

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

Redes Neurais Aplicadas à Modelagem de Canais de Comunicação Utilizando VANTs e Dispositivos IoT

Caio Mateus Machado Cardoso

DM 01/2023

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

2023

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

Caio Mateus Machado Cardoso

**Redes Neurais Aplicadas à Modelagem de Canais de Comunicação
Utilizando VANTs e Dispositivos IoT**

Dissertação submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da UFPA para obtenção do Grau de Mestre em Engenharia Elétrica na Área de Computação Aplicada.

Orientadora: Prof^a. Dr^a. Jasmine Priscyla Leite de Araújo

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

2023

**Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)**

M149r Machado Cardoso, Caio Mateus.
Redes neurais aplicadas à modelagem de canais de
comunicação utilizando VANTs e dispositivos IoT / Caio Mateus
Machado Cardoso. — 2023.
67 f. : il. color.

Orientador(a): Prof^ª. Dra. Jasmine Priscyla Leite de Araújo
Coorientador(a): Prof. Dr. Fabrício José Brito Barros
Dissertação (Mestrado) - Universidade Federal do Pará,
Instituto de Tecnologia, Programa de Pós-Graduação em
Engenharia Elétrica, Belém, 2023.

1. RNA. 2. SNR. 3. LoRa. 4. Radiopropagação. 5.
densamente arborizado. I. Título.

CDD 620

**“REDES NEURAIS APLICADAS À MODELAGEM DE CANAIS DE COMUNICAÇÃO
UTILIZANDO VANTS E DISPOSITIVOS IOT”**

AUTOR: CAIO MATEUS MACHADO CARDOSO

DISSERTAÇÃO DE MESTRADO SUBMETIDA À BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA, SENDO JULGADA ADEQUADA PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA.

APROVADA EM: 08/02/2023

BANCA EXAMINADORA:

Prof.^a Dr.^a Jasmine Priscyla Leite de Araújo
(Orientadora – PPGEE/UFPA)

Prof. Dr. Fabrício José Brito Barros
(Coorientador – PPGEE/UFPA)

Prof. Dr. Miércio Cardoso de Alcântara Neto
(Avaliador Interno – PPGEE/ITEC/UFPA)

Prof. Dr. Bruno Souza Lyra Castro
(Avaliador Externo ao Programa – CAMPUS CASTANHAL/UFPA)

Prof. Dr. Fabrício de Souza Farias
(Avaliador Externo ao Programa – CAMPUS CAMETÁ/UFPA)

VISTO:

Prof. Dr. Carlos Tavares da Costa Júnior
(Coordenador do PPGEE/ITEC/UFPA)

Dedico este trabalho à todos que me acompanharam nesta jornada

Agradecimentos

Agradeço a Deus.

Agradeço aos meus pais, Fernando Cardoso e Nilma Machado pelo apoio incondicional dado ao longo de toda a minha vida.

Agradeço aos meus irmão, Fernando Cardoso Filho (Dandi), Nilcielle Salheb e meu cunhado Rodrigo Salheb por sempre estarem presentes e dispostos a me ajudar quando necessário.

Agradeço a minha melhor amiga e namorada Viviane Albuquerque por todo companheirismo, disposição, presença e apoio do início ao fim da jornada do mestrado.

Agradeço aos professores Dr.^a Jasmine Araújo e Dr. Fabrício Barros por abrir as portas do LCT para mim, pela oportunidade de dar continuidade aos estudos cursando o mestrado, as orientações ao longo de todo percurso e confiança depositada em mim.

Agradeço aos Msc. Yuri Barbosa, Msc. Flavio Ferreira e Msc. Wirlan Lima por todo suporte durante as campanhas de medições para coleta de dados.

Agradeço aos Msc. Hugo Cruz e Msc. Alex Sanches, pelas orientações, disponibilidade, apoio dado ao longo de todo o trabalho, paciência e os conhecimentos repassados.

Agradeço aos amigos Joel Carvalho, Artur Machado e Brenda Barbosa pela companhia e suporte ao longo do curso.

Agradeço a todos os membros do Laboratório de Computação e Telecomunicações (LCT) por me ajudarem sempre que precisei.

Agradeço à todos os professores que contribuíram para a minha formação acadêmica.

"Você não pode simplesmente pular para o final.

O caminho é a melhor parte."

Robin Scherbatsky

Abstract

After the occurrence of the cellular networks fifth generation auction (5G), carried out by the National Telecommunications Agency (ANATEL), carriers started to implement the technology on Brazilian soil and it is expected that a massive amount of smart devices will become capable to connect to 5G networks, promoting the advancement and improvement of internet of things (IoT). However, Narrowband-IoT (NB-IoT) technology, used by 5G for IoT applications, is still not enough to meet all user requirements, with that in mind, LoRa technology emerges as an auxiliary to meet the requirements of users. Given this scenario, this work aims to analyze the behavior of the LoRa signal in a suburban and densely wooded environment. For this, measurement campaigns are carried out at the Federal University of Pará (UFPA) and from the collected data a neural network model capable of reproducing this behavior is proposed. The standard model is compared to baseline models and proves to be superior in the downlink and uplink scenarios with a minimum RMSE error of 1,6623 dB for the first and 1,3891 dB for the second.

Key-words: ANN, SNR, LoRa, Radiopropagation, Wooded Area

Resumo

Com a ocorrência do leilão da quinta geração (5G) de redes celulares, realizado pela Agência Nacional de Telecomunicações (ANATEL), as operadoras de telefonia começaram a implantação desta rede em solo brasileiro e espera-se que uma quantidade massiva de dispositivos seja capaz de se conectar a mesma propiciando na expansão e aprimoramento da *internet of things* (IoT). Contudo, a tecnologia *Narrowband-IoT* (NB-IoT), utilizada pelo 5G para aplicações IoT ainda não é suficiente para atender todos os requisitos do serviço *massive Machine-Type Communication* (mMTC), tendo isso em vista, a tecnologia Long-Range (LoRa), com longo alcance de transmissão e resiliência a ruído e interferência, surge como auxiliar para atender estes requisitos. Diante deste cenário, este trabalho tem como objetivo analisar o comportamento do sinal LoRa em um ambiente suburbano e densamente arborizado. Para isto, são realizadas campanhas de medições na Universidade Federal do Pará (UFPA) e a partir dos dados coletados é proposto um modelo de rede neural capaz de reproduzir esse comportamento. O modelo proposto é comparado à modelos de linha de base e demonstra ser superior nos cenários de *downlink* e *uplink* com erro RMSE mínimo de 1,6623 dB para o primeiro e 1,3891 dB para o segundo.

Palavras-chave: RNA, SNR, LoRa, Radiopropagação, densamente arborizado.

Lista de ilustrações

Figura 1 – Fenômeno da Difração	23
Figura 2 – Ilustração do sinal LoRa <i>Up-Chirp</i>	27
Figura 3 – Arquitetura da Rede LoRa	30
Figura 4 – Neurônio Artificial	32
Figura 5 – Metodologia de Medição	36
Figura 6 – Metodologia de Medição	38
Figura 7 – Configuração para Transmissão e Coleta das Informações	38
Figura 8 – Automóvel percorrendo a rota	39
Figura 9 – Rotas de Medição	39
Figura 10 – Dados de <i>Downlink</i>	40
Figura 11 – Dados de <i>Uplink</i>	41
Figura 12 – <i>Downlink</i> : SNR x Distância	42
Figura 13 – <i>Uplink</i> : SNR x Distância	42
Figura 14 – <i>Downlink</i> : SNR x Distância	43
Figura 15 – <i>Uplink</i> : SNR x Distância	43
Figura 16 – <i>Uplink</i> : SNR x Distância	44
Figura 17 – <i>Uplink</i> : SNR x Distância	44
Figura 18 – Arquitetura da RNRG	45
Figura 19 – Arquitetura da RNRG	46
Figura 20 – <i>Downlink</i> : Modelos de Linha de Base	47
Figura 21 – <i>Uplink</i> : Modelos de Linha de Base	48
Figura 22 – <i>Downlink</i> : Rede Neural.	50
Figura 23 – <i>Uplink</i> : Rede Neural.	51
Figura 24 – <i>Downlink</i> : Rede Neural Rota 1.	52
Figura 25 – <i>Uplink</i> : Rede Neural Rota 1.	52
Figura 26 – <i>Downlink</i> : Rede Neural Rota 2.	53
Figura 27 – <i>Uplink</i> : Rede Neural Rota 2.	53
Figura 28 – <i>Downlink</i> : Modelos de Linha de Base 6 m	62
Figura 29 – <i>Downlink</i> : Modelos de Linha de Base 24 m	62
Figura 30 – <i>Downlink</i> : Modelos de Linha de Base 60 m	63
Figura 31 – <i>Uplink</i> : Modelos de Linha de Base 6 m	64
Figura 32 – <i>Uplink</i> : Modelos de Linha de Base 24 m	64
Figura 33 – <i>Uplink</i> : Modelos de Linha de Base 60 m	65

