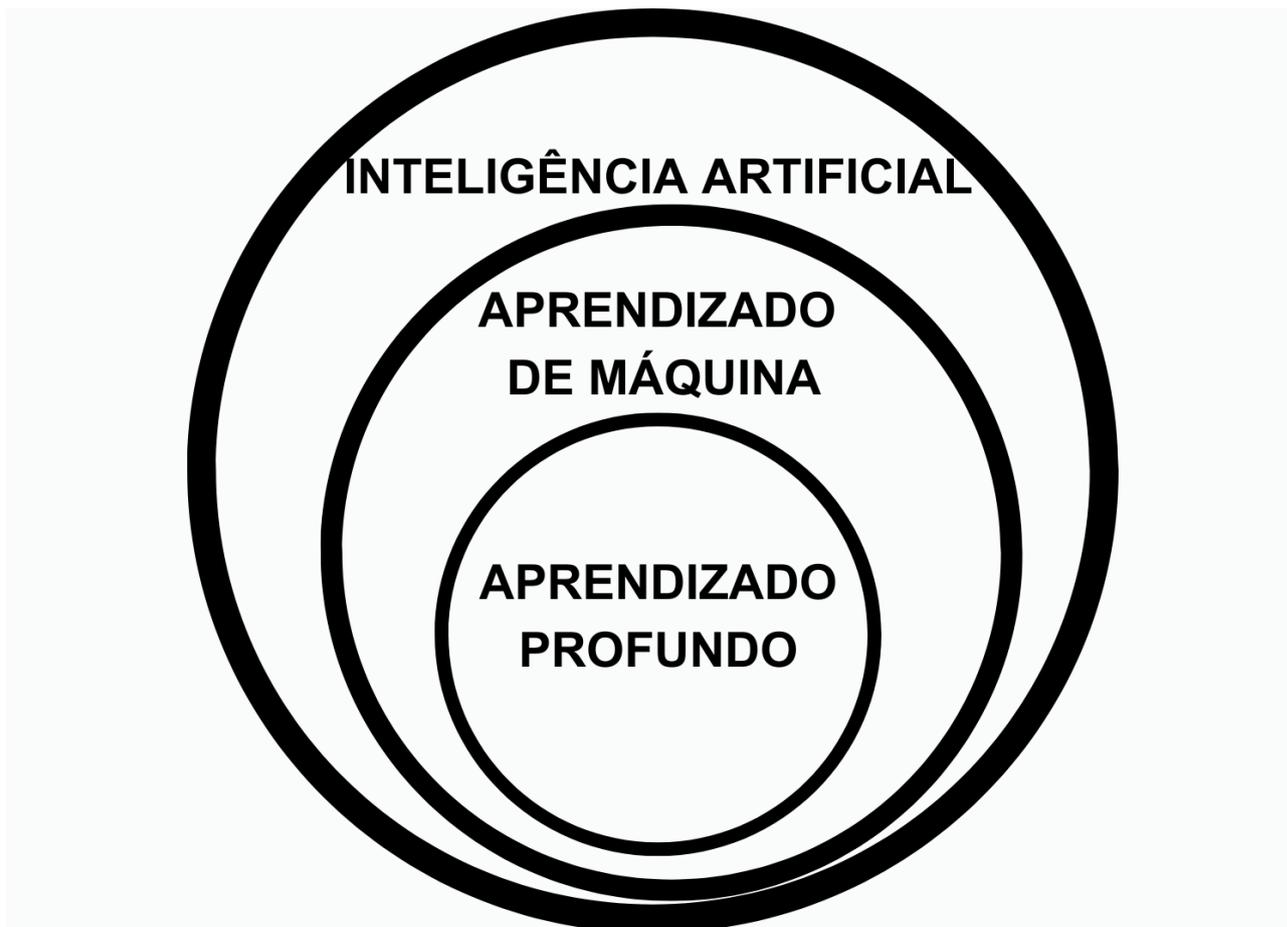


Figura 8 – Relação entre IA, ML e DL.

Fonte: Adaptado ([IORKAA; BARMA; MUAZU, 2021](#))

Para o presente estudo, o foco será nas técnicas a serem empregadas na elaboração da tese.

### 3.6.1 TÉCNICAS DE APRENDIZAGEM DE MÁQUINA (*MACHINE LEARNING - ML*)

Em relação às técnicas utilizadas no desenvolvimento de modelos de propagação, há uma tendência crescente no uso de ML, que é um dos subcampos mais representativos e poderosos da inteligência artificial. ML pode identificar padrões e detectar correlações entre variáveis em um grande conjunto de dados. Alguns exemplos aplicados em pesquisas relacionadas à caracterização do comportamento usando esses tipos de técnicas em ambientes com vegetação consideraram configurações com predominância de pastagens, florestas ou cultivos de tomate em estufa ([BARRIOS-ULLOA et al., 2023](#)).

De acordo com ([MURPHY, 2012](#)), as técnicas de ML podem ser classificadas em supervisionadas, não supervisionadas e aprendizado por reforço, conforme Figura 9.

A primeira categoria é a mais comumente usada e está associada a pares de dados  $(x, y)$ , onde  $x$  é a entrada para o modelo de *ML* e  $y$  é a saída específica mapeada a partir dessa entrada. Essa abordagem é aplicável à localização em redes de sensores sem fio.

Essa categoria pode ser subdividida em algoritmos de regressão e algoritmos de classificação. Os algoritmos de regressão são usados para prever valores contínuos, enquanto os algoritmos de classificação são usados para categorizar dados em classes distintas.

Por outro lado, as técnicas não supervisionadas diferem porque apenas a entrada  $x$  é conhecida. O objetivo dessas técnicas é encontrar padrões subjacentes nos dados de entrada, por exemplo, agrupando-os em classes.

E por fim, o aprendizado por reforço, ao contrário do aprendizado supervisionado e não supervisionado, trabalha com dados de um ambiente dinâmico. O objetivo é encontrar a melhor sequência de ações que resultará na maior recompensa a longo prazo. O agente/algoritmo explora, interage (por meio de ações) e aprende com o ambiente para determinar a melhor política.

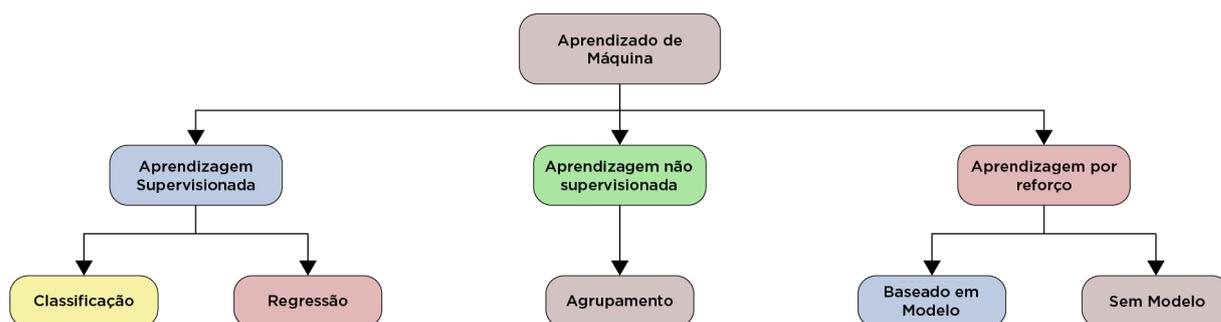


Figura 9 – Tipos de Técnicas Machine Learning.

Fonte: Adaptado (JUSTO-SILVA; FERREIRA; FLINTSCH, 2021)

## 3.6.2 REDES NEURAIS ARTIFICIAIS-RNAs

Nesta subseção, fornecemos uma breve introdução aos princípios fundamentais da teoria das redes neurais artificiais e iniciamos a exploração do tema principal deste estudo - redes neurais de múltiplas camadas (MLP) e redes neurais de regressão geral (GRNN).

As redes neurais de múltiplas camadas são uma das arquiteturas mais prevalentes em redes neurais artificiais. Sua popularidade advém de sua eficácia em uma ampla gama de aplicações de processamento de informação, tais como classificação de padrões, modelagem de funções e previsão de séries temporais, diferenciando das redes neurais de regressão geral, que ainda são pouco utilizadas, apesar de serem mais simples de serem implementadas.

### 3.6.2.1 INTRODUÇÃO

As redes neurais artificiais desempenham um papel significativo na otimização e no aprimoramento de redes LoRa conectadas a dispositivos IoT. Essas redes oferecem técnicas avançadas de aprendizado de máquina que podem melhorar a eficiência, a confiabilidade e o desempenho das comunicações LoRa.

Os modelos neurais artificiais têm como principal fonte de inspiração as redes neurais biológicas, então, uma rede neural pode ser definida como um sistema computacional inspirado na estrutura e no funcionamento do sistema nervoso biológico. Segundo (HAYKIN, 2009), ela é composta por um conjunto de unidades de processamento simples (neurônios artificiais), que estão interconectadas por meio de conexões ponderadas. Essas conexões são responsáveis por transmitir sinais entre os neurônios, permitindo que a rede realize tarefas de aprendizado, reconhecimento de padrões, e tomada de decisões, entre outras.

A Figura 10 representa a estrutura básica de um neurônio artificial, que é a unidade fundamental de processamento em uma Rede Neural Artificial (RNA). A seguir, detalhamos cada componente representado na imagem e seu papel no funcionamento do neurônio:

1. **Entradas** ( $u_1, u_2, \dots, u_n$ ): Estas são os sinais de entrada que o neurônio recebe. Estas entradas podem ser características de dados, como pixels de uma imagem ou valores numéricos de um conjunto de dados.
2. **Pesos** ( $w_1, w_2, \dots, w_n$ ): Cada entrada  $u_i$  é multiplicada por um peso  $w_i$  correspondente. Os pesos são parâmetros ajustáveis da rede que são modificados durante o treinamento para minimizar o erro na saída do modelo. Eles determinam a importância relativa de cada entrada na ativação do neurônio.

3. **Função de Agregação ( $\Sigma$ ):** Esta função calcula a soma das entradas ponderadas, expressa pela fórmula:

$$\sum_{i=1}^n u_i w_i$$

Esta soma pode também incluir um termo de *bias* (não mostrado explicitamente na imagem), que é um valor adicional adicionado à soma para facilitar o ajuste do modelo.

4. **Função de Ativação:** Após a agregação das entradas ponderadas, o resultado é passado por uma função de ativação. Essa função é crucial, pois introduz não-linearidade ao modelo, permitindo que a rede aprenda relações complexas entre os dados de entrada e saída. Funções comuns de ativação incluem ReLU, sigmoid e tanh.

- **ReLU (*Rectified Linear Unit*):** A função ReLU é definida como

$$f(x) = \max(0, x)$$

Ela retorna zero para valores de entrada negativos e retorna o próprio valor de entrada para valores positivos. A ReLU é amplamente utilizada devido à sua simplicidade e eficiência computacional, além de ajudar a mitigar o problema do gradiente desaparecido em redes profundas.

- **Sigmoid:** A função sigmoid é definida como

$$f(x) = \frac{1}{1 + e^{-x}}$$

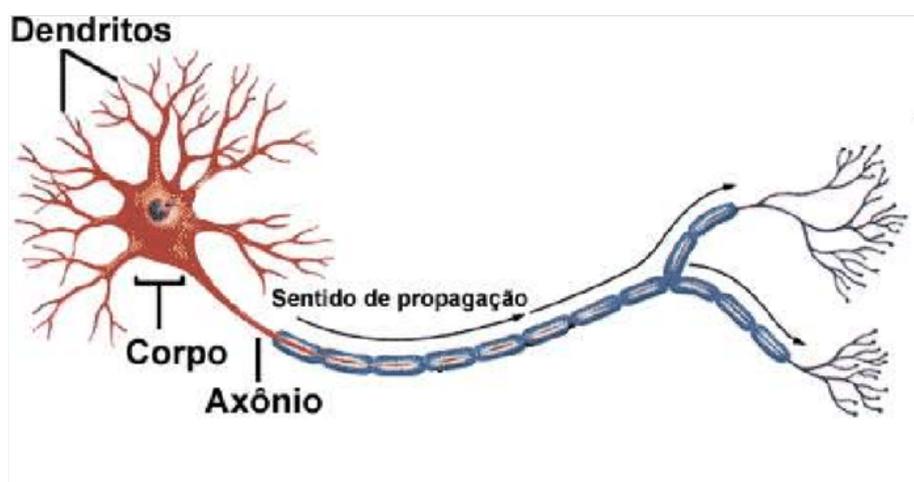
Ela mapeia qualquer valor de entrada para um intervalo entre 0 e 1. A sigmoid é frequentemente usada em problemas de classificação binária, pois sua saída pode ser interpretada como uma probabilidade.

- **Tanh (*Tangente Hiperbólica*):** A função tanh é definida como

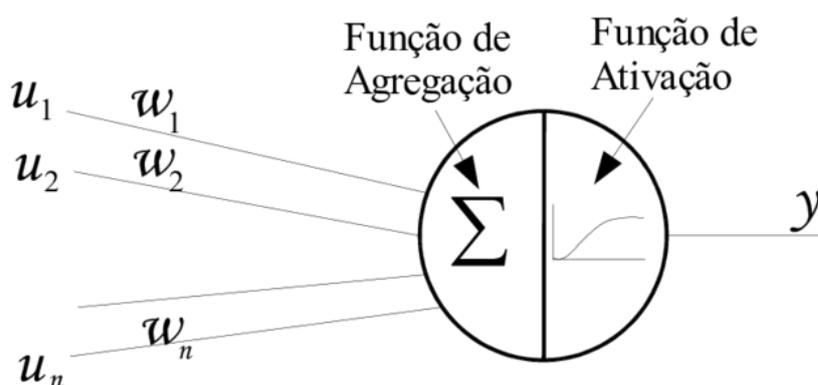
$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Ela mapeia valores de entrada para um intervalo entre -1 e 1. A tanh é semelhante à sigmoid, mas suas saídas são centradas em torno de zero, o que pode ajudar a acelerar a convergência durante o treinamento da rede neural.

5. **Saída ( $y$ ):** Esta é a saída final do neurônio, resultante da função de ativação. A saída  $y$  é utilizada como entrada para os neurônios nas próximas camadas da rede ou como saída final da rede, se o neurônio estiver na última camada.



Neurônio Natural



Neurônio Artificial

Figura 10 – Ilustração de um neurônio natural e um neurônio artificial.

Fonte: (FABRO, 2003)

Nesta pesquisa, foram utilizadas duas técnicas de ML supervisionadas, MLPs e GRNNs.

### 3.6.2.2 PERCEPTRONS DE MÚLTIPLAS CAMADAS (MULTILAYER PERCEPTRONS - MLPs)

O Multilayer Perceptron (MLP) é uma das arquiteturas mais comuns de Redes Neurais Artificiais (RNA) e pertence à classe das redes feedforward. Um MLP é composto por múltiplas camadas de neurônios em uma estrutura de camadas, incluindo uma camada de entrada, várias camadas ocultas e uma camada de saída. Cada neurônio em uma camada está conectado a todos os neurônios na camada subsequente através de pesos sinápticos. Esta estrutura permite que o MLP capture relações complexas e não-lineares entre as entradas e as saídas (HAYKIN, 2007).