Lista de tabelas

Tabela 1 – Resumo das Contribuições dos Trabalhos Correlatos.	20
Tabela 2 – Parâmetros da rede LoRa para a largura de banda 125 kHz e diferentes valores de SF	29
Tabela 3 – Categorização dos VANTs	34
Tabela 4 – Categorização dos VANTs de acordo com os possíveis ACL	35
Tabela 5 – Configurações utilizadas na transmissão.	37
Tabela 6 – <i>Downlink</i> : Coeficientes e RMSE para a altura de 42 m.	48
Tabela 7 – <i>Uplink</i> : Coeficientes e RMSE para a altura de 42 m.	49
Tabela 8 – <i>Downlink</i> : Resultados da Rede Neural.	50
Tabela 9 – <i>Uplink</i> : Resultados da Rede Neural.	51
Tabela 10 – <i>Downlink</i> : Coeficientes e RMSE para a altura de 6 m.	66
Tabela 11 – <i>Downlink</i> : Coeficientes e RMSE para a altura de 24 m.	66
Tabela 12 – <i>Downlink</i> : Coeficientes e RMSE para a altura de 60 m.	67
Tabela 13 – <i>Uplink</i> : Coeficientes e RMSE para a altura de 6 m.	67
Tabela 14 – <i>Uplink</i> : Coeficientes e RMSE para a altura de 24 m.	68
Tabela 15 – <i>Uplink</i> : Coeficientes e RMSE para a altura de 60 m.	68

Lista de abreviaturas e siglas

5G	Quinta Geração
ANATEL	Agência Nacional de Telecomunicações
4G	Quarta Geração
IoT	<i>Internet of Things</i>
eMBB	<i>enhanced mobile broadband</i>
URLLC	<i>ultra-reliable and low-latency communication</i>
mMTC	<i>massive machine-type communication</i>
NB-IoT	<i>Narrowband-IoT</i>
3GPP	<i>3rd Generation Partnership Project</i>
LPWAN	<i>Low-Power Wide-Area Networks</i>
LTE	<i>Long-Term Evolution</i>
FDMA	<i>Frequency Division Multiple Access</i>
OFDMA	<i>Orthogonal Frequency Division Multiple Access</i>
LoRaWAN	<i>Long-Range Wide-Area Network</i>
LoRa	<i>Long-Range</i>
ADR	<i>Adaptive Data Rate</i>
VANT	Veículo Aéreo Não Tripulado
RT	<i>Ray-Tracing</i>
RNA	Redes Neurais Artificiais
SNR	Relação Sinal-Ruído
A2G	<i>Air-Ground</i>
A2A	<i>Air-Air</i>
CRP	Canal de Rádio Propagação

LOS	Linha de Visada
NLOS	Sem Linha de Visada
RSSI	<i>Received Signal Strength Indicator</i>
SF	Fator de Espalhamento
PDR	Taxa de Entrega de Pacotes
RSS	<i>Received Signal Strength</i>
G2A	<i>Ground-Air</i>
G2G	<i>Ground-Ground</i>
FI	<i>Floating Intercept</i>
CSS	<i>Chirp Spread Spectrum</i>
FSK	<i>Frequency Shift Keying</i>
ISM	<i>Industrial Scientific and Medical</i>
BW	<i>Largura de Banda</i>
PMC	<i>Perceptrons de múltiplas camadas</i>
FBR	Funções de Bases Radiais
RNRG	Rede Neural de Regressão Generalizada
FDP	Função Densidade de Probabilidade
UFPA	Universidade Federal do Pará

Sumário

1	Introdução	15
1.1	Contextualização	15
1.2	Objetivos Gerais	16
1.3	Objetivos Específicos	17
1.4	Trabalhos Correlatos	17
1.5	Motivação	20
1.6	Estrutura do Trabalho	21
2	Fundamentação Teórica	22
2.1	Considerações Iniciais	22
2.2	Rádio propagação	22
2.2.1	Mecanismos de Propagação	22
2.2.1.1	Propagação no Espaço Livre	22
2.2.1.2	Reflexão	23
2.2.1.3	Difração	23
2.2.1.4	Espalhamento ou Dispersão	24
2.2.2	Modelos de Propagação	24
2.2.2.1	Modelos Teóricos	24
2.2.2.2	Modelos Empíricos	24
2.2.2.3	Modelo Okumura-Hata	25
2.2.2.4	Modelo <i>Floating Intercept</i>	26
2.3	Tecnologia LoRa	26
2.3.1	Modulação LoRa	27
2.3.2	Protocolo LoRaWAN	29
2.3.2.1	Arquitetura da Rede LoRa	29
2.4	Redes Neurais Artificiais	31
2.4.1	Neurônio Artificial	31
2.4.2	Redes de Funções de Bases Radiais	32
2.4.2.1	Rede Neural de Regressão Generalizada	33
2.5	Veículos Aéreo Não Tripulados	33
2.5.1	Classificação	33
2.5.1.1	Classificação com base no Peso Médio de Decolagem	34
2.5.1.2	Classificação com base na Autonomia do Veículo	34
2.5.2	Aplicações	35
2.6	Considerações Finais	35
3	Metodologia Proposta	36
3.1	Considerações Iniciais	36

3.2	Campanha de Medições	37
3.2.1	Equipamentos e Configurações	37
3.2.2	Cenário	37
3.2.3	Pré-Processamento dos Dados	39
3.2.3.1	Distância entre os Dispositivos LoRa	40
3.2.4	Dados Coletados	40
3.2.4.1	Rota 1	43
3.2.4.2	Rota 2	43
3.3	Treinamento da Rede Neural	45
3.4	Considerações Finais	46
4	Resultados	47
4.1	Considerações Iniciais	47
4.2	Modelos de Linha de Base	47
4.3	Modelo de Rede Neural	50
4.3.1	Rota 1	52
4.3.2	Rota 2	53
4.4	Considerações Finais	54
5	Conclusão	55
5.1	Trabalhos Futuros	55
5.2	Publicações	56
	 Referências	 57
	 Apêndices	 62
A	Apêndice A	62
B	Apêndice B	64
C	Apêndice C	66
D	Apêndice D	67

1 Introdução

1.1 Contextualização

A implantação da quinta geração (5G) de telefonia móvel em solo brasileiro já teve início, em Novembro de 2021, quando a Agência Nacional de Telecomunicações (ANATEL) realizou o leilão do 5G. Neste leilão, foi concedido às operadoras de telefonia móvel as licenças para exploração das faixas de frequência do 5G e a expectativa é de que até o final de Julho de 2022 todas as capitais já possuam acesso à tecnologia, gerando novos serviços e oportunidades de emprego para a população (ANATEL, 2022).

A tecnologia 5G é a sucessora da quarta geração (4G) de redes móveis e foi desenvolvida com o objetivo de conectar a tudo e todos (QUALCOMM, 2017) aprimorando as aplicações de *internet of things* (IoT). O 5G oferecerá suporte à serviços como *enhanced mobile broadband* (eMBB), *ultra-reliable and low-latency communication* (URLLC) e *massive machine-type communication* (mMTC).

O mMTC possui suporte à uma quantidade massiva de dispositivos IoT enviando dados de forma esporádica, para isso, o 5G utiliza a tecnologia *Narrowband-IoT* (NB-IoT), um padrão de radio desenvolvido pelo grupo 3rd Generation Partnership Project (3GPP) para *Low-Power Wide-Area Networks* (LPWAN) (RATASUK et al., 2016).

O NB-IoT, assim como no *Long-Term Evolution* (LTE), utiliza *Frequency Division Multiple Access* (FDMA) e *Orthogonal FDMA* (OFDMA) para as comunicações de *uplink* e *downlink* respectivamente. Esta tecnologia também faz uso de faixa de frequência licenciada beneficiando aplicações IoT que requerem comunicação mais frequente, pois não há limitação de *duty-cycle*, contudo o NB-IoT possui maior custo de implantação quando comparado a tecnologias como o *Long-Range Wide-Area Network* (LoRaWAN) (ABIRESEARCH, 2019).

O protocolo LoRaWAN, desenvolvido pela LoRa Alliance®, tem por objetivo fornecer conectividade em redes LPWAN, através de uma solução de baixo custo e longo alcance. O uso desta tecnologia em aplicações IoT tem aumentado e em 2019 atingiu a marca de 97 milhões de dispositivos Long-Range (LoRa) em circulação (ABIRESEARCH, 2019).

O protocolo faz uso do mecanismo, *adaptive data rate* (ADR) (ALLIANCE, 2015b), o qual altera a taxa e potência de transmissão de acordo com as condições do canal de comunicação, caracterizada pela relação sinal-ruído (SNR). Isto permite a utilização da tecnologia LoRa nos mais diversos cenários.

A tecnologia LoRa já é utilizada em diversas aplicações *outdoor* como monitoramento de plantações, vigilância, rastreamento e assistência médica (MARCHESE; MOHEDDINE; PATRONE,

2019). Além disso, considerando que o NB-IoT não será capaz de atender completamente os requisitos estabelecidos para o serviço mMTC do 5G, o protocolo LoRaWAN é uma alternativa que pode contribuir com o 5G, principalmente quando se considera aplicações IoT em locais remotos ou que não necessitem de baixa latência na transmissão (BOCKER et al., 2019).

Outra ferramenta utilizada nas aplicações acima mencionadas são os veículos aéreos não tripulados (VANT), e, com a chegada do 5G espera-se que esses veículos possam também atuar fornecendo auxílio para estabelecer enlaces de comunicação. Por exemplo, após a ocorrência de desastres naturais onde as estruturas terrestres dos sistemas de comunicação são prejudicadas e os usuários sofrem com perda de sinal e congestionamento da rede os VANTs podem ser utilizados como estações rádio base para fornecer conectividade (VALAVANIS, 2014).

Deste modo, as tecnologias LoRa e VANT podem ser utilizadas de forma conjunta para contribuir com os serviços do 5G mMTC e a cobertura das redes de comunicação, principalmente em locais de difícil acesso e regiões onde o sinal propagado se deteriora devido a presença de múltiplos obstáculos.

Para isto, é necessário entender de que forma o VANT impacta na propagação do sinal LoRa e o seu comportamento através do canal de comunicação. Existem duas formas tradicionais para realizar esta análise, a primeira utilizando métodos estocásticos com base em dados obtidos através de medições do sinal propagado pelo ambiente. A segunda utilizando métodos determinísticos como *Ray-Tracing* (RT), o qual requer uma modelagem detalhada do ambiente estudado (WU et al., 2020).

Além das técnicas tradicionais, as quais demandam tempo devido sua dificuldade de execução, também é possível fazer a análise do canal de comunicação através de técnicas heurísticas, como a rede neural artificial (RNA), uma ferramenta poderosa capaz de aproximar qualquer função (NIELSEN, 2015). Diante disso, este trabalho utiliza RNA para analisar a SNR do sinal LoRa propagado através do canal de comunicação, na frequência de 915 MHz, entre um VANT e um receptor em movimento, localizados em um ambiente suburbano densamente arborizado.

1.2 Objetivos Gerais

O objetivo geral deste trabalho é criar um modelo baseado em SNR que represente o canal de comunicação do sinal LoRa, na frequência de 915 MHz, entre um VANT e um veículo localizados em um ambiente densamente arborizado. Isto será feito a partir de medições para coletar os dados referentes a propagação do sinal LoRa. Em seguida, a partir dos dados coletados, analisar o impacto das árvores na propagação do sinal e treinar uma RNA para reprodução do comportamento do sinal propagado.

1.3 Objetivos Específicos

- Realizar campanhas de medições utilizando a tecnologia LoRa operando na frequência de 915 MHz em ambiente suburbano densamente arborizado, considerando LOS e NLOS;
- Treinar uma RNA com os dados medidos capaz de reproduzir o comportamento do sinal estudado.
- Estabelecer modelos *baseline* para verificar a viabilidade de utilização da RNA treinada;

1.4 Trabalhos Correlatos

Em (MOZAFFARI et al., 2019), os autores fornecem uma visão geral do estado da arte sobre VANTs aplicados à redes sem fio, investigando os principais desafios, aplicações e problemas em aberto. Adicionalmente, os autores apresentam a necessidade da investigação de modelos de propagação utilizando VANTs mais realísticos, considerando diversos ambientes e condições climáticas. Além disso, os autores indicam também a necessidade de modelos que considerem o desvanecimento em pequena escala para comunicações *Air-Ground* (A2G) e *Air-Air* (A2A).

Em (AHMAD; CHEEMA; FINLAY, 2020), é realizada uma pesquisa abrangente a respeito da modelagem do canal de radio propagação (CRP) para VANTs atuando como estações radio base, considerando modelagem a partir de medidas e simulações, cenários de uplink e downlink. Os autores descrevem lacunas em aberto nas pesquisas, casos de uso e os principais problemas existentes. Por exemplo, as modelagens do CRP para VANTs está limitada à áreas abertas com enlaces em linha de visada (LOS), em baixas altitudes, e possuem análise de desvanecimento em larga e pequena escala limitadas. Além disso, os autores apontam a importância de estudar os cenários em que o VANT está em mobilidade, pairando no ar, transmitindo e recebendo sinal em cenários de LOS e sem linha de visada (NLOS).

Os autores (GHAMARI et al., 2022) realizaram uma pesquisa extensiva relacionada as aplicações atuais para VANTs considerando casos de uso cívil e comercial, também são evidenciados os principais desafios e requisitos para a utilização dos mesmos em sistemas de comunicação. Além disso, os autores reforçam a importância da modelagem de canal utilizando VANTs visto que estes dispositivos possuem características únicas que os diferem da comunicação sem fio tradicional, somado a falta de modelos confiáveis para avaliação dos sistemas de comunicação sem fio utilizando estes veículos.

Os autores (GHAZALI; TEOH; RAHIMAN, 2021) agrupam em seu trabalho pesquisas que ilustram as principais tendências envolvendo o estudo de redes de comunicação LoRa baseadas em VANTs. Adicionalmente, os autores afirmam que este é um tema recente, que ainda possui muito a ser explorado. Outro ponto de destaque mencionado pelos autores é a quantidade limitada de pesquisas em que os dispositivos LoRa não estão em LOS, sendo necessário aprofundar-se neste tema.

A partir de dados medidos os autores (SUPRAMONGKONSET et al., 2021) estabelecem modelos para caracterização da perda de percurso na comunicação A2A, considerando o modelo de dois raios, com a reflexão em diversos tipos de solo, e uma modificação do modelo log-distance. Além do mais os autores realizam a análise para as tecnologias Wi-Fi (2.4 GHz) e LoRa (868 MHz). Contudo, a análise dos autores limitou-se a variação da altura do VANT receptor de 1 m à 10 m do solo e mantiveram a distância de 10 m entre os dois VANTs.

Os autores em (MOHEDDINE; PATRONE; MARCHESE, 2019) desenvolveram um *gateway* voador, cujo objetivo é ampliar a área de cobertura de um *gateway* IoT. Para isto, as tecnologias LoRa e LTE foram integradas à um VANT. Em seguida, um dispositivo LoRa envia dados de *Received Signal Strength Indicator* (RSSI), umidade e temperatura pelo canal de uplink. Por último, o *gateway* envia os dados recebidos via LoRa, através da interface LTE, para serem mostrados e analisados em um servidor. O estudo demonstra a viabilidade de combinar as tecnologias LoRa, VANT e LTE para incrementar a área de cobertura em locais onde os *gateways* terrestres não alcançam. Contudo, os autores não analisaram o cenário de *downlink* o canal de comunicação.

O objetivo dos autores em (PARK et al., 2018) é implementar um sistema de monitoramento de plantações e fazendas utilizando um *gateway* LoRaWAN voador. Desta forma, dois experimentos foram realizados: em um prédio de estacionamento e outro em uma fazenda de árvores. O primeiro teste mostrou a diminuição na velocidade de comunicação conforme o VANT se distanciava dos dispositivos LoRa. O segundo, na fazenda de árvores, demonstra a viabilidade de múltiplas conexões entre o *gateway* e muitos dispositivos LoRa. Contudo, assim como em (MOHEDDINE; PATRONE; MARCHESE, 2019), os autores em (PARK et al., 2018) somente analisaram o cenário de comunicação *uplink*.