A principal característica das MLPs é a presença de uma ou mais camadas ocultas, situadas entre a camada de entrada e a camada de saída, conforme a Figura 11. Cada camada é composta por neurônios interconectados, onde as conexões entre neurônios possuem pesos associados. Esses pesos são ajustados durante o processo de treinamento da rede para otimizar o desempenho e aumentar a precisão (HAYKIN, 2007).

- **Camada de Entrada**

A camada de entrada recebe os sinais externos ao modelo e os transmite diretamente para a primeira camada oculta. Os neurônios desta camada representam diretamente as características de entrada do conjunto de dados. Por exemplo, em um problema de reconhecimento de imagem, cada neurônio poderia representar um pixel específico da imagem.

- **Camadas Ocultas**

O MLP apresentado na figura possui duas camadas ocultas. Os neurônios nessas camadas processam os valores recebidos da camada anterior através de funções de ativação, que são essenciais para aprender padrões complexos. Essas camadas são onde a maior parte do processamento computacional acontece, através das transformações dos dados de entrada.

- **Camada de Saída**

Os neurônios na camada de saída sintetizam as informações processadas pelas camadas ocultas para fazer previsões ou classificações finais. O número de neurônios nesta camada geralmente corresponde ao número de classes no problema de classificação ou à dimensão do vetor de saída em problemas de regressão.

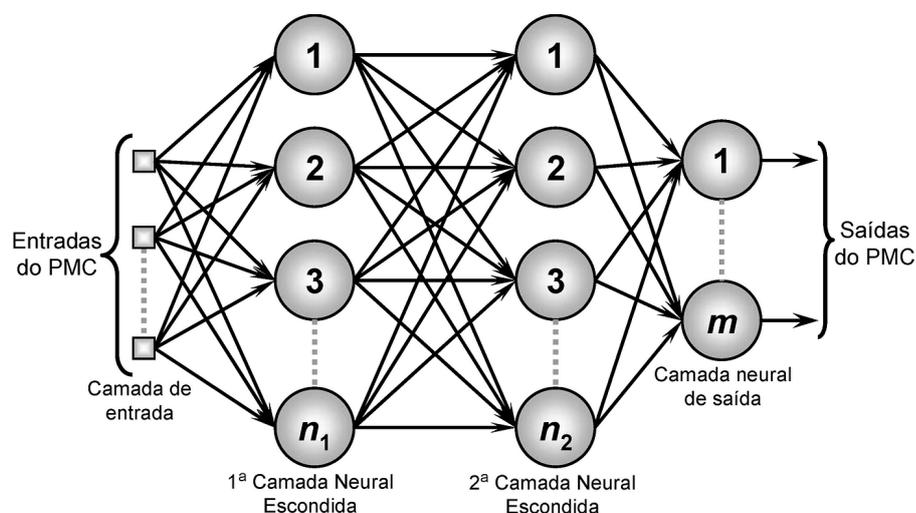


Figura 11 – Modelo de uma rede MLP

Fonte: (SILVA; SPATTI; FLAUZINO, 2010)

As MLPs são capazes de aprender com exemplos fornecidos durante o treinamento. A propagação dos dados ocorre diretamente da camada de entrada para a camada de saída através de uma combinação linear ponderada dos valores de entrada e dos pesos sinápticos. Posteriormente, a saída passa por uma função de ativação não linear, introduzindo não linearidade na rede e permitindo que ela aprenda relações complexas entre os dados.

Durante o processo de treinamento, os pesos sinápticos são ajustados usando algoritmos de aprendizado, como retropropagação, que calculam o erro entre as saídas da rede e os valores esperados, e atualizam iterativamente os pesos para minimizar esse erro. Uma vez que a rede tenha sido treinada, ela pode ser usada para fazer previsões ou classificar novos exemplos de entrada. Através do processo de propagação direta, a rede realiza uma série de operações matemáticas e ativações de neurônios, processando os dados de entrada e gerando uma saída final (HAYKIN, 2007).

As MLPs são amplamente utilizadas em áreas como reconhecimento de padrões, processamento de linguagem natural, visão computacional e muitas outras aplicações que envolvem análise e aprendizado a partir de dados complexos. Sua capacidade de aprender e generalizar a partir de exemplos as torna modelos poderosos para problemas de classificação e regressão.

### 3.6.2.3 REDE NEURAL DE REGRESSÃO GERAL

#### (GENERAL REGRESSION NEURAL NETWORK - GRNN)

A rede neural de regressão geral (GRNN) é um tipo de rede neural artificial desenvolvida para resolver problemas de regressão, ou seja, prever valores contínuos em resposta a um conjunto de variáveis de entrada. A GRNN foi originalmente proposta por Donald F. Specht em 1991 como uma extensão do algoritmo de classificação probabilística chamado rede neural probabilística (PNN) (SPECHT, 1991).

A GRNN é uma rede neural *feedforward* que se destaca por sua simplicidade e facilidade de implementação. É uma variante da rede RBF, que utiliza funções de base radial para realizar interpolação e extrapolação de dados e consiste em quatro camadas principais: a camada de entrada, a camada de padrão, a camada de soma e a camada de saída (SPECHT, 1991).

A Figura 12, mostra uma rede neural GRNN. Na camada de entrada, as variáveis de entrada são normalizadas e fornecidas como entrada para a rede. Em seguida, na camada de padrão, a rede compara os padrões de entrada com os padrões de treinamento armazenados. Esses padrões de treinamento consistem na combinação de valores de entrada e saída correspondentes. Cada padrão de treinamento tem uma função de ativação associada que mede a similaridade entre o padrão de entrada e o padrão de treinamento. Tipicamente, a função de ativação gaussiana é usada, onde a saída é uma medida da distância entre o padrão de entrada e o padrão de treinamento.

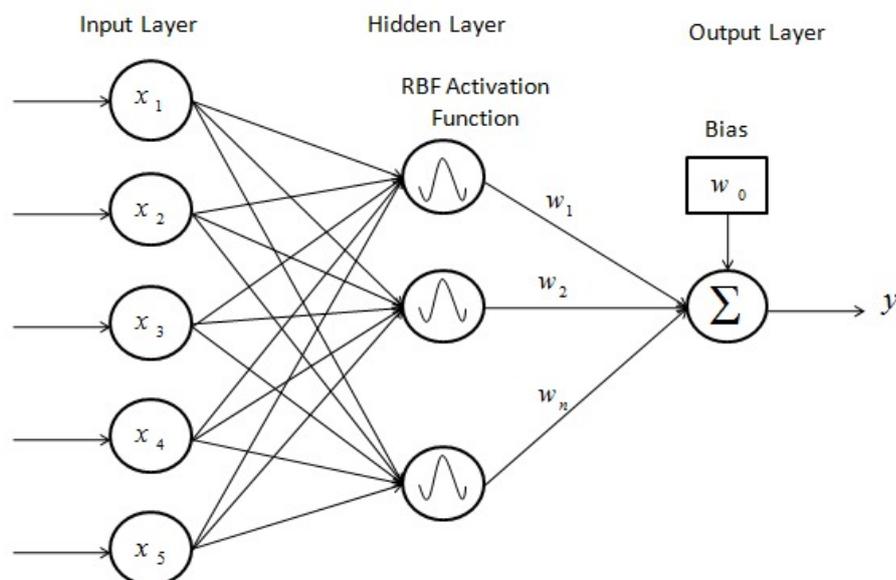


Figura 12 – Arquitetura padrão de uma rede GRNN

Fonte: (SOLANKI; DÍAZ, 2018)

A camada de soma recebe os valores de ativação calculados na camada de padrão e realiza uma soma ponderada desses valores. Os pesos associados aos valores de ativação são determinados pela função de ativação gaussiana, que atribui um peso maior aos padrões de treinamento mais próximos ao padrão de entrada.

Finalmente, a camada de saída combina as saídas da camada de soma para gerar uma resposta final, que é o valor previsto pela GRNN. A saída é calculada pela média ponderada dos valores de saída da camada de padrão, onde os pesos são determinados pela função de ativação gaussiana.

Uma das vantagens da GRNN é sua capacidade de aprendizado rápido e eficiente. Uma vez que a rede é treinada com padrões de entrada e saída correspondentes, ela pode prever rapidamente os valores de saída para novos padrões de entrada sem a necessidade de um processo iterativo de ajuste de pesos (SPECHT, 1991).

Além disso, a GRNN é conhecida por ser uma rede neural robusta capaz de lidar com ruído e dados incompletos, e ainda possui um baixo número de hiperparâmetros.

No entanto, é importante observar que a GRNN pode ser mais adequada para problemas de regressão simples com um número limitado de variáveis de entrada. Para problemas mais complexos ou grandes conjuntos de dados, outras arquiteturas de redes neurais, como redes neurais profundas, podem ser mais apropriadas.

## 3.7 CONSIDERAÇÕES FINAIS

Neste capítulo de referencial teórico, foram apresentados assuntos relevantes para o contexto da pesquisa. Discutiram-se os fundamentos básicos necessários para entender como a *IoT* funciona e como tecnologias específicas, como *LoRa/LoRaWAN*, operam. Compreender os princípios de radiopropagação é essencial para projetar redes *IoT* mais eficientes e confiáveis, considerando os desafios de comunicação sem fio em diferentes ambientes.

Além disso, foi fornecida uma visão geral sobre inteligência artificial (IA) e redes neurais artificiais, com destaque para perceptrons de múltiplas camadas (*Multilayer Perceptron - MLP*) e redes neurais de regressão generalizada (*Generalized Regression Neural Network - GRNN*). Esses conhecimentos podem ser aplicados na predição de valores de RSSI e SNR, contribuindo para o desenvolvimento de modelos de perda de propagação no contexto de *IoT*.

## 4 METODOLOGIA

### 4.1 CONSIDERAÇÕES INICIAIS

Esse Capítulo abordará a metodologia adotada no trabalho para tese, descrevendo as campanhas de medições que foram usadas para realizar a modelagem da perda de propagação, bem como, a posterior análise do tratamento dos dados e as implementações das redes neurais (MLP e GRNN) já efetuadas.

### 4.2 MATERIAIS E MÉTODOS

A metodologia aplicada nesta pesquisa é dividida nas seguintes etapas: coleta de dados (RSSI, SNR e geolocalizações), referente a transmissão do sinal em uma área de vegetação densa, em seguida, o pré-processamento dos dados, para fazer o tratamento dos dados e aplicar as técnicas de Machine Learning propostas, para predição de RSSI e SNR, posteriormente, calcular a perda de propagação, de acordo com o fluxograma na Figura 13.

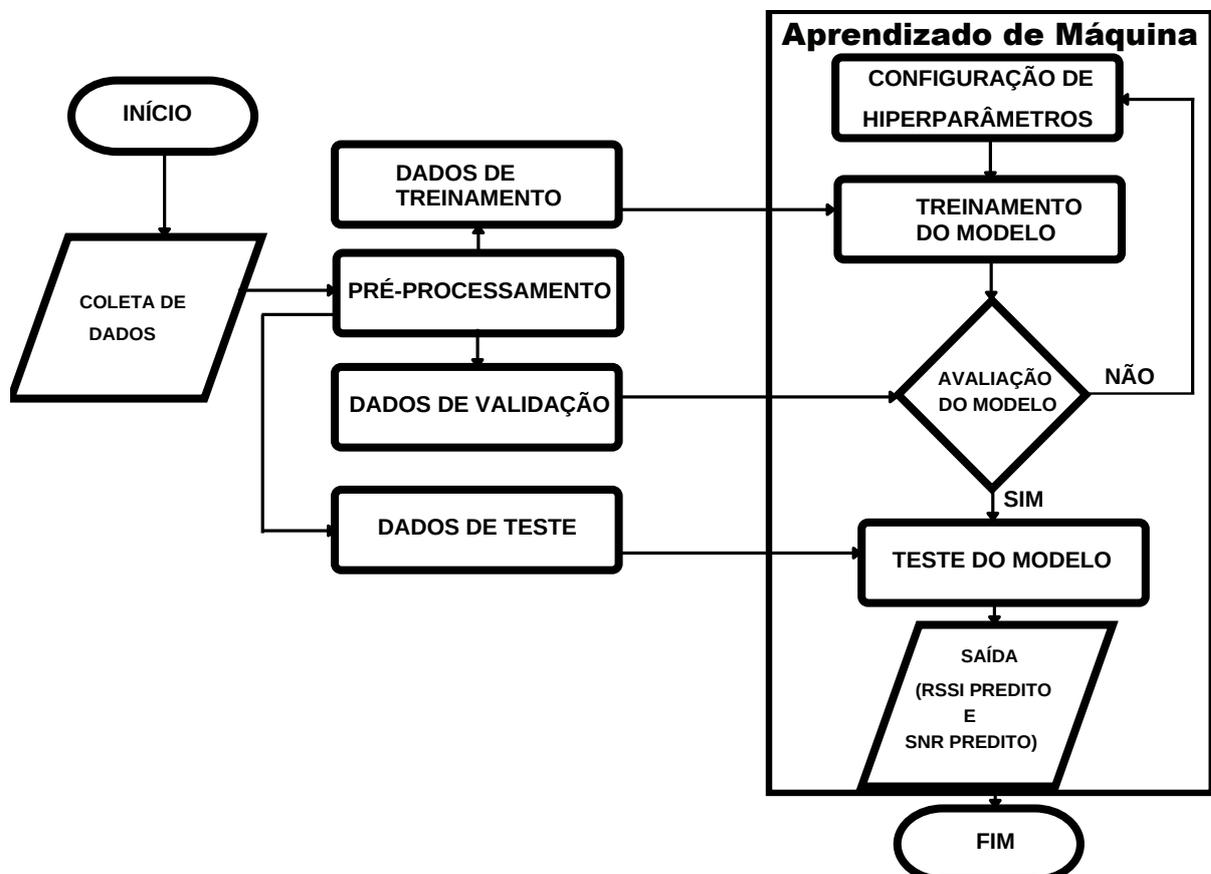


Figura 13 – Fluxograma da Metodologia Aplicada.

Fonte: A autora.

## 4.2.1 DESCRIÇÃO DA CAMPANHA DE MEDIÇÃO

Essa seção abordará a metodologia aplicada para a coleta dos dados, com o objetivo de usar esses dados medidos para modelar o comportamento médio do sinal sem fio em um cenário arborizado, descrevendo os dispositivos e configurações para a transmissão do sinal LoRa, levando em consideração os seguintes fatores: distância entre transmissor e receptor (Tx-Rx), altura do transmissor (Tx), além de detalhar as etapas do pré-processamento dos dados obtidos.

### 4.2.1.1 CENÁRIO

As medições foram realizadas em Belém do Pará, no campus da Universidade Federal do Pará (UFPA). A Cidade Universitária conta com a presença de pequenos bosques, formados por espécies nativas com vegetações arbóreas, arbustivas e forrageiras. Dentre esses bosques, escolhemos o bosque Camillo Vianna que contém  $16.700 m^2$  de extensão, como cenário para esta pesquisa, antes, o espaço era conhecido como Bosque Pau-mulato, pela presença de vários exemplares desta espécie (PAIVA; LUZ; SILVA, 2022), conforme a Figura 14.