Um modelo de radiopropagação para a rede LoRaWAN foi proposto por (CHALL; LAHOUD; HELOU, 2019). Os autores estudaram o ambiente da cidade de Beirut, Líbano, através de medidas de RSSI e SNR para situações *indoor* e *outdoor*, zonas urbanas e rural utilizando a frequência de 868 MHz e o fator de espalhamento (SF) 12. Os resultados demonstram a confiabilidade da rede LoRaWAN para diferentes aplicações IoT, alcançando 9 km de cobertura em áreas urbanas e até 47 km para a zona rural, levando em conta um limiar de 90% da taxa de entrega de pacotes (PDR). Contudo, os autores não modificaram os valores de SF, considerando apenas o qual possui a menor taxa de dados, o que, em alguns casos, pode não ser viável. Além disso, apenas a comunicação via *uplink* foi analisada pelos autores.

Os autores (DAMBAL et al., 2019) estudaram o comportamento da comunicação LoRa para ambientes urbanos, considerando situações *indoor* e *outdoor-indoor*, também levando em conta os efeitos da polarização das antenas na transmissão. Para o ambiente urbano, um VANT foi utilizado para aumentar a cobertura da transmissão. Segundo os autores a orientação da antena é crucial na *Received Signal Strength* (RSS) e as alturas de 25 m e 50 m de altura não impactam significativamente na RSS, mas se a antena transmissora estiver na orientação vertical, o sinal recebido se torna mais forte. Entretanto, os autores analisaram apenas um SF e restringiram o trabalho a examinar a comunicação *uplink*.

A maior parte dos estudos acima mencionado analisaram apenas uma direção de propagação, *dowlink* ou *uplink*. Levando em conta o princípio da reciprocidade (BALANIS, 2015), a propagação do sinal pode ser modelada analisando apenas um sentido e representar o canal de comunicação nos dois sentidos. No entanto, neste estudo o terreno não é isotrópico (SILVA et al., 2020), o caminho de propagação é composto de um conjunto de prédios, áreas abertas e zonas densamente arborizadas, deste modo o princípio da reciprocidade não pode ser utilizado. Consequentemente, é relevante a realização de um estudo do CRP considerando LOS e NLOS para redes sem fio com a utilização de VANTs nas mais diversas situações.

Quando considera-se as técnicas heurísticas, os autores (BRAGA et al., 2020) realizaram medições de potência recebida na frequência de 521 MHz em um ambiente híbrido cidade-rio para prever o campo elétrico através de uma RNA. Os autores em (BENMUS; ABOUD; SHATTER, 2015) também utilizam RNA para propor um modelo de perda de propagação a partir de valores de RSS medidos em três frequências diferentes: 900, 1800 e 2100 MHz.

De forma complementar, os autores (AYADI; ZINEB; TABBANE, 2017) propuseram um modelo de propagação para redes heterogêneas. Eles realizaram medições de potência recebida e treinaram uma RNA para prever a perda de propagação nas frequências: 450, 850, 1800, 2100 e 2600 MHz. Além disso, os autores (ROFI et al., 2021) coletaram dados de RSSI na frequência de 868 MHz em um ambiente tropical no cenário de downlink, em seguida, treinaram uma RNA para modelar a perda de propagação.

Ademais, em (DUANGSUWAN; JUENGGITTIKUL; MAW, 2021), os autores propõe a utilização de RNA e *support vector regression* para realizar a predição da perda de percurso para o canal de comunicação *Ground-Air* (G2A) considerando um cenário de fazendas inteligentes. Os resultados obtidos demonstram a viabilidade da utilização destas técnicas com acurácia de 97%. Contudo, os autores utilizaram a tecnologia Wi-Fi, a qual possui alcance limitado, para fazer a transmissão dos dados.

Os trabalhos acima expostos contrapuseram modelos de propagação clássicos, como, Okumura-Hata, Lee e SUI com modelos de RNA propostos para realizar a caracterização do ambiente. Os resultados mostram a melhor performance da RNA, provando a sua eficiência em prever a perda de propagação em diversas circunstâncias. A Tabela 1 a seguir ilustra o resumo das principais contribuições dos trabalhos citados.

Tabela 1 – Resumo das Contribuições dos Trabalhos Correlatos.

Referência	Tecnologia	Comunicação	Frequência	Cenário/Modelagem	Métrica
(SUPRAMONGKONSET et al., 2021)	Wi-Fi LoRa	A2A	2.4 GHz 868 MHz	Outdoor/Empírica	RSSI
(MOHEDDINE; PATRONE; MARCHESE, 2019)	LoRa	G2A	868 MHz	Outdoor/Empírica	RSSI
(PARK et al., 2018)	LoRa	G2A	915 MHz	Outdoor/Empírica	Não Mencionado
(CHALL; LAHOUD; HELOU, 2019)	LoRa	G2G	868 MHz	Indoor/Empírica Outdoor/Empírica	PDR RSSI SNR
(DAMBAL et al., 2019)	LoRa	G2G A2G	902 928 MHz	Indoor/Empírica Outdoor/Empírica	RSS
(SILVA et al., 2020)	TV Digital	G2G	VHF-UHF	Outdoor/Empírica	Campo Elétrico
(BRAGA et al., 2020)	TV Digital	G2G	521 MHz	Outdoor/Heurística	Campo Elétrico
(BENMUS; ABOUD; SHATTER, 2015)	Celular	G2G	900 MHz 1800 MHz 2100 MHz	Outdoor/Heurística	RSS
(AYADI; ZINEB; TABBANE, 2017)	Não Mencionado	G2G	450 MHz 850 MHz 1800 MHz 2100 MHz	Outdoor/Heurística	Potência Recebida
(ROFI et al., 2021)	LoRa	G2G	868 MHz	Outdoor/Heurística	RSSI
(DUANGSUWAN; JUENKITTIKUL; MAW, 2021)	Wi-Fi	G2A	2.4 GHz	Outdoor/Heurística	RSSI
Proposta do Autor	LoRa	G2A A2G	915 MHz	Outdoor/Heurística	SNR

Fonte: O Autor

Ao observar a Tabela 1, nota-se que dentre os seis trabalhos que estudaram a tecnologia LoRa, a frequência de 915 MHz foi analisada apenas por (PARK et al., 2018), além disso, a análise ficou restrita a comunicação G2A e a métrica de análise não foi mencionada. Adicionalmente, verifica-se que o trabalho proposto é o único a analisar ambos os sentidos de comunicação (G2A e A2G), somando-se ao trabalho (CHALL; LAHOUD; HELOU, 2019) como os únicos a utilizarem a SNR como métrica de estudo.

1.5 Motivação

Visto que a arborização urbana proporciona melhorias significativas na qualidade de vida de uma população, a mesma tem destaque em discussões sobre os problemas nas cidades (ALMEIDA; NETO, 2010). Deste modo, foi instituído pela Organização das Nações Unidas (ONU) a Década da Restauração de Ecossistemas 2021-2030, com os objetivos de conter a degradação e promover a restauração de ecossistemas (ZANDONAI, 2021).

Sendo assim, espera-se um aumento no número de regiões arborizadas em zonas urbanas, ocasionando em um impacto direto nos sistemas de telecomunicações a partir da criação de novas obstruções acarretando em novas zonas de sombreamento do sinal.

Desta maneira, a partir do que foi exposto anteriormente verifica-se a necessidade de analisar a propagação do sinal em ambientes densamente arborizados. Adicionalmente, visto que a tecnologia LoRa, objeto de estudo de diversos trabalhos, está em expansão e será responsável por mais da metade da conectividade por via não-celular (ABIRESEARCH, 2020), optou-se pela realização da análise de propagação do sinal desta tecnologia.

Ademais, os trabalhos correlatos demonstram a importância de realizar as análises considerando os cenários de transmissão G2A e A2G, em conjunto à necessidade de modelos de CRP mais realísticos considerando situações de LOS e NLOS utilizando VANTs.

1.6 Estrutura do Trabalho

- No Capítulo 2 é apresentada a base teórica para entendimento de como a onda eletromagnética se propaga pelo o meio, as peculiaridades do sinal LoRa, o protocolo LoRaWAN e o funcionamento de uma rede neural;
- No Capítulo 3 apresenta-se os equipamentos, configurações e o cenário em que foi realizada a coleta dos dados. Também é apresentada a metodologia utilizada para coleta e treinamento do modelo de rede neural proposto;
- No Capítulo 4 são apresentados os resultados de desempenho dos modelos de linha de base e do modelo de predição de SNR utilizando RNA;
- Por fim, no Capítulo 5 apresenta-se a conclusão do trabalho desenvolvido, assim como os resultados obtidos e os trabalhos futuros.

2 Fundamentação Teórica

2.1 Considerações Iniciais

Neste capítulo serão abordado os principais temas que auxiliaram no desenvolvimento da metodologia proposta, servindo como base teórica para entendimento do mesmo, também serão descritas as tecnologias e métricas de desempenho utilizadas no trabalho.

2.2 Rádio propagação

O entendimento da propagação de ondas eletromagnéticas, acústicas, de rádio e de luz é um dos pré-requisitos para o desenvolvimento dos serviços de telecomunicações, pois as mesmas são utilizadas para realizar a transmissão de informação (SIZUN, 2006). Deste modo, também é importante entender os mecanismos de propagação das ondas para o melhor entendimento dos resultados obtidos nessa dissertação.

2.2.1 Mecanismos de Propagação

As ondas direta e refletidas no solo são consideradas mecanismo básicos na propagação, além destes, também há a ocorrência de ondas espalhadas, refletidas, difratadas e a propagação através de objetos, dependendo do ambiente em que a onda se propaga (SILVA, 2021).

2.2.1.1 Propagação no Espaço Livre

A propagação através do espaço livre é utilizada como referência, considerada o cenário ideal para transmissão de informação em um sistema de comunicação sem fio. Este cenário é utilizado para a análise do comportamento do sinal entre um transmissor e receptor através da equação de Friis, dado um percurso em que não haja obstruções (RAPPAPORT, 2001). A equação de Friis, também conhecida como modelo de propagação no espaço livre, estima a potência recebida P_r à uma distância d do transmissor, vide equação 2.1.

$$P_r(d) = \frac{P_t G_t G_r \lambda^2}{(4\pi d)^2 L} \quad (2.1)$$

Onde, $P_r(d)$ é a potência recebida em Watts, P_t a potência utilizada na transmissão em Watts, G_t e G_r são os ganhos nas antenas transmissoras e receptoras, respectivamente, λ o comprimento da onda, L as perdas no sistema ($L \geq 1$), para $L = 1$ não há perdas no sistema, e d a distância em metros.

A partir da equação de Friis, pode-se calcular a perda de propagação do sinal, Pl através da equação 2.2.

$$Pl(d) = \frac{P_t}{P_r} = \frac{(4\pi d)^2 L}{P_t G_t G_r \lambda^2} \quad (2.2)$$

A equação 2.2 pode ser reescrita para a forma logarítmica, considerando um sistema sem perdas, a frequência da portadora em MHz e a distância entre o transmissor e receptor em km, a atenuação do sinal é dada por 2.3.

$$Pl_{dB}(d) = 20\log_{10}(f_{MHz}) + 20\log_{10}(d_{km}) - 10\log_{10}(G_t) - 10\log_{10}(G_r) - 32,44 \quad (2.3)$$

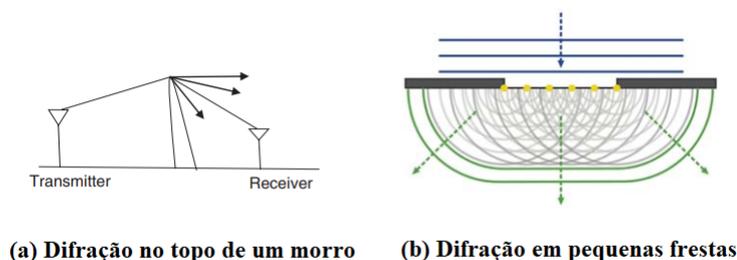
2.2.1.2 Reflexão

O fenômeno da reflexão ocorre quando uma onda eletromagnética colide contra um obstáculo de dimensões muito superiores ao seu comprimento de onda, geralmente, paredes, prédios, casas, dentre outros. Caso a onda incida sobre um dielétrico perfeito, parte da energia é transmitida para o segundo meio e parte é refletida de volta para o meio original, se o segundo meio for um condutor perfeito, neste caso, toda energia é refletida para o meio original. Deste modo, o raio refletido parcialmente ou totalmente, pode ocasionar uma interferência construtiva ou destrutiva no raio direto que chega ao receptor (RAPPAPORT, 2001).

2.2.1.3 Difração

Os efeitos da difração foram observados pela primeira vez por Francesco Maria Grimaldi, existem dois fenômenos que são explicados pela difração a ocorrência deles depende do tipo de obstáculo que a onda atravessa. O primeiro fenômeno é a habilidade de uma onda eletromagnética contornar obstáculos, como o topo de uma montanha. A difração também é responsável pela habilidade da onda de propagar através de pequenas aberturas como a grade de difração (SALOUS, 2013). A Figura 1 ilustra os dois fenômenos da difração.

Figura 1 – Fenômeno da Difração



Fonte: adaptado de (SALOUS, 2013)

2.2.1.4 Espalhamento ou Dispersão

O espalhamento ocorre quando a onda eletromagnética incide sobre um objeto cuja a dimensão é menor que o seu comprimento de onda. Quando isto ocorre, múltiplas pequenas reflexões do sinal são geradas, em alguns casos essa reflexão coincide com a direção do receptor (RAPPAPORT, 2001). Na prática as ondas dispersas são produzidas quando a onda incide sobre irregularidades presentes no canal, como folhagem, poste de iluminação, pequenos objetos e superfícies ásperas.

2.2.2 Modelos de Propagação

Os modelos de rádio propagação são utilizados para predizer o campo elétrico ou a potência que chega à um receptor. Com essas informações, é possível determinar as curvas de perda de propagação em larga escala, para o espaço livre utilizando a equação 2.3. Os modelos também podem descrever o comportamento da perda para cenários em que há obstruções, como construções e vegetações (RAPPAPORT, 2001). Os modelos são divididos em três grupos, determinísticos, utilizam apenas métodos teóricos, empíricos, baseados em medições e semi-determinísticos que combinam medições e teoria.

2.2.2.1 Modelos Teóricos

Estes são modelos constituídos a partir de formulações teóricas, como indicado pelo nome, as quais tem como fundamento suposições originadas a partir de dados coletados ou leis físicas. Alguns modelos teóricos não levam em consideração as características específicas do ambiente de estudo, ou seja, são modelos mais genérico. No entanto, existem modelos teóricos chamados de *site-specific* que fornecem um resultado mais preciso através da técnica de RT ao custo de um elevado poder computacional (CASTRO, 2010).

2.2.2.2 Modelos Empíricos

Um modelo empírico é criado com base em observações e medições. Desta forma, o modelo empírico é regido por uma equação elaborada para se ajustar aos dados medidos da melhor forma possível. Estes modelos estão vinculados ao local estudado, pois necessitam de informações como frequência de operação do sistema, alturas das antenas e características do ambiente para representar a perda de propagação com precisão. Além disso, diferente dos modelos de RT esses não necessitam de um elevado poder computacional (CASTRO, 2010), (RODRIGUES et al., 2005).

2.2.2.3 Modelo Okumura-Hata

O modelo Okumura-Hata foi elaborado após Okumura efetuar uma série de medições na cidade de Tokyo (OKUMURA, 1968). Este modelo é muito utilizado para o planejamento de redes celulares, sendo válido para frequências até 1500 MHz, estações base entre 30 e 200 metros, alturas do receptor entre 1 e 10 metros e distância da estação base até 100 km (PARSONS, 2001). O modelo Okumura-Hata é expresso pela equação 2.4.

$$L(\text{dB}) = 69,55 + 26,16\log(f_{\text{MHz}}) - 13,82\log(h_t) - a(h_r) + (44,9 - 6,55\log(h_t))\log(d_{\text{km}}) \quad (2.4)$$

Onde, L é a perda de propagação em dB para uma zona urbana; f é a frequência, em MHz; h_t é a altura do transmissor, em m; h_r é a altura do receptor, em m; d é a distância entre transmissor e receptor, em km; $a(h_r)$ é o fator de correção para a altura da antena em função do tipo de área, em dB.