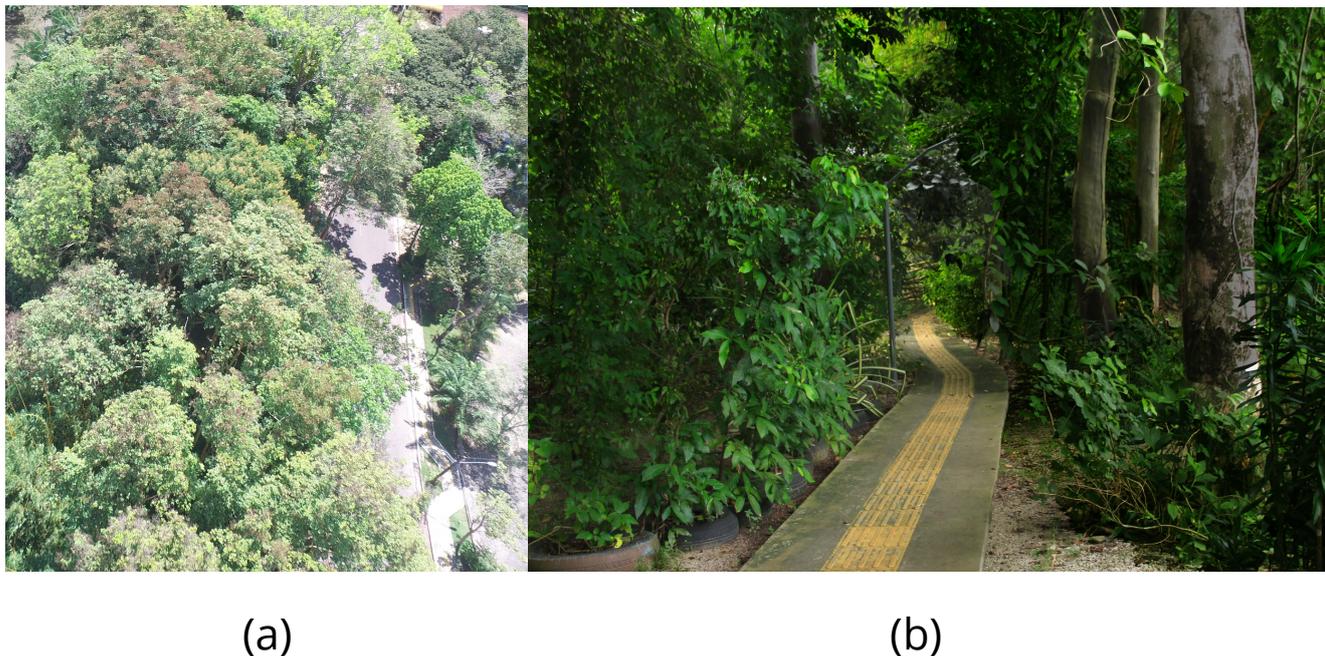


Figura 14 – Cénario de Medições Bosque Camilo Viana (UFPA) : (a) Vista área do Bosque de Floresta Amazônica. (b) Caminho de corredor de árvores interno do bosque percorrido para coleta de dados.

Fonte: A autora.

#### 4.2.1.2 SETUP DE MEDIÇÃO

Para a coleta de dados, foram utilizados três conjuntos de shields LoRa Dragino, que empregam o chip SX1276 da SEMTECH. Esses conjuntos estavam equipados com antenas monopolo e omnidirecionais, acoplados a Arduinos, sendo dois para recepção, de forma a otimizar a coleta dos dados, e um para transmissão. Além disso, foi utilizado um drone modelo Inspire 1, conforme mostrado nas figuras abaixo:

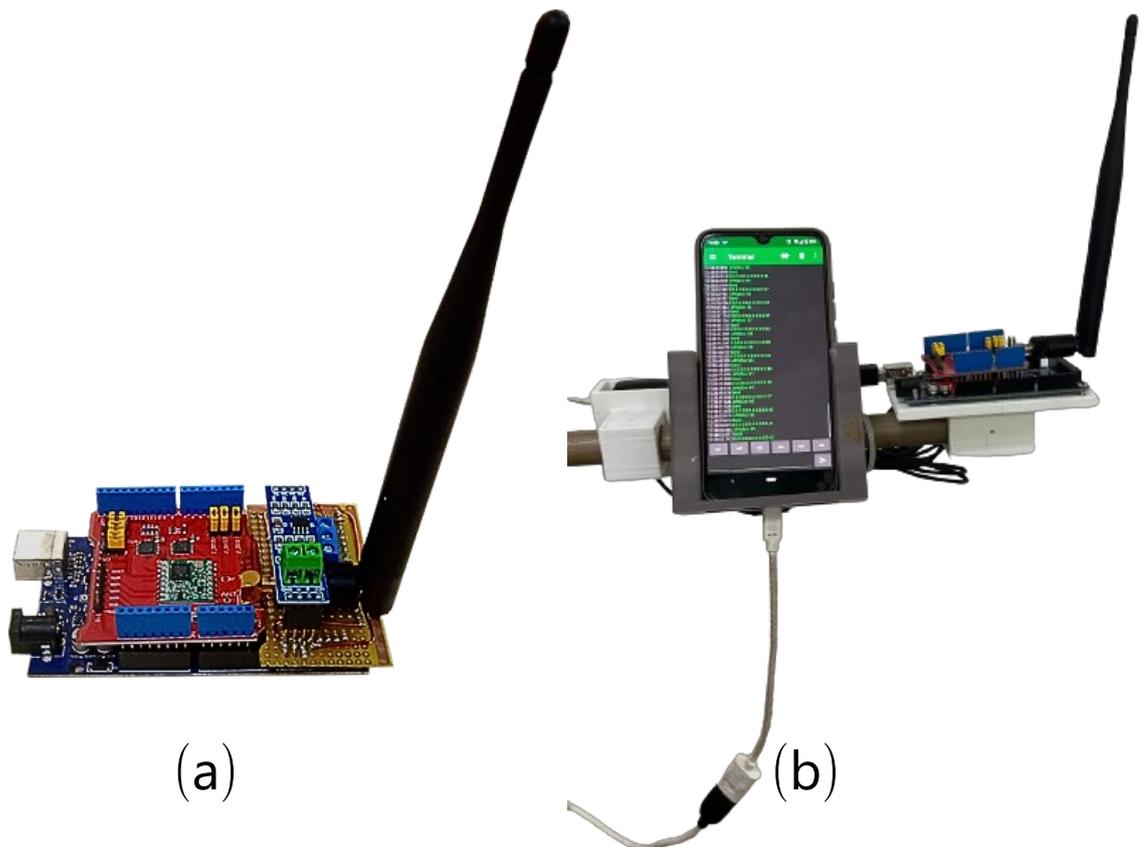


Figura 15 – Equipamentos de Transmissão e Recepção: **(a)** Arduino Uno Module + Dragino 915 MHz LoRa Module + Antena Omnidirecional. **(b)** Módulo Arduino Uno + Módulo de LoRa Dragino 915 Mhz + Antena Omnidirecional + GPS + smartphone.

Fonte: A autora.

Os conjuntos acima, estavam configurados de acordo com a Tabela 3.

Tabela 3 – Configuração dos parâmetros do setup de medição.

Frequência de Operação	Potência Radiada Efetiva	Fator de Espalhamento	Largura de Banda	Taxa de Codificação
915 MHz	5 dBm	12	125 KHz	4/5

Fonte: A autora.

Ao utilizar a tecnologia LoRa (*Long Range*) em um ambiente densamente arborizado, optar pelo Spreading Factor (*SF*) mais alto, como o SF12, apresenta diversas vantagens significativas. A escolha do *SF* adequado desempenha um papel crucial na qualidade da comunicação e na capacidade de superar obstáculos físicos, como árvores, típicos desses ambientes.

O *SF* determina a taxa de transmissão e a sensibilidade do receptor LoRa. Em ambientes densamente arborizados, o SF12 é uma opção ideal por algumas razões importantes. Em primeiro lugar, um *SF* alto oferece um alcance maior de comunicação. As árvores e outras vegetações densas atuam como obstáculos físicos que podem enfraquecer e atenuar o sinal de rádio. No entanto, ao usar um *SF* alto, o sinal LoRa é espalhado em uma largura de banda mais ampla, o que ajuda a contornar esses obstáculos e a estender o alcance da transmissão (LORA™..., 2023).

Além disso, o SF12 é menos suscetível a reflexões, o que é particularmente relevante em ambientes com muitos obstáculos. Árvores e outros objetos presentes podem causar reflexões do sinal, resultando em problemas de interferência e cancelamento de fase. O SF12 é mais robusto em relação a essas reflexões, garantindo uma comunicação mais estável e confiável, isso contribui para melhorar a confiabilidade da comunicação e a integridade dos dados transmitidos (BOR; VIDLER; ROEDIG, 2016).

#### 4.2.1.3 METODOLOGIA DE MEDIÇÃO

As medições basearam-se na transmissão e recepção do sinal, estando o transmissor acoplado em um Drone Inspire 1, localizado fora do bosque, em diferentes alturas (6 m, 12 m e 18 m), e os receptores fixados a uma haste com altura de 2 m, sendo deslocado por uma pessoa caminhando pelo interior do bosque. Ambos com as antenas na polarização vertical e na horizontal, conforme ilustrado na Figura 16.

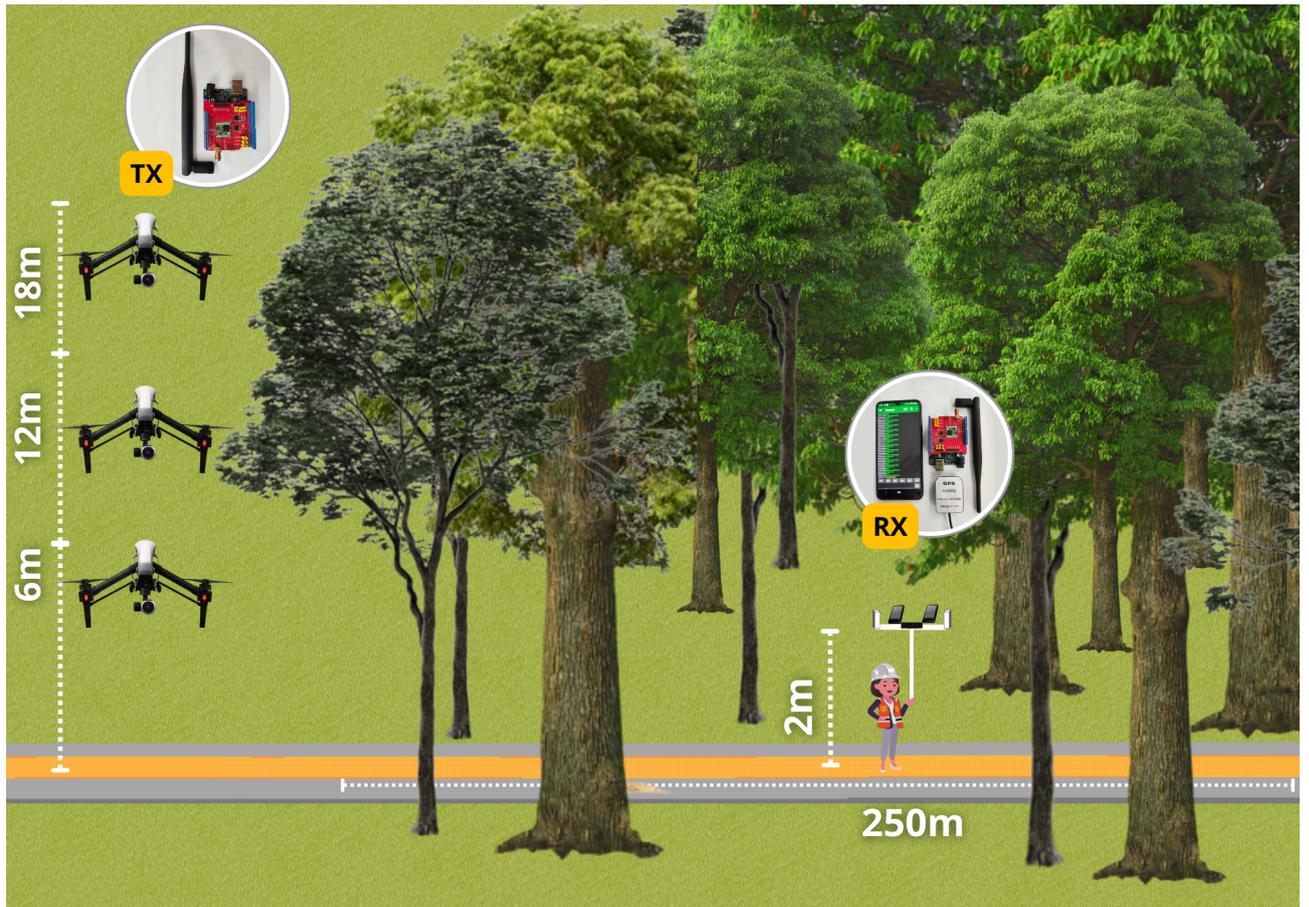


Figura 16 – Cenário de metodologia de medições.

Fonte: A autora.

Tendo em vista, a morfologia do bosque, composta predominantemente por espécies de árvores do tipo Pau Mulato, uma árvore típica da Amazônia (STEHMANN; FARIA; BRAGIONI, 2019), que tem no ambiente com altura média de 24 m, foram definidas as alturas do transmissor em 6 m (tronco das árvores), 12 m (início da copa das árvores) e 18 m (meio da copa das árvores). Com isso, pretende-se analisar a influência das alturas do transmissor e das polarizações das antenas no bosque.

Foram realizadas as seguintes combinações de configurações dos parâmetros de transmissão e recepção expostos conforme Tabela 4.

Tabela 4 – Configuração correspondentes a metodologia das medições.

SF	Alturas	Polarização das Antenas
12	6 m	V-V
	12 m	H-H
	18 m	

Fonte: A autora.

Dado que se tem um *SF*, três alturas, duas polarizações em um cenário sem visada (*NLOS*), foram realizadas 6 combinações, e para cada combinação, foi percorrida 6 vezes a rota de 250 m no interior do bosque, percorrendo a mesma rota 36 vezes, sendo coletadas 4.525 amostras no total, aproximadamente, 358 amostras por rota, o que equivale, em torno de uma amostra a cada 2 m, caminhando em uma velocidade média de aproximadamente 1,67 m/s. Cada amostra era composta por valores de latitude e longitude, *RSSI* e *SNR*.

## 4.2.2 TRATAMENTO DOS DADOS

O tratamento de dados consiste em um conjunto de técnicas e etapas aplicadas para melhorar, organizar, limpar, transformar os dados brutos para serem analisados. Além de, identificar e corrigir erros, ruídos e valores ausentes nos dados. E mais, o tratamento de dados também lida com a integração e combinação de dados provenientes de diferentes fontes, permitindo criar um conjunto de dados unificado e coerente.

Isso nos possibilita a visualização de distribuições, identificação de padrões e tendências, bem como a realização de análises estatísticas descritivas. Através dessa análise, é possível obter *insights* e compreensão dos dados, auxiliando na tomada de decisões.