Este modelo pode ser aplicado para áreas urbanas e rurais a partir das variações do termo $a(h_r)$, conforme os ajustes feitos por Hata e ilustrado nas equações 2.5, 2.6 e 2.7

- Para Cidades Pequenas e Médias

$$a(h_r) = (1,1\log(f_{\text{MHz}}) - 0,7)h_r - (1,56\log(f_{\text{MHz}}) - 0,8) \quad (2.5)$$

- Para Cidades Grandes

$$a(h_r) = 8,29(\log(1,54h_r))^2 - 1,1 \quad f < 300\text{MHz} \quad (2.6)$$

$$a(h_r) = 3,2(\log(11,75h_r))^2 - 4,97 \quad f \geq 300\text{MHz} \quad (2.7)$$

A partir da equação 2.8 é possível determinar a perda de percurso total para zona rural.

$$L_r = L - 4,78(\log(f_{\text{MHz}}))^2 + 18,33\log(f_{\text{MHz}}) - 40,94 \quad (2.8)$$

Para a zona suburbana é utilizada a equação 2.9, apresentada a seguir:

$$L_{su} = L - 2 \left(\log \left(\frac{f_{\text{MHz}}}{28} \right) \right)^2 - 5,4 \quad (2.9)$$

2.2.2.4 Modelo *Floating Intercept*

O modelo *Floating Intercept* (FI), também conhecido como modelo Alfa-Beta, é utilizado pelos padrões WINNERII e 3GPP para determinar a perda de percurso (KYÖSTI et al., 2008). Para isto, a âncora, determinada pela potência recebida na distância de referência, e o expoente de perda de propagação, são substituídos pelos parâmetros alfa e beta. O modelo FI é apresentado na equação 2.10 a seguir:

$$L(d)_{dB}^{FI} = \alpha + 10 \times \beta \log(d) + X_{\sigma} \quad (2.10)$$

Onde, α é o valor em dB para perda inicial; β é o expoente de perda de percurso e responsável pela inclinação da reta; X_{sigma} é uma variável aleatória com média zero e desvio padrão σ , ela é responsável por descrever as oscilações presentes no sinal em larga escala, sendo um parâmetro opcional da equação. Para encontrar o melhor ajuste dos dados ao modelo FI é necessário aplicar o método dos mínimos quadrados lineares, utilizando a notação matricial 2.11.

$$\mathbf{D} = \begin{bmatrix} 1 & d_n \\ \cdot & \cdot \\ \cdot & \cdot \\ \cdot & \cdot \\ 1 & d_o \end{bmatrix} \quad \mathbf{L} = \begin{bmatrix} l_n \\ \cdot \\ \cdot \\ \cdot \\ l_o \end{bmatrix} \quad \boldsymbol{\theta} = \begin{bmatrix} \alpha \\ \beta \end{bmatrix} \quad (2.11)$$

Onde, \mathbf{D} são os valores de distância medidos, \mathbf{L} é a perda de propagação medida associada à \mathbf{D} e $\boldsymbol{\theta}$ são os parâmetros que serão calculados. Para encontrar o valores de α e β utiliza-se a equação 2.12.

$$\boldsymbol{\theta} = ((\mathbf{D}^T \mathbf{D})^{-1}) \mathbf{D}^T \mathbf{L} \quad (2.12)$$

2.3 Tecnologia LoRa

A tecnologia LoRa foi desenvolvida pela SEMTECH para realizar transmissão sem fio de longo alcance. Esta é uma tecnologia proprietária e atua diretamente na camada física realizando a modulação do sinal, com uma técnica de espalhamento espectral derivada da técnica *Chirp Spread Spectrum* (CSS). O sinal modulado é espalhado por uma largura de banda, o que propicia maior resiliência do sinal à ruídos (SEMTECH, 2015).

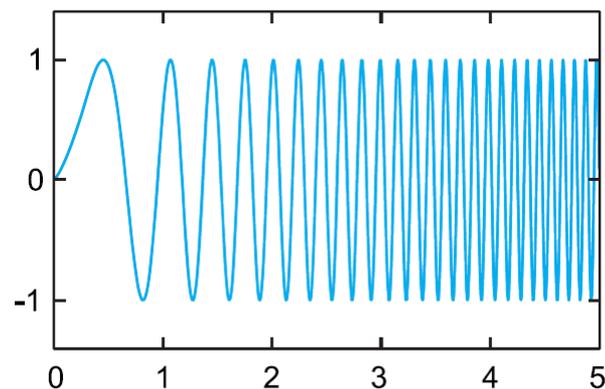
Em conjunto com a tecnologia LoRa existe o protocolo LoRaWAN, o qual atua na camada de enlace da rede LoRaWAN. Este protocolo não é proprietário e pode ser alterado de acordo com as necessidades do projeto em que os transceptores serão implementados.

2.3.1 Modulação LoRa

A modulação CSS utilizada pela tecnologia LoRa foi desenvolvida para uso em comunicações espaciais e militares na década de 1940 (ALLIANCE, 2015a). A modulação LoRa conserva as características de baixa potência da modulação *Frequency Shift Keying* (FSK) incrementando o alcance do sinal.

Na modulação CSS, o sinal senoidal possui amplitude constante, frequência variante no tempo e duração determinada possibilitando sua distribuição ao longo de toda banda de maneira uniforme. Esta distribuição do sinal garante ao sinal maior resistência à interferência e ruídos. Adicionalmente, a tecnologia oferece a possibilidade de balancear a sensibilidade de recepção e a taxa de transmissão através da utilização dos SFs (SEMTECH, 2019). A Figura 2 a seguir ilustra um sinal LoRa modulado, conhecido como *Chirp*, caso o mesmo possua uma frequência crescente é denominado *Up-Chirp*, se a frequência for decrescente, então se denomina *Down-Chirp*.

Figura 2 – Ilustração do sinal LoRa *Up-Chirp*



Fonte: (SEMTECH, 2019)

A tecnologia LoRa opera na faixa de frequências não licenciadas *Industrial Scientific and Medical* (ISM), compostas pelas faixas 433 MHz na Ásia e Europa, 868 MHz na Europa e 915 MHz no continente americano, facilitando a implementação e reduzindo os custos operacionais. No Brasil, a frequência de 915 MHz foi estabelecida para uso pela ANATEL, influenciando diretamente no alcance máximo de transmissão.

Um transceptor LoRa padrão possui ao todo cinco parâmetros que alteram o consumo energético, a resiliência à ruído e alcance máximo da transmissão. Potência de transmissão, ajustável entre 2 dBm e 14 dBm de acordo com o módulo; Frequência central da portadora entre 137 MHz e 1020 MHz, podendo variar com o modelo do dispositivo; Largura de Banda (BW), determina a faixa de frequência ocupada pelo sinal transmitido, uma BW elevada proporciona maior taxa de transmissão, contudo a sensibilidade de recepção é reduzida devido a adição de ruído no canal, os valores possíveis são 125 kHz, 250 kHz e 500 kHz (SOARES, 2019).

O sinal LoRa é um *chirp* espalhado na frequência, o pacote LoRa é constituído de um conjunto de *chirps* divididos em preâmbulo e informação útil, a duração de uma transmissão LoRa é determinada pelo tempo em que os dois levam para serem transmitidos, conforme visto na equação 2.13.

$$T_{pkt} = T_{pre} + T_{phy}, \quad (2.13)$$

onde T_{pkt} é o tempo no ar de um pacote, T_{pre} é o tempo de duração do preâmbulo e T_{phy} é o tempo de duração da informação útil que está sendo transmitida. O tempo de duração do preâmbulo é calculado de acordo com a equação 2.14.

$$T_{pre} = (N_{pre} + 4, 25) \times \frac{2^{SF}}{BW}, \quad (2.14)$$

onde N_{pre} é o número de preâmbulos enviados na transmissão e $\frac{2^{SF}}{BW}$ é o tempo de um símbolo T_{sym} , calculado de acordo com o SF e a largura de banda BW . O tempo de duração da transmissão da informação útil é visto na equação 2.15:

$$T_{phy} = (8 + \max[\text{ceil}[TEMP](CR + 4), 0]) \times T_{sym} \quad (2.15)$$

O CR é o *coding rate*, variando de 1 a 4 e variável $TEMP$ é definida na equação 2.16:

$$TEMP = \frac{(28 + 8PL + 16CRC - 4SF - 20IH)}{4(SF - 2DE)}, \quad (2.16)$$

onde, PL é o tamanho do payload em bytes; CRC é uma flag com valor 1 se utilizado a checagem cíclica de redundância e 0 caso o contrário; IH define se o cabeçalho é implícito (1) ou explícito (0); DE define se a otimização de taxa de dados está (1) ou não ativa (0) (SEMTECH, 2016).