Portanto, o tratamento de dados é uma etapa necessária para a modelagem e análise, especialmente na construção de modelos preditivos e analíticos. Ele envolve a seleção de atributos relevantes, divisão dos dados em conjuntos de treinamento e teste, aplicação de algoritmos de aprendizado de máquina ou técnicas analíticas, validação de modelos e avaliação de desempenho.

Nesta pesquisa, para fazer o tratamento de dados, foi utilizada a regra conhecida como regra *3-sigma* ( $3\sigma$ ), é usada para identificar e remover *outliers*, utiliza 3 vezes o valor do desvio padrão da média ( $\mu$ ) em uma janela de 25 amostras, deslizando essa janela ao longo da série de medições para definir os limites superior e inferior,  $\mu+3\sigma$  e  $\mu-3\sigma$ , respectivamente. Com isso, é possível detectar valores que estão muito acima ou abaixo da média desses subconjuntos de amostras (LÓPEZ, 2023).

### 4.2.2.1 CÁLCULO DA DISTÂNCIA

O cálculo da distância através da latitude e longitude por meio da equação de Haversine é uma ferramenta fundamental na área de geolocalização e navegação. A equação de Haversine é uma fórmula matemática que permite estimar a distância entre dois pontos na superfície da Terra, considerando sua localização em termos de coordenadas de latitude e longitude. Esta equação considera a curvatura da Terra e leva em conta o raio médio do planeta para calcular a distância em uma esfera.

A equação é representada da seguinte forma em 4.1 (CHOPDE; NICHAT, 2013):

$$D_r = \sqrt{\left(2r \cdot \arcsin\left(\sqrt{\sin^2\left(\frac{\varphi_2 - \varphi_1}{2}\right) + \cos\varphi_1 \cos\varphi_2 \sin^2\left(\frac{\lambda_2 - \lambda_1}{2}\right)}\right)\right)^2 + h^2} \quad (4.1)$$

Em que,  $D_r$  representa a distância entre Tx-Rx,  $r$  é o raio médio da Terra (por exemplo, aproximadamente 6371 km);  $\varphi_1$  e  $\lambda_1$  são as coordenadas de latitude e longitude do primeiro ponto, respectivamente;  $\varphi_2$  e  $\lambda_2$  são as coordenadas de latitude e longitude do segundo ponto, respectivamente;  $\arcsin$  é a função arco seno;  $\sin$  e  $\cos$  são as funções trigonométricas seno e cosseno, respectivamente, e  $h$  é a diferença entre as alturas do Tx e Rx em relação ao solo.

#### 4.2.2.2 CÁLCULO DA PERDA DE PROPAGAÇÃO

A potência de sinal esperada (ESP) segundo (GONZÁLEZ-PALACIO et al., 2022), é definida como a potência do sinal no receptor (Equação (4.2)):

$$ESP_{(dB)} = RSSI_{(dBm)} + SNR_{(dB)} - 10 \cdot \log_{10} \left(1 + 10^{\frac{SNR_{(dB)}}{10}}\right) \quad (4.2)$$

Assim, podemos calcular a perda de propagação através da Equação (4.3) de balanceamento de link, como sendo:

$$PL_{(dB)} = P_{Tx(dBm)} + G_{(dBi)} - ESP_{(dB)} \quad (4.3)$$

$ESP$  é a potência esperada do sinal em determinado ponto em dB;  $P_{Tx}$  é a potência transmitida pelo gateway em dBm;  $G$  é a soma dos ganhos das antenas de transmissão e recepção, geralmente em dBi e, por fim,  $PL$  representa a perda de propagação do sinal em dB.

#### 4.2.3 Métodos de Predição de RSSI e SNR

Nesta tese, são apresentados dois métodos de predição por meio do uso de RNAs do tipo Perceptron de Múltiplas Camadas e de Regressão Geral, ambas para predição de RSSI e SNR, ambos baseados em medições utilizando LoRa, trabalhando na faixa de frequência de 915 MHz em ambientes de bosque Amazônico.

A partir dos dados obtidos na campanha de medições e após a fase de tratamento, foi possível aplicá-los no desenvolvimento das RNAs.

#### 4.2.3.1 CONJUNTO DE DADOS

O conjunto de dados usado para implementar ambas as técnicas, MLP e GRNN, consiste em 4525 amostras distribuídas em três conjuntos de dados gerados aleatoriamente: o conjunto de treinamento contendo 3167 pontos, que corresponde a 70% do total de dados; e o conjunto de validação e o conjunto de teste, cada um contendo 679 pontos, totalizando 30% do total de amostras, como mostrado na Tabela 5.

Tabela 5 – Divisão do conjunto de dados.

<b>Conjunto de Amostras</b>	<b>Número de Amostras</b>	<b>% em Relação ao Total</b>
Treinamento	3167	70%
Validação	679	15%
Teste	679	15%

Fonte: A autora.

#### 4.2.3.2 PERCEPTRONS DE MÚLTIPLAS CAMADAS (MULTILAYER PERCEPTRONS - MLPs)

O processo de treinamento da MLP envolve apresentar um padrão às unidades da camada de entrada, onde as unidades calculam sua resposta e a apresentam à camada de saída para obter a resposta da rede. Em seguida, o erro é calculado e propagado da camada de saída de volta para a camada de entrada, e os pesos das conexões nas unidades da camada oculta são ajustados, diminuindo gradualmente o erro para alcançar a melhor taxa de generalização do MLP. No treinamento supervisionado do MLP, foi utilizado o algoritmo de Levenberg–Marquardt.

Muitos testes foram realizados considerando diferentes topologias de RNA para determinar a melhor rede. O teste considerou números de neurônios de 1 a 30 na camada oculta, e para cada neurônio na camada oculta o teste foi repetido para 100 sementes aleatórias diferentes. Finalmente, a topologia com uma camada oculta com 24 neurônios produziu a melhor precisão, conforme visto na Figura 17.

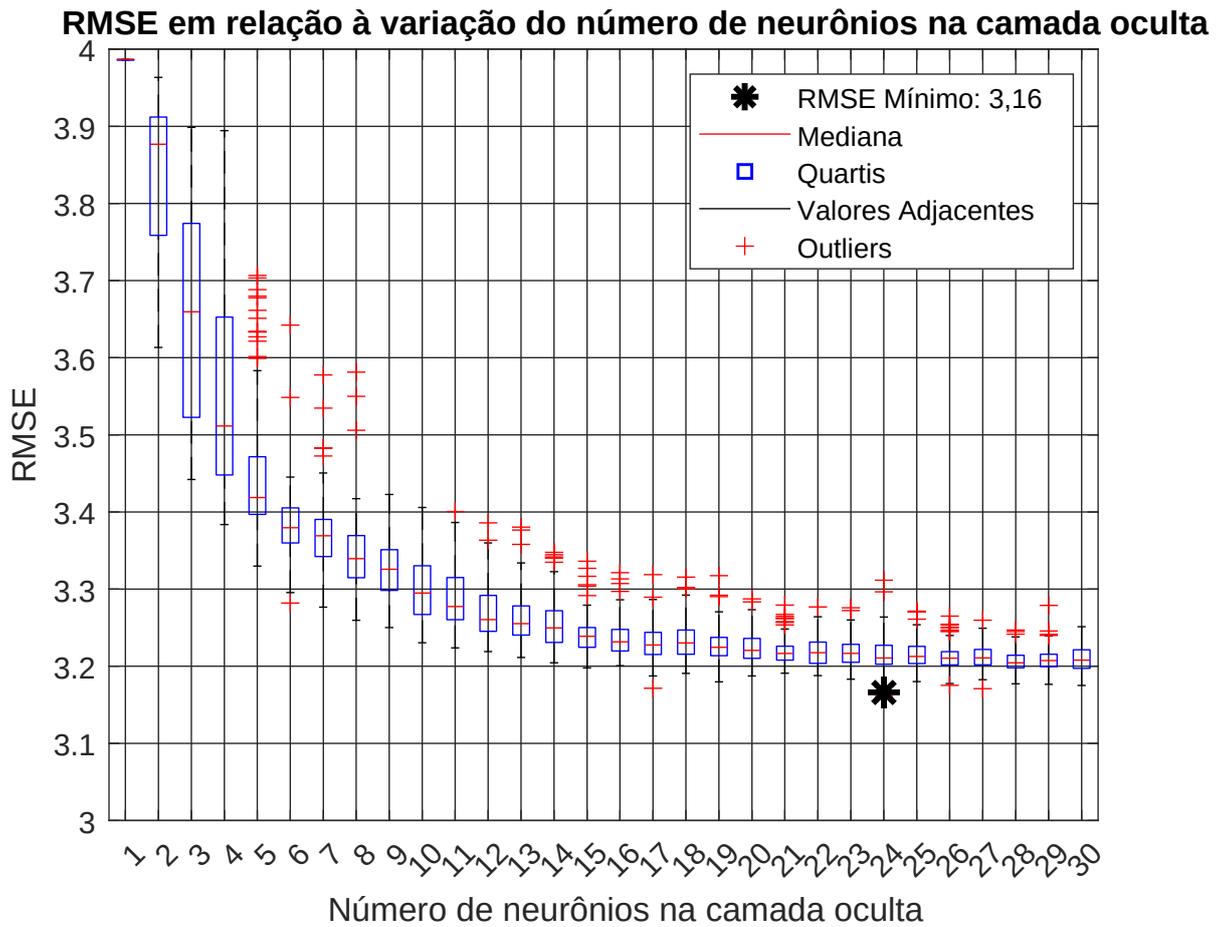


Figura 17 – RMSE em relação ao número de neurônios na camada oculta.

A Figura 18 representa a rede neural MLP modelada para esta pesquisa, na qual a camada de entrada possui três neurônios, que representam a distância entre o transmissor (Tx) e o receptor (Rx) em metros (m), as alturas do Tx, 6, 12 e 18, em metros (m) e as co-polarizações das antenas transmissoras e receptoras (VV e HH), com função sigmóide na camada oculta e função de ativação linear para a camada de saída.

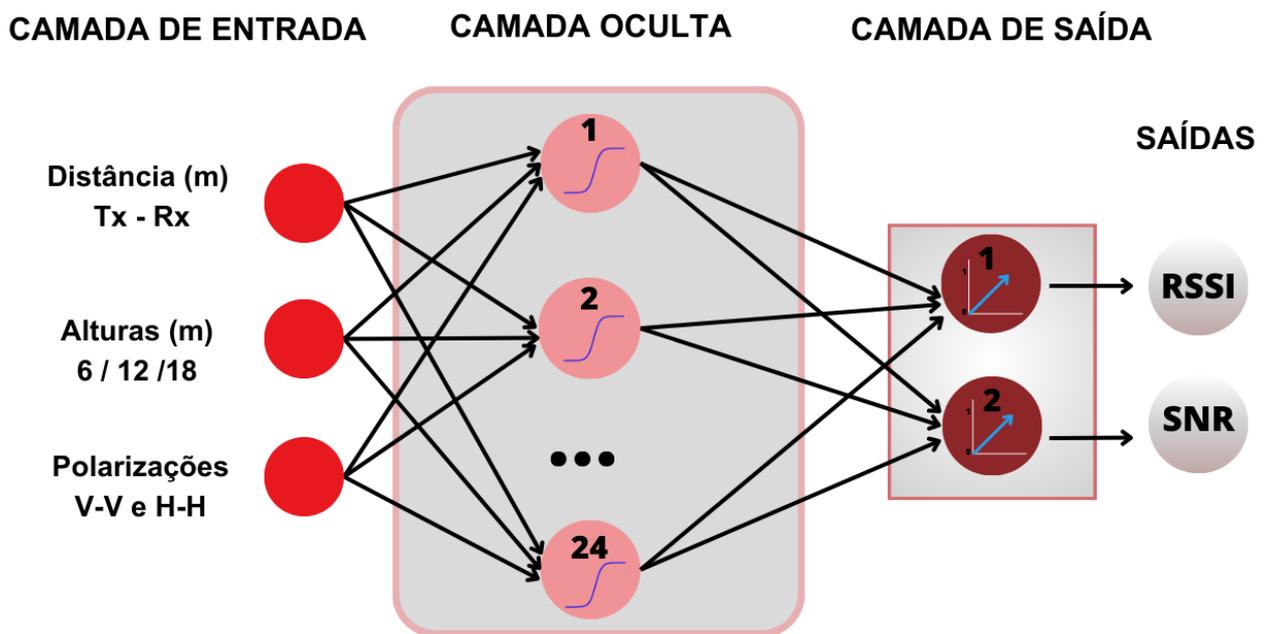


Figura 18 – Rede MLPNN implementada.

Fonte: A autora.

#### 4.2.3.3 REDE NEURAL DE REGRESSÃO GERAL (GENERAL REGRESSION NEURAL NETWORK - GRNN)

A GRNN difere significativamente das arquiteturas tradicionais de redes neurais, como a rede MLP, em sua conceituação e utilização de "pesos" e "bias". Como visto anteriormente, os "pesos" na MLP são ajustados durante o processo de treinamento para minimizar o erro de previsão, e os termos de "bias" são usados para fornecer flexibilidade adicional, permitindo que o modelo se ajuste melhor aos dados. Esse processo envolve uma otimização iterativa para ajustar esses parâmetros.

No entanto, na GRNN o que poderia ser analogamente referido como "pesos" são na verdade os próprios pontos de dados, armazenados na camada de padrões da rede. Cada neurônio nesta camada representa uma memória direta dos dados de treinamento, e a saída da rede é calculada com base na proximidade dos dados de entrada a esses pontos armazenados, modulados por uma função de base radial.

Neste caso, o parâmetro de espalhamento ( $\sigma$ ), que controla a largura dessa função, para este modelo foi definido como 0,0039. É o principal parâmetro ajustável nesta rede, facilitando sua implementação e ajuste.

Em resumo, é a estrutura da GRNN e sua dependência de todo o conjunto de dados de treinamento que define sua função e eficácia.

A Figura 19 representa a arquitetura da GRNN usada nesta pesquisa, considerando as mesmas entradas que o MLP e também prevendo RSSI e SNR como saída.

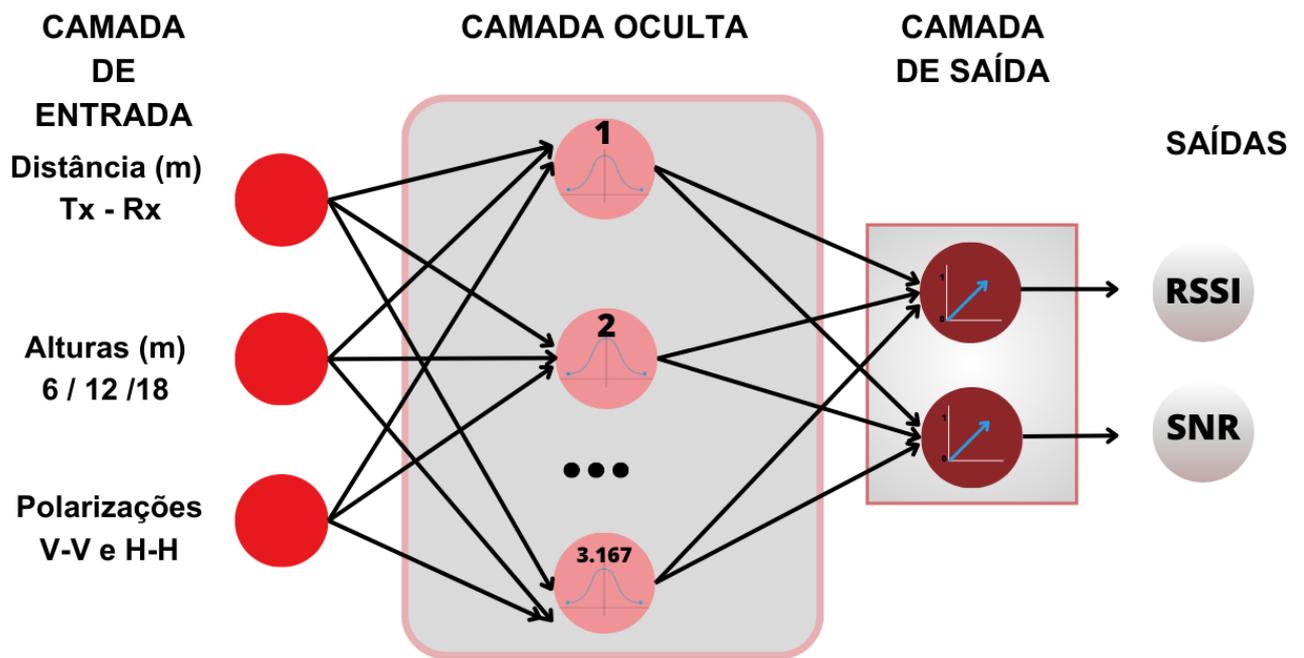


Figura 19 – Rede GRNN implementada.

Fonte: A autora.

# 5 RESULTADOS

Nesta seção, serão apresentados os resultados obtidos na floresta típica da Amazônia, onde a vegetação tem uma altura média de 24 m, e as alturas dos transmissores são definidas em 6 m (tronco da árvore), 12 m (início da copa da árvore) e 18 m (meio da copa). A influência dessas alturas e polarizações das antenas na propagação do sinal será analisada. Em seguida, serão feitas comparações entre os modelos propostos baseados em RNA com outros modelos de perda de propagação, como os modelos CI, FI, Weissberger, *Early* ITU-R, Cost235 e FITU-R, com o objetivo de demonstrar a eficiência do uso de técnicas de ML como MLP e GRNN na estimativa de perda de propagação em ambientes arborizados.

## 5.1 ANÁLISE DA INFLUÊNCIA DE ALTURAS E POLARIZAÇÕES EM AMBIENTES COM VEGETAÇÃO DENSA

A comunicação sem fio em ambientes densamente arborizados tem ganhado importância crescente devido a aplicações como monitoramento ambiental, prevenção de incêndios e sistemas de busca e resgate. No entanto, a vegetação densa, especialmente as copas das árvores, pode causar atenuação e interferência de sinal, tornando essencial selecionar adequadamente a polarização e altura do transmissor para melhorar a confiabilidade e qualidade das transmissões (KUMAR et al., 2023).

As transmissões de sinal sem fio em tais ambientes apresentam desafios únicos, onde a escolha adequada da polarização da onda eletromagnética pode afetar significativamente o desempenho da transmissão neste cenário (BARRIOS-ULLOA et al., 2022a). Esta seção explora a eficácia das polarizações HH (horizontal transmitida e horizontal recebida) e VV (vertical transmitida e vertical recebida) em diferentes alturas em relação às transmissões nos níveis do tronco e da copa das árvores.

A escolha da polarização de micro-ondas (como HH e VV) em diferentes alturas de transmissões abaixo das copas das árvores está relacionada à interação das ondas eletromagnéticas com a vegetação. Essa interação pode variar dependendo da estrutura e densidade da vegetação, bem como das características das ondas utilizadas. Essas variáveis influenciam diretamente a qualidade do sinal recebido, que pode ser avaliada por meio de parâmetros como RSSI e SNR.

A relação entre RSSI e SNR na tecnologia LoRa é que o RSSI fornece informações sobre a intensidade do sinal, enquanto o SNR complementa essas informações indicando a qualidade do sinal em relação ao ruído de fundo. Para obter uma visão mais abrangente e precisa da qualidade

do link de comunicação LoRa, é importante considerar ambos os parâmetros. Em algumas implementações LoRa, o SNR pode ser mais significativo na determinação da capacidade de recepção de dados do que o RSSI, especialmente em ambientes com alto ruído ou interferência. Portanto, a escolha adequada da polarização e da altura de transmissão pode melhorar tanto o RSSI quanto o SNR, resultando em uma comunicação mais estável e confiável em ambientes densamente arborizados.

A Figura 20 ilustra os pontos de medição que estão no meio de uma floresta densa. O transmissor, que está representado na cor rosa, no início do caminho e possui uma longitude e latitude estáticas; em contraste, o receptor varia em longitude e latitude, pois está se movendo pelo caminho. As Figuras 20a e 20b mostram os valores medidos de RSSI e SNR, respectivamente. Uma análise detalhada de RSSI e SNR de acordo com a altura do transmissor está abaixo.

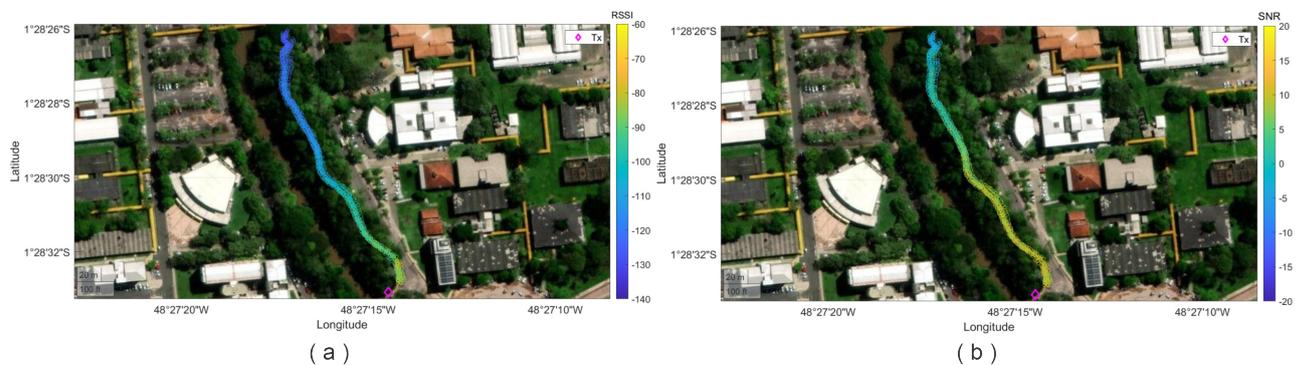


Figura 20 – **(a)** Dados de GPS coletados correspondentes aos níveis de RSSI versus distância no ambiente estudado. **(b)** Os dados de GPS coletados correspondentes aos níveis de SNR versus distância no ambiente estudado.

As figuras apresentadas a seguir foram geradas a partir de dados medidos no bosque. Esses dados foram coletados para capturar informações relevantes sobre a transmissão de sinais em ambientes reais com vegetação.

De acordo com a Figura 21, o valor mais baixo para o RSSI com polarização vertical é  $-133$  dBm e o mais alto é  $-75$  dBm; por outro lado, para a polarização horizontal, o valor mais baixo é  $-135$  dBm e o mais alto é  $-75$  dBm. Além disso, pode-se observar que os valores de RSSI são semelhantes para ambas as polarizações; no entanto, os valores de RSSI para VV mostram valores mais altos, especialmente para distâncias maiores que 150 m.

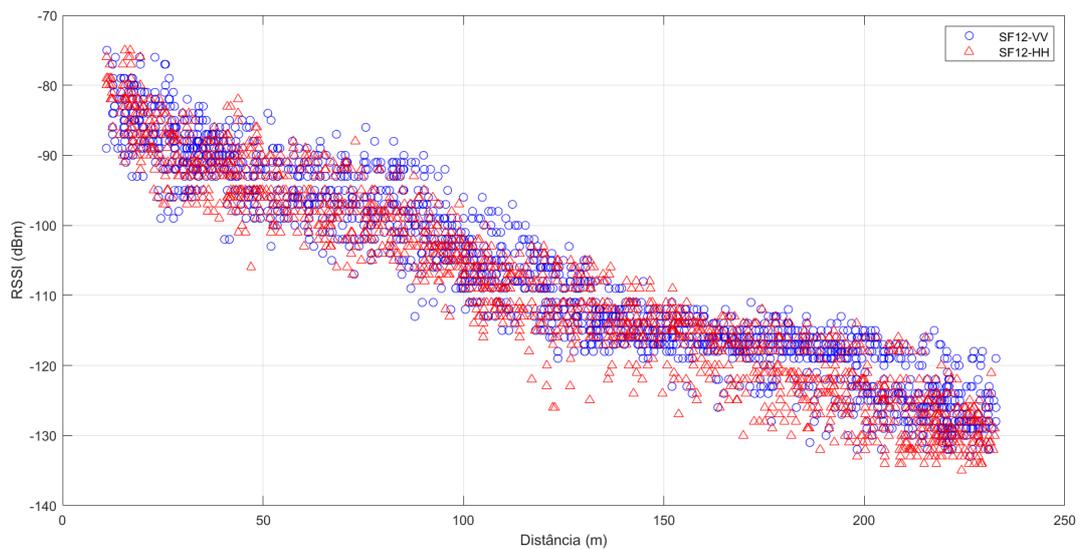


Figura 21 – Distribuição dos dados de RSSI medidos em relação à distância para SF12 em todas as alturas para as polarizações HH e VV.

Além disso, para VV, os valores de RSSI apresentam uma tendência decrescente em torno de 20 dB a cada 100 m. Para HH, a diminuição nos valores de RSSI é de cerca de 25 dB a cada 100 m. Isso indica que a floresta causa uma atenuação considerável, mesmo em distâncias curtas.

A Figura 22 mostra que o SNR mínimo para HH é  $-13$  e para VV é  $-9$ ; o valor máximo para HH é 13 e para VV é 14. Além disso, o SNR para ambas as polarizações começa a diminuir para distâncias maiores que 100 m para SF12 em todas as alturas. No entanto, a polarização VV apresenta uma qualidade de sinal mais forte e melhor em um ambiente densamente arborizado, o que significa que o RSSI do sinal é mais forte em relação ao ruído, resultando em melhor desempenho de comunicação. Além disso, ao observar as variações nos valores de RSSI e SNR com a distância, observa-se que o ambiente florestal afeta tanto o RSSI quanto o SNR, mesmo em curtas distâncias.

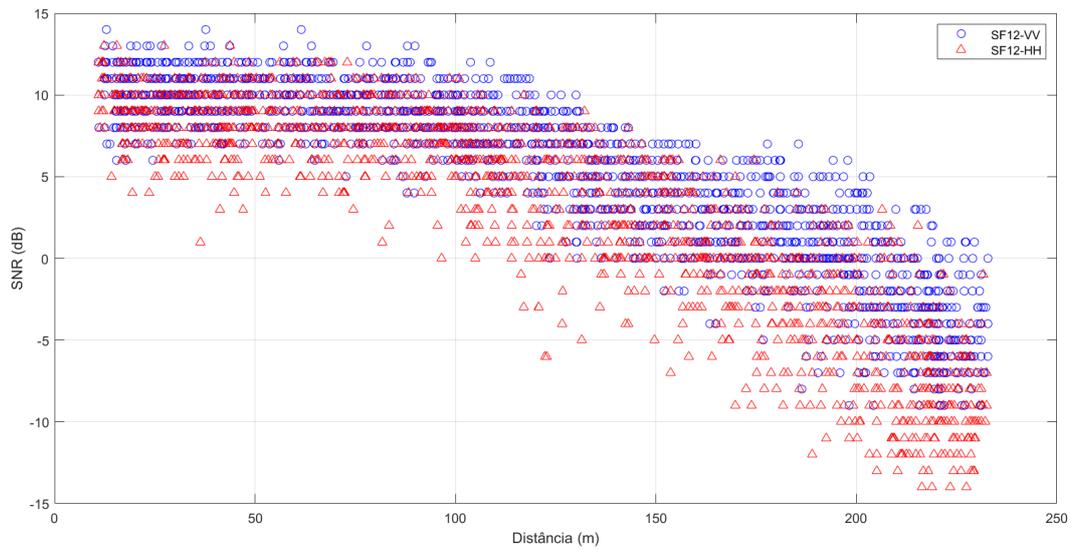


Figura 22 – Distribuição dos dados de SNR medidos em relação à distância para SF12 em todas as alturas para as polarizações HH e VV.

Em resumo, de acordo com as Figuras 21 e 22, pode-se observar que a polarização VV apresenta melhor desempenho na transmissão em comparação com a polarização HH para todas as alturas. Além disso, em todas essas situações, observou-se que o RSSI exibiu um comportamento linear e o SNR apresentou um comportamento exponencial para uma distância inferior a 250 m.

## 5.2 ANÁLISE DOS VALORES DE RSSI E SNR EM RELAÇÃO ÀS ALTURAS DO TRANSMISSOR (Tx)

Os resultados de RSSI e SNR para SF12 em ambientes densamente arborizados para redes IoT na faixa de frequência de 915 MHz são apresentados e analisados para cada altura de Tx.

Um novo gráfico (Figura 23) que condensa as informações de valores de RSSI, média e desvio padrão para intervalos de distância fixos é apresentado para facilitar a comparação entre diferentes alturas e polarizações. A média e o desvio padrão são calculados considerando todos os valores de RSSI contidos dentro do intervalo de distância coberto por uma janela deslizante.

Os valores de RSSI e SNR ao longo do caminho percorrido são exibidos para a combinação de alturas SF12 de 6, 12 e 18 m nas Figuras 23 e 24.

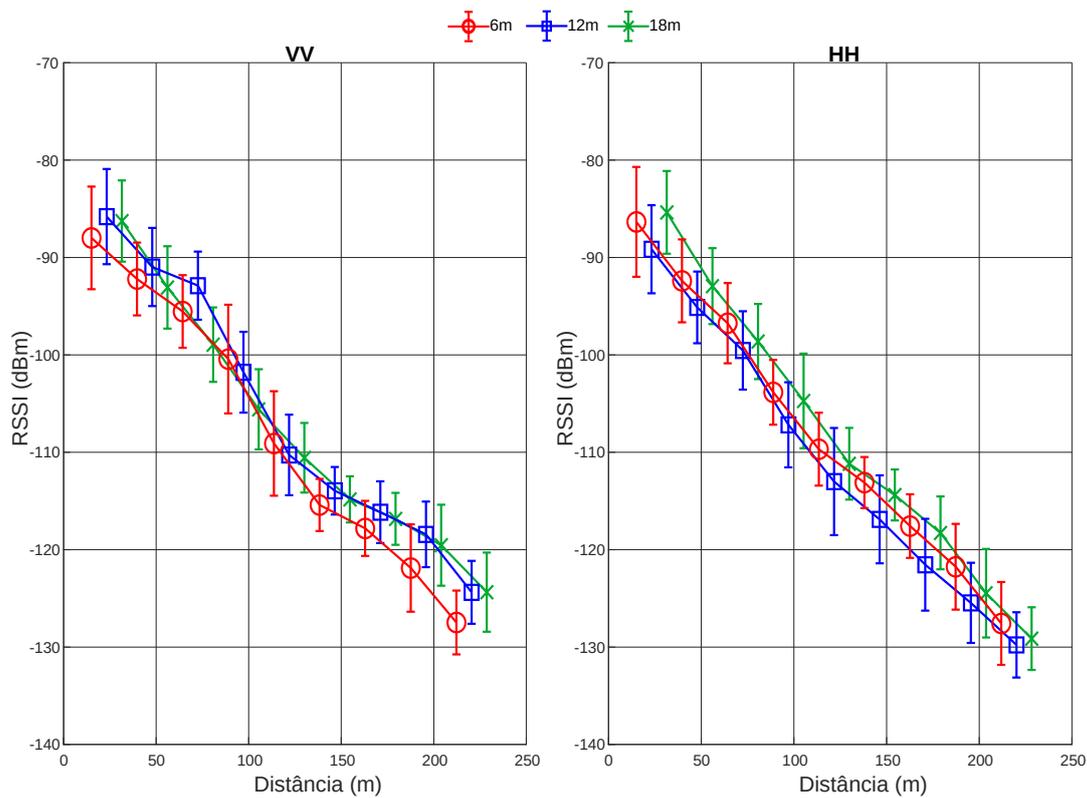


Figura 23 – Análise dos valores médios e desvio padrão do RSSI para SF12 em todas as alturas e para as polarizações VV e HH.