Como visto nas equações 2.14 e 2.15, o tempo de um símbolo é importante pois ele está correlacionado à duração total da transmissão de uma mensagem LoRa. Adicionalmente o T_{sym} , está diretamente ligado à taxa de bits que podem ser transmitidos por segundo, expresso na equação 2.17 (SEMTECH, 2015).

$$R_b = SF \times \left(\frac{\left(\frac{4}{4+CR} \right)}{T_{sym}} \right) \text{ bits/s} \quad (2.17)$$

Desta forma, analisando a equação 2.17 para uma largura de banda constante, podemos observar a importância do parâmetro SF. Ao alterar o SF, verifica-se um incremento no T_{sym} o que ocasiona no aumento da probabilidade de colisões de pacotes, a redução da taxa de transmissão dos dados utilizando a tecnologia LoRa e a redução da sensibilidade de recepção expressa na equação 2.18 (NETO, 2020).

$$S_{rx} = -174 + \log_{10}(BW) + NF + SNR_{dB} \quad (2.18)$$

Onde, o termo constante refere ao ruído térmico presente no receptor; NF é a Figura de Ruído do receptor e SNR_{dB} é a relação sinal-ruído em decibéis, exigida pelo esquema de modulação. A Tabela 2 a seguir ilustra os níveis mínimos de sensibilidade para diferentes SF.

Tabela 2 – Parâmetros da rede LoRa para a largura de banda 125 kHz e diferentes valores de SF

SF	SNR (dB)	Sensibilidade (dBm)	Bit Rate (Bits/s)
7	-7.5	-123	5469
8	-10	-126	3125
9	-12.5	-129	1758
10	-15	-132	977
11	-17.5	-134.5	537
12	-20	-137	293

Fonte: Adaptado de (SEMTECH, 2015)

2.3.2 Protocolo LoRaWAN

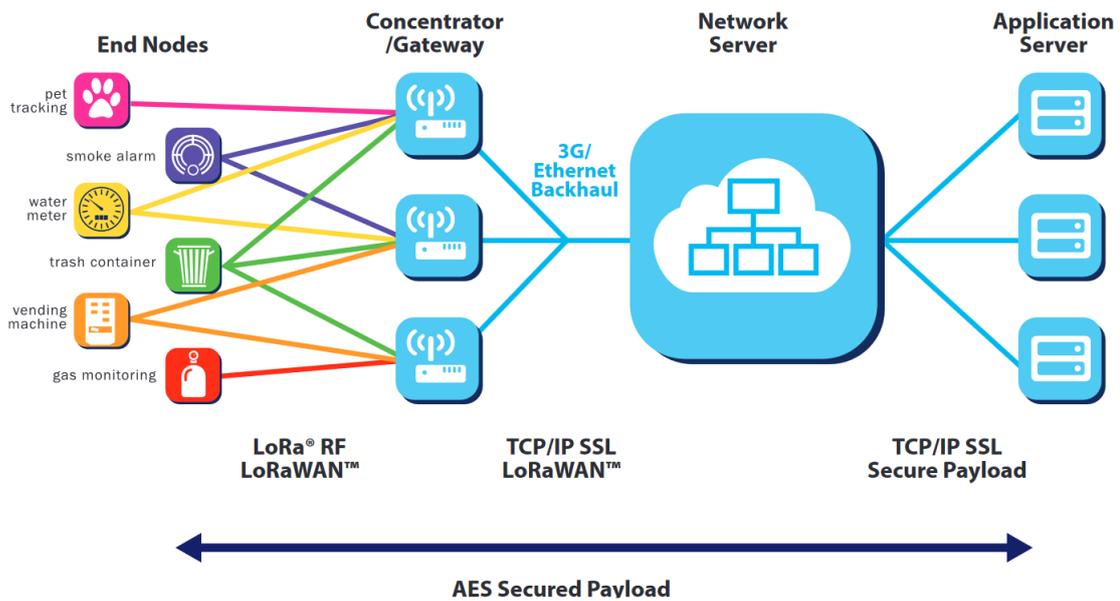
A camada física LoRa possibilita a criação de enlaces para comunicação de longo alcance. A terminologia LoRaWAN define o protocolo de comunicação e a arquitetura do sistema para a rede LoRa, o protocolo e arquitetura de rede em conjunto possuem grande influência sobre o tempo de vida da bateria de um dispositivo LoRa, a capacidade da rede, qualidade do serviço, segurança, entre outras aplicações que utilizam a rede (ALLIANCE, 2015a).

2.3.2.1 Arquitetura da Rede LoRa

O protocolo LoRaWAN utiliza a topologia estrela na sua arquitetura em detrimento da arquitetura *mesh*, utilizada por diversos protocolos IoT. Este uso é justificado pelo consumo energético reduzido da topologia estrela com longo alcance, pois esta não necessita de conexão constante entre todos os dispositivos da rede como observado na topologia *mesh* (ALLIANCE, 2015a).

A arquitetura de uma rede LoRaWAN geralmente é composta por quatro tipos de dispositivos. O primeiro tipo são os dispositivos IoT, conhecidos como *endnodes* ou nós, estes são os sensores e atuadores. O segundo tipo é composto pelos *gateways* estes recebem as informações enviadas utilizando a tecnologia LoRa e transferem para os servidores de rede, terceiro tipo de dispositivos, através de conexão *Internet Protocol* (IP). Por fim, os servidores de rede processam a informação e repassam para o quarto tipo de dispositivos, os servidores de aplicação. A Figura 3 ilustra a arquitetura da rede LoRa.

Figura 3 – Arquitetura da Rede LoRa



Fonte: (ALLIANCE, 2015a)

Dentro da arquitetura representada na Figura 3, os dispositivos IoT são divididos em três classes (A, B e C) diferentes de dispositivos, as quais consideram o balanceamento da vida útil da bateria e a latência de comunicação.

- **Classe A:** Dispositivos que permitem comunicação bi-direcional, onde cada transmissão de *uplink* (*endnode-gateway*) deve ser seguida de duas janelas de recepção de *downlink* (*gateway-endnode*) curtas. Os agendamentos das transmissões é feito utilizando o protocolo ALOHA, ademais, a classe A é composta pelos sistemas com menor consumo energético, utilizados especialmente em aplicações que não demandam muitas comunicações *downlink* (AUGUSTIN et al., 2016).
- **Classe B:** Os dispositivos desta classe possuem janelas de recepção extras que são abertas em horários específicos. Para que as recepções extras possam ocorrer, os dispositivos da classe B recebem do *gateway* avisos sincronizados no tempo permitindo que o servidor saiba quando o *endnode* está escutando (AUGUSTIN et al., 2016).
- **Classe C:** Estes dispositivos são os quais possuem a maior capacidade energética, isto possibilita que eles possam escutar o canal de comunicação de forma contínua, com baixa latência nas transmissões *downlink* (AUGUSTIN et al., 2016).

2.4 Redes Neurais Artificiais

As redes neurais artificiais (RNA) tem como base o cérebro humano, um sistema altamente complexo, não-linear e de computação paralela para processamento de informação. Ele tem a capacidade de organizar seus neurônios para realizar diferentes tarefas como atividades motoras e reconhecimento de padrões, em velocidade muito superior que os computadores existentes (HAYKIN, 2009).