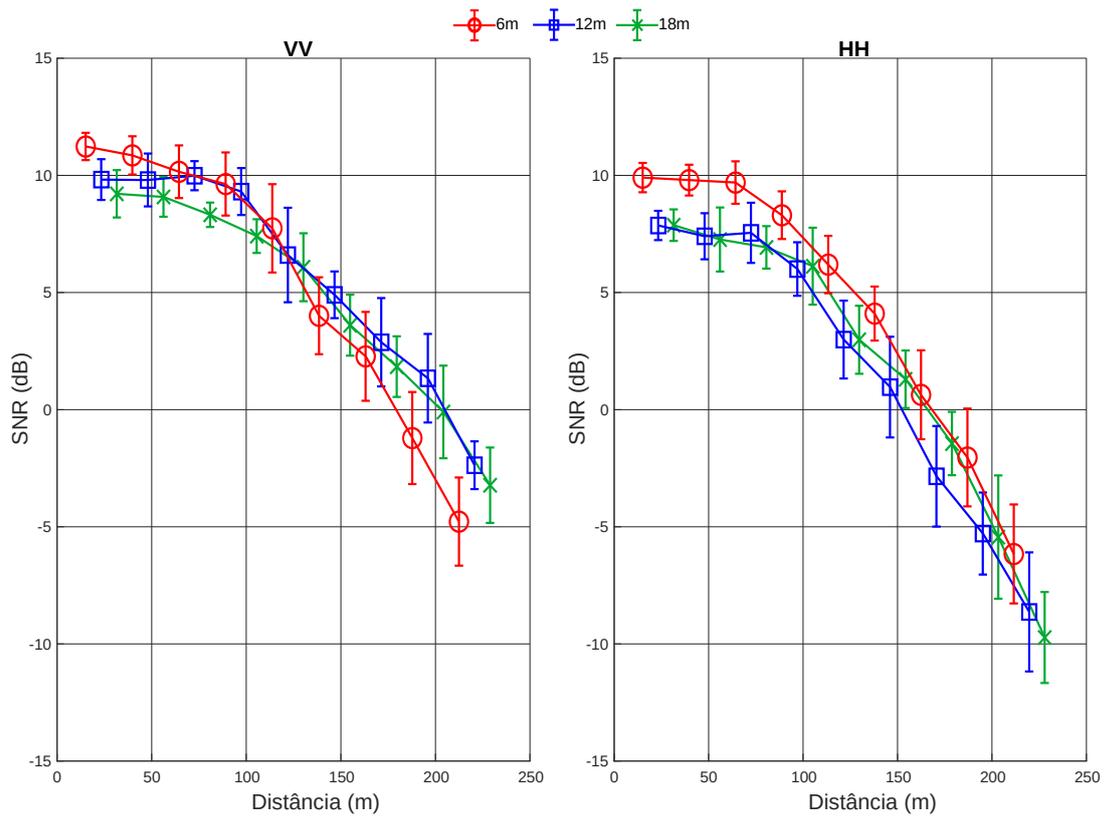


Figura 24 – Análise dos valores médios e desvio padrão do SNR para SF12 em todas as alturas e para as polarizações VV e HH.

Primeiramente, ao analisar as Figuras 23 e 24, observa-se que, para a polarização horizontal da antena (HH) a uma altura de 6 m, onde o transmissor está localizado no nível do tronco da árvore, os valores de RSSI variam de  $-131$  a  $-80$  dBm, enquanto o SNR varia de  $-8$  a  $11$  dB.

Quando a altura é aumentada para 12 m, correspondente ao início da copa da árvore, os valores de RSSI variam de  $-133$  a  $-85$  dBm, enquanto o SNR varia de  $-11$  a  $8$  dB. Finalmente, a uma altura de 18 m, correspondente ao meio da copa da árvore, os valores de RSSI variam de  $-132$  a  $-82$  dBm, enquanto o SNR varia de  $-12$  a  $8$  dB.

Por outro lado, ao analisar a polarização vertical da antena (VV), observa-se que, a uma altura de 6 m, os valores de RSSI variam de  $-131$  a  $-83$  dBm, enquanto o SNR varia de  $-7$  a  $12$  dB. A uma altura de 12 m, os valores de RSSI estão na faixa de  $-128$  a  $-81$  dBm, e os valores de SNR estão na faixa de  $-3$  a  $11$  dB. Finalmente, para uma altura de 18 m, os valores de RSSI estão na faixa de  $-129$  a  $-82$  dBm, e os valores de SNR estão na faixa de  $-5$  a  $10$  dB.

A partir das Figuras 23 e 24, é possível observar que a polarização VV apresenta valores de RSSI e SNR similares à polarização HH. No entanto, a diminuição no nível do sinal VV sobre a distância é menor em comparação com o sinal HH.

Além disso, a Tabela 6 é apresentada para mostrar os valores das métricas estatísticas, desvio padrão ( $\sigma$ ) e média, do RSSI e do SNR para diferentes polarizações e alturas. Analisando a tabela, pode-se verificar que, em média, o valor mais baixo da polarização VV (a uma altura de 18 m) mostra um resultado praticamente igual ao valor mais alto da polarização HH (a uma altura de 6 m).

E mais, em todas as alturas, a polarização VV apresenta uma média de RSSI ligeiramente maior do que a polarização HH. O desvio padrão do RSSI é relativamente consistente entre as diferentes alturas e polarizações, com valores variando entre aproximadamente 14,84 dBm e 16,62 dBm.

Em relação ao SNR, a polarização VV tende a apresentar uma média de SNR mais alta do que a polarização HH em todas as alturas. O desvio padrão do SNR é maior para a polarização HH em comparação com a polarização VV, especialmente a 12 m e 18 m de altura.

Tabela 6 – Métricas estatísticas do sinal coletado

Altura	$\sigma$ -RSSI (dBm)		Média RSSI (dBm)		$\sigma$ -SNR (dB)		Média SNR (dB)	
	HH	VV	HH	VV	HH	VV	HH	VV
6 m	14,84	16,62	-107,24	-105,76	6,68	6,93	4,32	5,36
12 m	14,86	15,01	-111,09	-106,24	6,87	5,13	1,16	5,10
18 m	15,91	14,90	-108,76	-107,31	7,22	5,96	1,08	4,28

Fonte: A autora.

Em resumo, ao posicionar o transmissor nas alturas de 12 m e 18 m, correspondentes ao início e ao meio das copas das árvores, respectivamente, observa-se que a média do SNR é significativamente menor para a polarização HH. Isso sugere uma maior degradação da qualidade do sinal nessas alturas, indicando que as folhas têm um impacto considerável na atenuação do sinal em um ambiente arborizado.

Essas observações indicam que a polarização VV pode ser mais eficaz em manter uma melhor qualidade de sinal, tanto em termos de RSSI quanto de SNR, em diferentes alturas, especialmente em ambientes com vegetação densa.

Além disso, ao analisar os valores médios de RSSI e SNR para cada situação, verifica-se que, conforme as alturas aumentam, os valores médios de RSSI e SNR diminuem, conforme mostrado na Tabela 6.

### 5.3 AJUSTES DOS MODELOS DE PROPAGAÇÃO CI e FI

Os valores de PLE e os coeficientes alfa ( $\alpha$ ) e beta ( $\beta$ ) são importantes para melhorar a precisão das previsões de propagação de sinal em ambientes reais, o que aprimora o desempenho de redes sem fio em áreas com vegetação. Todos os valores de *PLE* para o modelo CI e os coeficientes ( $\alpha$  e  $\beta$ ) e a distância inicial ( $d_0$ ) para o modelo FI são exibidos na Tabela 7.

Tabela 7 – Valores dos coeficientes ajustados para FI e CI.

SITUAÇÕES	FI ( $d_0$ (m)  $\alpha$   $\beta$ )	CI (PLE)
SF12-6 m-HH	10,92 69,02 4,98	3,93
SF12-6 m-VV	10,92 68,29 4,91	3,85
SF12-12 m-HH	17,32 76,56 5,87	4,15
SF12-12 m-VV	12,45 68,34 4,79	3,73
SF12-18 m-HH	14,13 71,43 5,66	4,08
SF12-18 m-VV	12,47 73,30 4,71	3,86

Fonte: A autora.

De acordo com os valores de FI( $\beta$ ) e CI (*PLE*), a uma altura de 6 m (tronco de árvore), a perda de propagação para ambas as polarizações VV e HH é semelhante. No entanto, a alturas de 12 m (início da copa das árvores) e 18 m (meio da copa das árvores), a polarização VV apresenta o menor decaimento com a distância.

### 5.4 AVALIAÇÃO DOS MODELOS DE PROPAGAÇÃO PROPOSTOS BASEADOS EM REDES NEURAIAS ARTIFICIAIS (RNAs)

Os modelos propostos utilizam três variáveis de entrada: distância (de 5 a 250 m), altura do transmissor (6, 12 e 18 m) e a copolarização das antenas transmissora e receptora (HH-VV). Para avaliar a precisão dos modelos propostos, duas métricas foram aplicadas: erro quadrático médio (RMSE) e desvio padrão ( $\sigma$ ).

O RMSE mede a raiz quadrada da média dos erros quadráticos entre os valores previstos pelo modelo e os valores medidos. Seu objetivo é prever um valor numérico contínuo, como a perda de propagação em um sistema de comunicação sem fio. O RMSE é calculado usando a Equação (5.1) (MONTGOMERY DC; RUNGER, 2012):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5.1)$$

em que  $\sum$  indica a soma de todos os elementos para cada amostra  $i$ ,  $y_i$  representa o valor observado real na amostra  $i$ ,  $\hat{y}_i$  representa o valor previsto pelo modelo para a  $i$ -th amostra e  $n$  é o número total de amostras ou observações no conjunto de dados.

O  $\sigma$  é uma medida de dispersão ou variabilidade nos dados em relação à média. Em termos simples, nos diz o quão longe os valores estão da média. O desvio padrão é calculado usando a fórmula (5.2) (HAYKIN, 2009):

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}} \quad (5.2)$$

em que  $\sum$  indica a soma de todos os elementos,  $x_i$  é o valor individual no conjunto de dados,  $\bar{x}$  é a média dos valores e  $n$  é o número total de exemplos.

A importância do desvio padrão na avaliação dos modelos de perda de propagação baseados em RNA está relacionada à sua capacidade de nos mostrar a variabilidade dos valores observados de perda de propagação. Quanto menor o desvio padrão, mais consistentes e precisos são os resultados previstos pelo modelo.

Para avaliar adequadamente um modelo de perda de propagação baseado em RNA, é essencial considerar tanto o RMSE quanto o desvio padrão. O RMSE fornece uma ideia geral da precisão das previsões do modelo, enquanto o desvio padrão ajuda a entender a variabilidade nos dados e a confiabilidade das previsões em diferentes cenários.

Além disso, é importante enfatizar que a escolha das métricas de avaliação também depende do contexto e dos requisitos específicos do problema em questão. Por exemplo, em aplicações críticas como sistemas de comunicação, é essencial ter modelos de previsão de perda de propagação com alta precisão e baixo desvio padrão para garantir o bom desempenho do sistema.

Os resultados obtidos foram próximos em termos de desempenho, como mostrado na Figura 25, e as respostas do MLP, representadas pelo x vermelho, estão próximas das respostas do GRNN, representadas pelo quadrado preto. Além disso, o RMSE de 3,86 dB para o GRNN e 3,8614 dB para o MLPNN sugere que ambas as redes foram capazes de capturar efetivamente padrões nos dados e generalizar para novas amostras. Essa proximidade nos resultados também pode indicar que o problema é relativamente bem comportado e que ambas as redes estão fornecendo soluções consistentes e precisas.

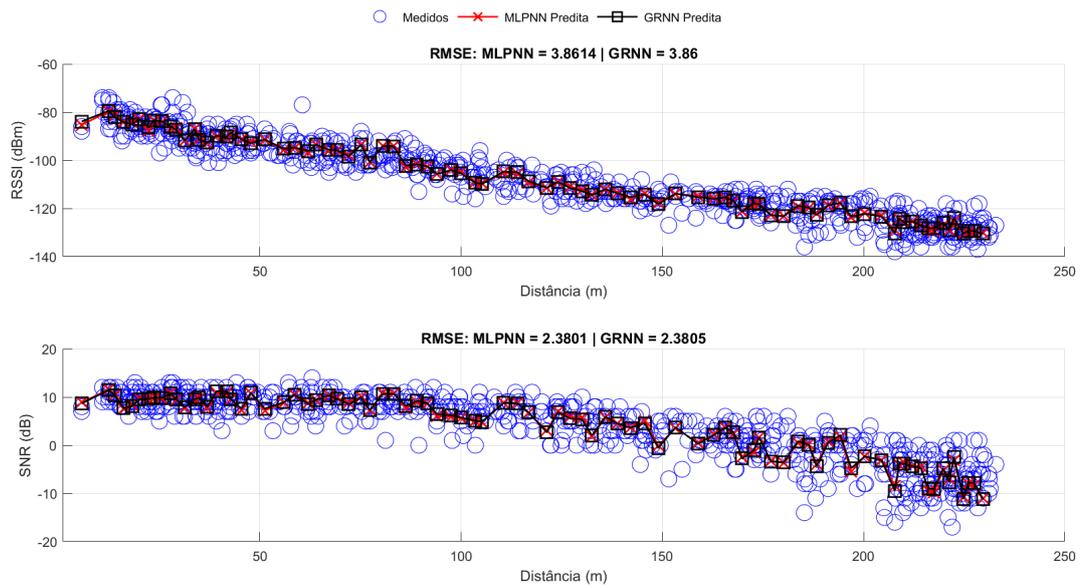


Figura 25 – Dados medidos e previsão da MLPNN e GRNN.

A Tabela 8 mostra os valores das métricas avaliadas. Pode-se observar que ambas as RNAs estavam muito próximas em termos de precisão e acurácia. No entanto, em relação ao tempo de treinamento, o GRNN foi aproximadamente 82% mais rápido que o MLPNN. Ambos foram treinados usando um notebook equipado com um processador Core i5 12500H. A vantagem do GRNN em exigir um custo computacional mais baixo é uma característica importante a ser considerada, especialmente ao lidar com grandes volumes de dados ou ao otimizar recursos disponíveis.

Tabela 8 – Métricas de avaliação para as RNAs

RNAs	RMSE	$\sigma$	Tempo de Treinamento (s)
GRNN	3,8600	3,8558	0,3634
MLPNN	3,8614	3,8564	2,0839

Fonte: A autora.

## 5.5 COMPARAÇÃO COM MODELOS DE PERDA DE PROPAGAÇÃO DA LITERATURA

Os resultados apresentados pelos modelos baseados em RNA propostos para ambientes densamente arborizados para redes IoT na faixa de frequência de 915 MHz foram comparados com modelos empíricos CI e FI, bem como com modelos adaptados para ambientes vegetados, nomeadamente Weissberger, *Early* ITU-R, Cost235 e FITU-R.

Como visto na Figura 25, os modelos MLPNN e GRNN representaram melhor o comportamento médio dos dados medidos, obtendo valores de RMSE e desvio padrão que foram semelhantes e menores do que os outros modelos analisados. Isso se deve aos modelos de propagação baseados em RNA serem capazes de estimar com mais precisão a variabilidade na perda de propagação em um único ponto, bem como representar o comportamento do sinal no ambiente estudado.

A Figura 26 mostra a comparação dos modelos baseados em RNA propostos e os modelos adaptados à vegetação com os dados medidos para uma altura de 6 m VV.

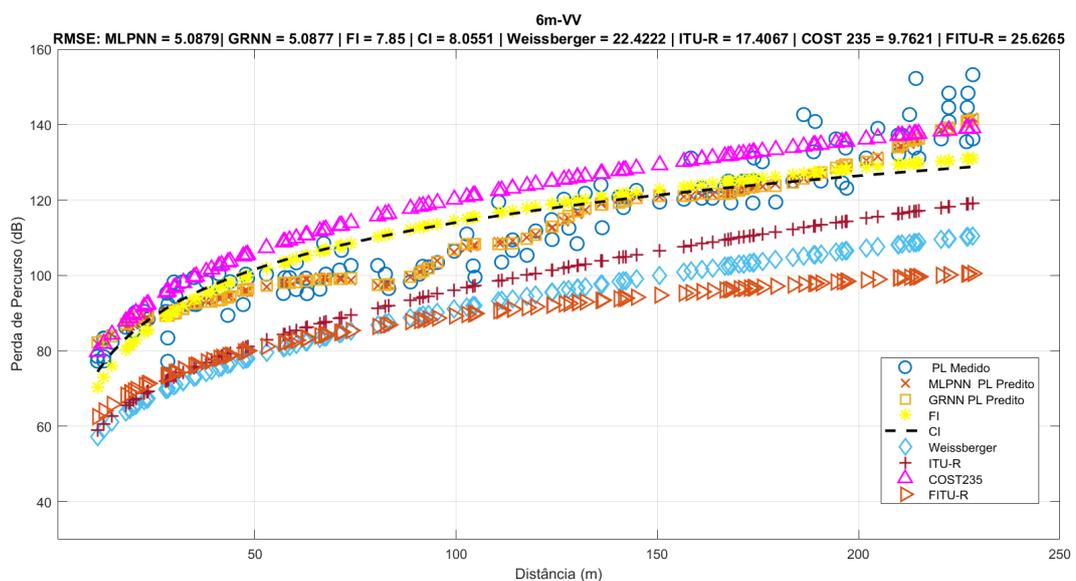


Figura 26 – Modelos de perda de propagação aplicados e propostos, MLPNN e GRNN.

Os outros modelos empíricos de propagação obtiveram valores de RMSE e desvio padrão mais altos do que os modelos propostos. Em particular, os modelos FI e CI, que foram ajustados de acordo com os dados medidos usando a técnica de mínimos quadrados lineares, mostraram valores de RMSE mais altos. No entanto, o modelo FI se ajustou melhor aos dados medidos devido ao uso de dados medidos diretamente como referência inicial, permitindo um ajuste mais preciso às condições específicas do ambiente de propagação, enquanto o modelo CI considera o valor de *FSPL* como o ponto de referência inicial.

Para os modelos de perda de propagação em ambientes com vegetação, o que melhor representou os dados medidos foi o COST235, devido ao seu desenvolvimento específico para ambientes com vegetação e parâmetros ajustados para refletir a densidade e o tipo de vegetação, seguido pelo ITU-R, Weissberger e, finalmente, o pelo modelo FITU-R. O modelo FITU-R tem um desempenho melhor do que os modelos ITU-R e Weissberger até os primeiros 50 m.

As comparações dos modelos de propagação, por meio das métricas RMSE e  $\sigma$ , para as outras alturas e polarizações, estão apresentadas na Tabela 9. A análise detalhada dos resultados revela que o modelo FITU-R apresentou o pior desempenho, especialmente na polarização horizontal (HH), devido à sua natureza genérica e falta de otimização para ambientes com vegetação.

Esses resultados destacam a importância de utilizar modelos específicos e bem ajustados para prever a perda de sinal em diferentes ambientes, especialmente em cenários complexos como os que têm vegetação densa.

Tabela 9 – Comparação dos Resultados dos Modelos de Propagação.

SITUAÇÕES	MÉTRICAS	GRNN	MLPNN	CI	FI	WEISSB.	ITU-R	COST 235	FITU-R
SF12-6 m-HH	RMSE	3,46	3,39	7,83	7,69	22,12	16,90	9,91	25,70
	$\sigma$	4,21	4,14	7,86	7,73	6,51	6,17	17,23	9,30
SF12-6 m-VV	RMSE	4,12	4,11	8,05	7,85	22,42	17,40	9,76	25,62
	$\sigma$	4,97	4,96	8,08	7,88	6,95	6,46	18,73	9,95
SF12-12 m-HH	RMSE	4,11	4,19	8,11	7,84	26,70	21,30	7,83	30,40
	$\sigma$	5,71	5,80	8,15	7,89	7,35	6,73	17,77	10,21
SF12-12 m-VV	RMSE	3,66	3,61	7,44	7,42	19,59	14,50	11,75	23,32
	$\sigma$	4,29	4,24	7,45	7,45	6,09	6,35	16,00	8,16
SF12-18 m-HH	RMSE	4,01	4,04	9,38	8,53	23,99	18,43	10,01	28,26
	$\sigma$	5,30	5,31	9,41	8,58	8,20	7,30	19,13	11,48
SF12-18 m-VV	RMSE	3,82	3,86	7,24	7,10	21,42	16,21	10,10	25,10
	$\sigma$	5,11	5,16	7,27	7,13	6,22	6,12	16,72	8,77

Fonte: A autora.

## 6 CONCLUSÕES

Este trabalho teve como objetivo desenvolver dois modelos de propagação utilizando técnicas de aprendizado de máquina, MLPNN e GRNN, para ambientes densamente arborizados em uma frequência de 915 MHz, e avaliá-los em relação a dados medidos e modelos existentes na literatura. Para alcançar esse objetivo, uma extensa campanha de medição foi realizada na floresta Camillo Vianna, localizada na Universidade Federal do Pará, que apresenta várias espécies de árvores, predominantemente do tipo Pau-Mulato.

Nesta campanha de medição, foram coletados dados relacionados à geolocalização, RSSI e SNR ao longo de um percurso de 250 m. Posteriormente, houve a necessidade de processamento de dados, como o cálculo da distância usando geolocalizações e o cálculo da perda de propagação usando dados de RSSI e SNR.

Além disso, redes neurais artificiais (MLPNN e GRNN) foram treinadas, além da aplicação da técnica dos mínimos quadrados para ajustar os modelos de propagação CI e FI. O objetivo era prever o comportamento médio da propagação do sinal e avaliá-los em relação aos dados medidos. Em seguida, foram comparados com modelos adaptados para vegetação (ITU-R, Weissberger, COST235 e FITU-R).

Assim, os modelos de propagação propostos, MLPNN e GRNN, alcançaram melhor precisão, com valores de RMSE de 3,8614 dB e 3,86 dB, e valores de desvio padrão de 3,8564 dB e 3,8558 dB, respectivamente, para RSSI. Além disso, para a previsão de SNR, os valores de RMSE foram 2,3801 dB e 2,3805 dB, e os valores de desvio padrão foram 2,3788 dB e 2,3798 dB, respectivamente. Os resultados mostram a capacidade dos modelos de aprender com os dados e capturar relações não lineares. Essa capacidade permite que esses modelos alcancem uma maior capacidade preditiva do comportamento médio do sinal em comparação com modelos clássicos na literatura.

Os resultados satisfatórios obtidos pelas RNAs MLPNN e GRNN na modelagem da perda de propagação indicam que ambas são opções viáveis para essa tarefa de regressão. Com diferença mínima nos resultados de RMSE, a escolha entre as duas pode ser orientada pela velocidade de treinamento e demanda de recursos, com a GRNN tendo vantagem nesses aspectos.

Embora os modelos CI e FI tenham apresentado desempenho geralmente melhor do que os modelos de propagação adaptados para vegetação, vale ressaltar que ambos foram ajustados com dados medidos do ambiente, como mostrado na Tabela 7. Quanto aos modelos ajustados para ambientes vegetados, o modelo de propagação COST235 geralmente se ajustou melhor aos dados medidos do que outros modelos de vegetação, devido ao seu desenvolvimento específico e parâmetros ajustados para ambientes com vegetação.

Outra contribuição significativa do trabalho foi a análise em relação às alturas e copolarizações. A escolha apropriada da polarização da onda eletromagnética para transmissões de sinal sem fio em ambientes com vegetação é fundamental para otimizar a eficiência e a confiabilidade das comunicações. Esta pesquisa demonstrou que a polarização VV é mais adequada para todas as alturas. Compreender essas diferenças permite o projeto de redes de comunicação mais eficientes e resilientes, contribuindo para avanços em aplicações de monitoramento e pesquisa em ambientes densamente arborizados. Finalmente, outra contribuição foi calcular os valores de  $PLE$ ,  $\alpha$  e  $\beta$  para o ambiente de estudo, como mostrado na Tabela 7.

Para trabalhos futuros, a intenção é analisar o impacto do fator de espalhamento e, conseqüentemente, a taxa de bits, já que os dois estão diretamente relacionados. Além disso, analisar as alturas superiores a 18 m e inferiores a 6 m para quantificar o impacto da vegetação densa nos sinais eletromagnéticos. Para examinar as copolarizações de transmissor e receptor, é necessário utilizar antenas de diferentes alturas para entender qual tipo de polarização sofre menos perda através da floresta. Além disso, devido à perda de propagação imposta pela vegetação na transmissão em diferentes cenários, a intenção é utilizar outras técnicas de aprendizado de máquina (como *Neurofuzzy* e *Random Forest*), e ainda, usar outras métricas estatísticas (incluindo MAE, MPE, MAPE e GRG-MAPE), além disso, empregar o modelo ITU-R P.1546-6, pois é a nova extensão do modelo 1546 para distâncias inferiores a 1000 km.

# Referências

- ALIMPERTIS, E. et al. City-Wide Signal Strength Maps: Prediction with Random Forests. In: *The World Wide Web Conference*. [S.l.]: ACM, 2019. Citado na página 2.
- ALLIANCE, L. White paper: A technical overview of lora and lorawan. *The LoRa Alliance: San Ramon, CA, USA*, p. 7–11, 2015. Citado 2 vezes nas páginas 21 e 22.
- ALMUHAYA, M. A. M. et al. A survey on lorawan technology: Recent trends, opportunities, simulation tools and future directions. *Electronics*, v. 11, n. 1, 2022. ISSN 2079-9292. Disponível em: <<https://www.mdpi.com/2079-9292/11/1/164>>. Citado na página 8.
- ALSAYYARI, A.; ALDOSARY, A. Path Loss Results for Wireless Sensor Network Deployment in a Long Grass Environment. In: *2018 IEEE Conference on Wireless Sensors (ICWiSe)*. [S.l.]: IEEE, 2018. Citado na página 10.
- ALWIS, C. D. et al. Survey on 6G Frontiers: Trends, Applications, Requirements, Technologies and Future Research. *IEEE Open Journal of the Communications Society*, Institute of Electrical and Electronics Engineers (IEEE), v. 2, p. 836–886, 2021. Citado na página 1.
- AMIN, F. et al. A step toward next-generation advancements in the internet of things technologies. *Sensors*, MDPI, v. 22, n. 20, p. 8072, 2022. Citado na página 32.
- ANZUM, R. Factors that affect LoRa propagation in foliage medium. *Procedia Computer Science*, Elsevier BV, v. 194, p. 149–155, 2021. Citado 2 vezes nas páginas 8 e 10.
- ASHTON, K. That ‘internet of things’ thing. In: . [s.n.], 1999. Disponível em: <<https://api.semanticscholar.org/CorpusID:109032799>>. Citado na página 15.
- AUGUSTIN, A. et al. A study of lora: Long range & low power networks for the internet of things. *Sensors*, MDPI, v. 16, n. 9, p. 1466, 2016. Citado na página 19.
- BARRIOS-ULLOA, A. et al. Modeling radio wave propagation for wireless sensor networks in vegetated environments: A systematic literature review. *Sensors*, MDPI AG, v. 22, n. 14, p. 5285, jul 2022. Citado 2 vezes nas páginas 10 e 53.
- BARRIOS-ULLOA, A. et al. Modeling radio wave propagation for wireless sensor networks in vegetated environments: A systematic literature review. *Sensors*, MDPI, v. 22, n. 14, p. 5285, 2022. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9324029/>>. Citado na página 3.
- BARRIOS-ULLOA, A. et al. Modeling of path loss for radio wave propagation in wireless sensor networks in cassava crops using machine learning. *Agriculture*, MDPI, v. 13, n. 11, p. 2046, 2023. Citado na página 33.
- BASSI, A.; HORN, G. Internet of things in 2020: A roadmap for the future. *European Commission: Information Society and Media*, v. 22, p. 97–114, 2008. Citado na página 15.
- BOR, M. C.; VIDLER, J.; ROEDIG, U. Lora for the internet of things. In: *Ewsn*. [S.l.: s.n.], 2016. v. 16, p. 361–366. Citado 2 vezes nas páginas 19 e 45.

- CARDOSO, C. M. M. et al. SNR Prediction with ANN for UAV Applications in IoT Networks Based on Measurements. *Sensors*, MDPI AG, v. 22, n. 14, p. 5233, jul 2022. Citado na página 3.
- CARVALHO, A. A. P. d. et al. Empirical path loss model in city-forest environment for mobile communications. *Journal of Communication and Information Systems*, v. 36, n. 1, p. 70–74, Mar. 2021. Disponível em: <<https://jcis.sbrt.org.br/jcis/article/view/766>>. Citado na página 2.
- CARVALHO, N. P.; MATOS, L. J.; CATALDO, E. Rede Neural Artificial Aplicada na Predição de Cobertura de Sinal em Vegetação. In: *XXXVIII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais - SBrT*. [S.l.: s.n.], 2020. Citado na página 30.
- CASTRO, B. S. L. et al. Comparison between known propagation models using least squares tuning algorithm on 5.8 GHz in amazon region cities. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, FapUNIFESP (SciELO), v. 10, n. 1, p. 106–113, jun 2011. Citado 2 vezes nas páginas 2 e 3.
- CAVALCANTI, B. J. Análise de modelos de predição de perdas de propagação em redes de comunicações lte e lte-advanced usando técnicas de inteligência artificial. Brasil, 2017. Citado na página 25.
- CENTENARO, M. et al. Long-range communications in unlicensed bands: the rising stars in the iot and smart city scenarios. *IEEE Wireless Communications*, v. 23, n. 5, p. 60–67, 2016. Citado na página 16.
- CHERUVU, S. et al. Connectivity technologies for iot. In: \_\_\_\_\_. *Demystifying Internet of Things Security: Successful IoT Device/Edge and Platform Security Deployment*. Berkeley, CA: Apress, 2020. p. 347–411. ISBN 978-1-4842-2896-8. Disponível em: <[https://doi.org/10.1007/978-1-4842-2896-8\\_5](https://doi.org/10.1007/978-1-4842-2896-8_5)>. Citado na página 17.
- CHILAMKURTHY, N. S. et al. Low-power wide-area networks: A broad overview of its different aspects. *IEEE Access*, IEEE, v. 10, p. 81926–81959, 2022. Citado 2 vezes nas páginas 17 e 18.
- CHOPDE, N. R.; NICHAT, M. Landmark based shortest path detection by using a\* and haversine formula. *International Journal of Innovative Research in Computer and Communication Engineering*, v. 1, n. 2, p. 298–302, 2013. Citado na página 48.
- Consultimer. *LoRa: Conheça a Tecnologia de Radiofrequência de Longo Alcance*. [S.l.], 2023. Disponível em: <<https://consultimer.com/o-que-e-lora-conheca-a-tecnologia-de-radiofrequencia-de-longo-alcance/#:~:text=LoRa%2C%20abrevia%C3%A7%C3%A3o%20de%20%E2%80%9Clong%20range%E2%80%9D%2C%20%C3%A9%20a%20tecnologia,plataforma%20ideal%20para%20a%20Internet%20das%20Coisas%20%28IoT%29.>>>. Citado na página 1.
- COTA, N. et al. On the use of Okumura-Hat a propagation model on railway communications. In: *2013 16th International Symposium on Wireless Personal Multimedia Communications (WPMC)*. [S.l.: s.n.], 2013. p. 1–5. Citado na página 2.
- CRUZ, H. A. O. et al. Methodology for LoRa gateway placement based on bio-inspired algorithms for a smart campus in wooded area. *Sensors*, MDPI AG, v. 22, n. 17, p. 6492, aug 2022. Citado na página 3.

ERAS, L. E. C. et al. A radio propagation model for a rainforest–river environment using utd and geometrical optics. *IEEE Antennas and Wireless Propagation Letters*, v. 21, n. 1, p. 54–58, 2022. Citado na página 2.

FABRO, J. *Uma abordagem neuro-nebulosa para controle preditivo de processos multi-estágios*. Tese (Doutorado), 12 2003. Citado na página 37.

FREITAS, P. V. A. D. Avaliação e modelagem da cobertura de sinal na faixa de 3, 5 ghz para um ambiente com clutter. *Masters Dissertation*, Universidade Federal Fluminense-UFFRJ, 2021. Citado na página 25.

GAMBIROŽA, J. Č. et al. Capacity in lorawan networks: Challenges and opportunities. In: IEEE. *2019 4th International Conference on Smart and Sustainable Technologies (SpliTech)*. [S.l.], 2019. p. 1–6. Citado na página 21.

GONZÁLEZ-PALACIO, M. et al. LoRaWAN path loss measurements in an urban scenario including environmental effects. *Data*, MDPI AG, v. 8, n. 1, p. 4, dec 2022. Citado na página 48.

HAXHIBEQIRI, J. et al. A survey of lorawan for iot: From technology to application. *Sensors*, v. 18, n. 11, 2018. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/18/11/3995>>. Citado na página 18.

HAYKIN, S. *Neural Networks: A comprehensive foundation* (3rd edition). [S.l.]: Prentice Hall, 2007. 842 p. ISBN 9780131471399. Citado 3 vezes nas páginas 37, 38 e 39.

HAYKIN, S. *Neural networks and learning machines, 3/E*. [S.l.]: Pearson Education India, 2009. Citado 2 vezes nas páginas 35 e 61.

IORKAA, A. A.; BARMA, M.; MUAZU, H. Machine learning techniques, methods and algorithms: Conceptual and practical insights. *International Journal of Engineering Research and Applications*, v. 11, p. 55–64, 08 2021. Citado na página 33.

JO, H.-S. et al. Path Loss Prediction Based on Machine Learning Techniques: Principal Component Analysis, Artificial Neural Network, and Gaussian Process. *Sensors*, MDPI AG, v. 20, n. 7, p. 1927, mar 2020. Citado na página 11.

JUSTO-SILVA, R.; FERREIRA, A.; FLINTSCH, G. Review on machine learning techniques for developing pavement performance prediction models. *Sustainability*, v. 13, n. 9, 2021. ISSN 2071-1050. Disponível em: <<https://www.mdpi.com/2071-1050/13/9/5248>>. Citado na página 34.

KELLY, S.; SURYADEVARA, N.; MUKHOPADHYAY, S. Towards the implementation of iot for environmental condition monitoring in homes. *IEEE Sensors Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 13, n. 10, p. 3846–3853, 2013. ISSN 1530-437X. Citado na página 15.

KUMAR, M. et al. Wireless sensor networks for environmental monitoring in forest ecosystems. *European Chemical Bulletin*, v. 12, p. 4173–4193, 06 2023. Citado na página 53.

LOPEZ-ITURRI, P. et al. Radio Channel Characterization in Dense Forest Environments for IoT-5G. In: *5th International Electronic Conference on Sensors and Applications*. [S.l.]: MDPI, 2018. Citado na página 2.

- LÓPEZ, S. G. *Detection of unsupervised anomalies in light sensors*. Dissertação (B.S. thesis) — Universitat Politècnica de Catalunya, 2023. Citado na página 47.
- LORAWAN Regional Parameters RP002-1.0.4. 2022. <<https://resources.lora-alliance.org/technical-specifications/rp002-1-0-4-regional-parameters>>. Citado na página 16.
- LORA™ Modulation Basics note An1200.22. 2023. <<https://www.semtech.com/uploads/documents/an1200.22.pdf>>. Citado 3 vezes nas páginas 1, 19 e 45.
- LOUREIRO, A. A. et al. Redes de sensores sem fio. In: SN. *Simpósio Brasileiro de Redes de Computadores (SBRC)*. [S.l.], 2003. p. 179–226. Citado na página 15.
- MACCARTNEY, G. R. et al. Indoor office wideband millimeter-wave propagation measurements and channel models at 28 and 73 GHz for ultra-dense 5g wireless networks. *IEEE Access*, Institute of Electrical and Electronics Engineers (IEEE), v. 3, p. 2388–2424, 2015. Citado na página 27.
- MACEDO, A. et al. Channel analysis for 3.5 GHz frequency in airport. *Journal of Communication and Information Systems*, Sociedade Brasileira de Telecomunicações, v. 38, n. 1, p. 115–120, aug 2023. Citado na página 28.
- MEKKI, K. et al. A comparative study of lpwan technologies for large-scale iot deployment. *ICT express*, Elsevier, v. 5, n. 1, p. 1–7, 2019. Citado na página 22.
- MONTGOMERY DC; RUNGER, G. *Estatística aplicada e probabilidade para engenheiros*. [S.l.]: (5ª Edição), 2012. Citado na página 60.
- MORETA, C. E. G.; ACOSTA, M. R. C.; KOO, I. Prediction of Digital Terrestrial Television Coverage Using Machine Learning Regression. *IEEE Transactions on Broadcasting*, Institute of Electrical and Electronics Engineers (IEEE), v. 65, n. 4, p. 702–712, dec 2019. Citado 2 vezes nas páginas 2 e 11.
- MURPHY, K. P. *Machine learning a probabilistic perspective: a probabilistic perspective*. [S.l.]: MIT Press, 2012. ISBN 9780262018029. Citado na página 33.
- MYAGMARDULAM, B. et al. Path loss prediction model development in a mountainous forest environment. *IEEE Open Journal of the Communications Society*, Institute of Electrical and Electronics Engineers (IEEE), v. 2, p. 2494–2501, 2021. Citado 2 vezes nas páginas 9 e 10.
- NDZI D., K. L. M. E. Z. A. A. R. F. M. S. A. J. M. Vegetation attenuation measurements and modeling in plantations for wireless sensor network planning. *in Electromagnetics Rese-1147 arch B*, 36, 283-301, 2012. Citado na página 29.
- NETO, N. C. M. Fuzzy c-means based gateway placement algorithm for lorawan. 2020. Citado na página 20.
- OJO, M. O.; ADAMI, D.; GIORDANO, S. Experimental evaluation of a lora wildlife monitoring network in a forest vegetation area. *Future Internet*, v. 13, n. 5, 2021. ISSN 1999-5903. Disponível em: <<https://www.mdpi.com/1999-5903/13/5/115>>. Citado na página 8.
- OJO, S.; IMOIZE, A.; ALIENYI, D. Radial basis function neural network path loss prediction model for LTE networks in multitransmitter signal propagation environments. *International Journal of Communication Systems*, Wiley, v. 34, n. 3, nov 2020. Citado na página 11.

- PAIVA, B. S.; LUZ, L. M. da; SILVA, C. N. da. *Sistemas de áreas verdes da Cidade Universitária Professor José da Silveira Netto, da UFPA, em Belém (PA)*. [S.l.]: v. 25, n. 1, p. 297-323, jan-abr 2022, ISSN 1516-6481 / 2179-7536, 2022. Citado 2 vezes nas páginas 3 e 43.
- RAPPAPORT, T. S. *Wireless communications—principles and practice*, (the book end). *Microwave Journal*, Horizon House Publications, Inc., v. 45, n. 12, p. 128–129, 2002. Citado 3 vezes nas páginas 25, 26 e 27.
- RAPPAPORT, T. S. *Comunicações sem fio: princípios e práticas*. [S.l.]: Pearson Prentice Hall, 2009. Citado 2 vezes nas páginas 24 e 25.
- RAPPAPORT, T. S. et al. Wideband millimeter-wave propagation measurements and channel models for future wireless communication system design. *IEEE Transactions on Communications*, Institute of Electrical and Electronics Engineers (IEEE), v. 63, n. 9, p. 3029–3056, sep 2015. Citado na página 29.
- RAZA, U.; KULKARNI, P.; SOORIYABANDARA, M. Low power wide area networks: An overview. *IEEE Communications Surveys Tutorials*, v. 19, n. 2, p. 855–873, 2017. Citado na página 19.
- RUSSELL, S. J.; NORVIG, P. *Artificial intelligence: a modern approach*. [S.l.]: Pearson, 2016. Citado na página 31.
- SABRI, N. et al. Investigation of Empirical Wave Propagation Models in Precision Agriculture. *MATEC Web of Conferences*, EDP Sciences, v. 150, p. 06020, 2018. Citado 2 vezes nas páginas 9 e 10.
- SCHAFFERS, H. et al. *Smart cities and the future internet: Towards cooperation frameworks for open innovation*. [S.l.]: Springer Berlin Heidelberg, 2011. Citado na página 1.
- SERETIS, A.; SARRIS, C. D. An Overview of Machine Learning Techniques for Radiowave Propagation Modeling. *IEEE Transactions on Antennas and Propagation*, Institute of Electrical and Electronics Engineers (IEEE), v. 70, n. 6, p. 3970–3985, jun 2022. Citado na página 11.
- SILVA, D. K. Nakata da et al. A propagation model for mixed paths using dyadic green's functions: A case study over the river for a city–river–forest path. *IEEE Antennas and Wireless Propagation Letters*, v. 17, n. 12, p. 2364–2368, 2018. Citado na página 2.
- SILVA, I. N. d.; SPATTI, D. H.; FLAUZINO, R. A. *Redes neurais artificiais para engenharia e ciências aplicadas*. 2010. Citado na página 38.
- SILVA, J. C.; SIQUEIRA, G. L.; CASTELLANOS, P. Propagation model for path loss through vegetated environments at 700–800 mhz band. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, SciELO Brasil, v. 17, p. 179–187, 2018. Citado 2 vezes nas páginas 30 e 31.
- SOLANKI, V.; DÍAZ, V. G. *Ijmlnce editorial note volume no 02, issue no 04*. 12 2018. Citado na página 40.
- SPADACCINO, P.; CRINÓ, F. G.; CUOMO, F. *Lorawan behaviour analysis through dataset traffic investigation*. *Sensors*, v. 22, n. 7, 2022. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/22/7/2470>>. Citado na página 23.

SPECHT, D. A general regression neural network. *IEEE Transactions on Neural Networks*, Institute of Electrical and Electronics Engineers (IEEE), v. 2, n. 6, p. 568–576, 1991. Citado 2 vezes nas páginas 39 e 40.

STEHMANN, J. R.; FARIA, F. S.; BRAGIONI, T. L. S. *50 árvores do museu*. [S.l.]: <http://hdl.handle.net/1843/40587>, 2019. Citado na página 46.

SUN, S. et al. Investigation of prediction accuracy, sensitivity, and parameter stability of large-scale propagation path loss models for 5g wireless communications. *IEEE Transactions on Vehicular Technology*, Institute of Electrical and Electronics Engineers (IEEE), v. 65, n. 5, p. 2843–2860, may 2016. Citado 3 vezes nas páginas 27, 28 e 30.

THRANE, J.; ZIBAR, D.; CHRISTIANSEN, H. L. Model-aided deep learning method for path loss prediction in mobile communication systems at 2.6 ghz. *IEEE Access*, v. 8, p. 7925–7936, 2020. Citado na página 2.

T.S.RAPPAPORT (Ed.). *Wireless Communications Principles and Practice*. [S.l.]: EUA, Prentice Hall, 2<sup>o</sup>and, 2002. Citado na página 29.

WANG, W. et al. Comparative Analysis of Channel Models for Industrial IoT Wireless Communication. *IEEE Access*, Institute of Electrical and Electronics Engineers (IEEE), v. 7, p. 91627–91640, 2019. Citado na página 1.

WU, H.; ZHANG, L.; MIAO, Y. The Propagation Characteristics of Radio Frequency Signals for Wireless Sensor Networks in Large-Scale Farmland. *Wireless Personal Communications*, Springer Science and Business Media LLC, v. 95, n. 4, p. 3653–3670, feb 2017. Citado na página 10.

WU, L. et al. Received Power Prediction for Suburban Environment based on Neural Network. In: *2020 International Conference on Information Networking (ICOIN)*. [S.l.]: IEEE, 2020. Citado na página 11.

XU, L. D.; HE, W.; LI, S. Internet of things in industries: A survey. *IEEE Transactions on Industrial Informatics*, v. 10, n. 4, p. 2233–2243, 2014. Citado na página 15.

ZOURMAND, A. et al. Internet of Things (IoT) using LoRa technology. In: *2019 IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS)*. [S.l.]: IEEE, 2019. Citado na página 1.