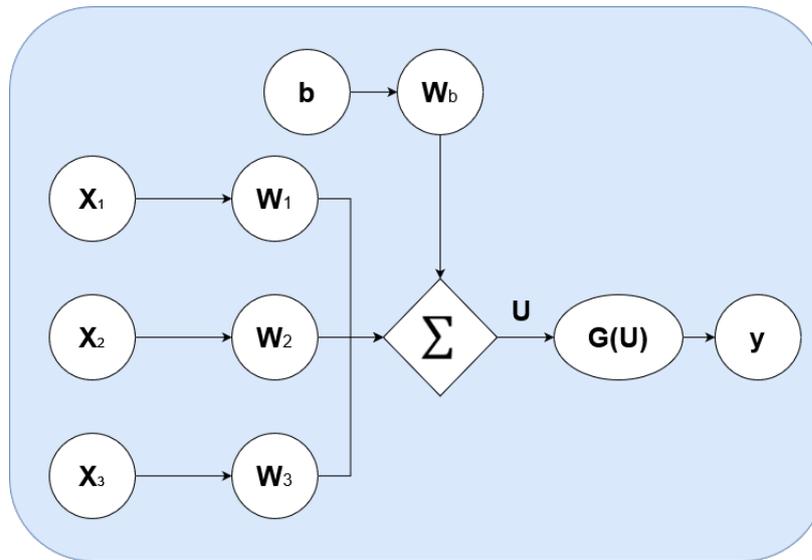
Dessa forma, as RNA são modelos computacionais com capacidade de aquisição e manutenção de conhecimento, inspiradas no sistema nervoso dos seres vivos, funcionam como um conjunto de unidades de processamento, neurônios artificiais, interligados por sinapses artificiais, representadas por matrizes e vetores de pesos sinápticos (SILVA, 2010). As principais características da rede neural são apresentadas a seguir:

- **Não-Linearidade:** Um neurônio artificial pode ou não ser linear, caso ele não seja linear, essa característica é propagada por toda a rede neural. Esta característica é importante, pois em muitas aplicações do cotidiano os sinais de entrada da rede são não-linear (HAYKIN, 2009).
- **Mapeamento de Entrada e Saída:** A partir da aprendizagem supervisionada, onde um conjunto de treino é apresentado à rede contendo diversas amostras rotuladas com o sinal de entrada e a respectiva saída desejada, os pesos sinápticos são atualizados para que a rede aprenda a realizar o mapeamento de entradas e saídas de forma aproximada à uma inferência estatística não-paramétrica (HAYKIN, 2009).
- **Adaptabilidade:** A RNA é capaz de se adaptar ao ambiente, uma RNA treinada para operar em um ambiente, pode ser re-treinada para se adequar a pequenas alterações no ambiente de operação, pois os seus pesos sinápticos possuem uma capacidade de adaptação intrínseca (HAYKIN, 2009).
- **Tolerância a Falhas:** Quando a conexão entre neurônios da RNA apresenta uma falha, o funcionamento da mesma não fica comprometido. As falhas de conexão entre neurônios ocasionam em uma leve degradação da sua performance, ao invés de uma falha geral na RNA, devido a natureza distributiva da informação contida nos neurônios (HAYKIN, 2009).

2.4.1 Neurônio Artificial

Os neurônios artificiais (*Perceptrons*) presentes nos modelos de RNA são não-lineares e realizam funções simples, a partir de sua função de ativação inerente, eles geram uma resposta contínua com base nos sinais agrupados e coletados em suas entradas (SILVA, 2010). A seguir a Figura 4 ilustra um neurônio artificial.

Figura 4 – Neurônio Artificial



Fonte: adaptado de (SILVA, 2010)

Desta forma, ao analisar a Figura 4 verifica-se que o neurônio artificial é composto de sete elementos. Os sinais de entrada (X_1, X_2, X_3), os pesos sinápticos (w_1, w_2, w_3, w_b), o agregador (Σ), o bias (b), o potencial de ativação (U), a função de ativação (G) e o sinal de saída (y). As equações 2.19 e 2.20 a seguir demonstram o cálculo do sinal de saída de um neurônio.

$$U = \sum_{i=1}^n w_i \cdot X_i + (b \cdot w_b) \quad (2.19)$$

$$y = G(U) \quad (2.20)$$

O conjunto de *perceptrons* formam as RNA, as quais são caracterizadas pelas suas arquiteturas, estas podem ser recorrente ou realimentada, *feedforward* de camada simples ou *feedforward* de múltiplas camadas. Dentre as redes *feedforward* de múltiplas camadas, os principais tipos são as redes *perceptrons* de múltiplas Camadas (PMC) e as redes de funções de bases radiais (FBR). Para este trabalho optou-se pela utilização de uma rede FBR chamada de rede neural de regressão generalizada (RNRG).

2.4.2 Redes de Funções de Bases Radiais

As redes FBR, são aplicadas em quase todos os tipos de problemas abordados pela rede PMC. Em contraste às redes PMC, as quais são compostas por inúmeras camadas intermediárias, a estrutura de uma rede FBR é constituída de apenas uma camada intermediária, cuja as funções de ativação dos neurônios são do tipo gaussiana (SILVA, 2010).

2.4.2.1 Rede Neural de Regressão Generalizada

A RNRG é um método para estimar a função densidade de probabilidade (FDP) conjunta dado um conjunto de treinamento. Visto que a FDP é gerada a partir das características dos dados sem pré-conceitos devido à sua forma, o sistema se torna perfeitamente geral. Não há problemas se a função é composta por múltiplas regiões gaussianas disjuntas em qualquer número de dimensões ou distribuições mais simples (WASSERMAN, 1993).

A principal vantagem da RNRG sobre as redes neurais tradicionais, como a PMC, é o tempo de treinamento reduzido, o que justifica sua escolha para modelagem e controle de sistemas dinâmicos. Ademais, a RNRG possui menos erros de teste quando comparada a PMC, o que confirma sua maior capacidade de generalização (AL-MAHASNEH et al., 2018). A equação 2.21 representa a saída da rede RNRG.

$$y_j = \frac{\sum_{i=1}^n (h_i \cdot w_{ij})}{\sum_{i=1}^n h_i} \quad (2.21)$$

Onde, y_j é o valor estimado da função, w_{ij} é a saída desejada para o vetor de treino x_i e saída y_j ; $h_i = e^{-\frac{D_i^2}{2\sigma^2}}$ é a saída dos neurônios na camada oculta; $D_j^2 = (x - u_i)^T(x - u_i)$ é a distância quadrática entre o vetor de treino u_i e o vetor de entrada x ; i é o centro do neurônio i e σ é a constante responsável pelo controle do tamanho da região receptiva.

2.5 Veículos Aéreo Não Tripulados

Os veículos aéreo não tripulados (VANT) tem se tornado tópico de diversas pesquisas nos últimos anos (MOHEDDINE; PATRONE; MARCHESE, 2019; PARK et al., 2018; DAMBAL et al., 2019; SUPRAMONGKONSET et al., 2021; DUANGSUWAN; JUENGGITTIKUL; MAW, 2021; MARCHESE; MOHEDDINE; PATRONE, 2019), isto ocorre devido à ampla gama de aplicações nas quais estes podem ser utilizados, sua autonomia e flexibilidade. Sendo assim, é importante saber selecionar de forma adequada o veículo de acordo com a aplicação utilizada.

2.5.1 Classificação

Estes veículos podem ser classificados de diversas formas e geralmente são divididos em categorias distintas para auxiliar no processo de regulamentação. Sendo assim, cada categoria possui requisitos específicos que o VANT precisa atender para estar apto a voar, de forma similar ao que ocorre atualmente para aviação tradicional com veículos tripulados.

2.5.1.1 Classificação com base no Peso Médio de Decolagem

A primeira forma de classificar é através do peso médio de decolagem do VANT, o qual está diretamente relacionado com a energia gerada durante uma possível queda do veículo. Este é considerado o primeiro fator que afeta a segurança das operações com VANTs (WEIBEL; HANSMAN, 2004), a seguir na Tabela 3 são apresentadas as diferentes categorias de VANTs.

Tabela 3 – Categorização dos VANTs

	Massa (kg)	Alcance (km)	Altura de Vôo (m)	Resistência (h)
Micro	<5	<10	250	1
Mini	<20/25/30/150*	<10	150/250/300	<2
Tactical				
Close Range (CR)	25 - 150	10 - 30	3.000	2 - 4
Short Range (SR)	50 - 250	30 - 70	3.000	3 - 6
Medium Range (MR)	150 - 500	70 - 200	5.000	6 - 10
MR Endurance (MRE)	500 - 1.500	>500	8.000	10 - 18
Low Altitude Deep Penetration (LADP)	250 - 2.500	>250	50 - 9.000	0.5 - 1
Low Altitude Long Endurance (LALE)	15 - 25	>500	3.000	>24
Medium Altitude Long Endurance (MALE)	1.000 - 1.500	>500	3.000	24 - 48
Strategic				
High Altitude Long Endurance (HALE)	2.500 - 5.000	>2.000	20.000	24 - 48
Stratospheric (Strato)	>2.500	>2.000	>20.000	>48
Exo-Stratospheric (EXO)	TBD	TBD	>30.500	TBD
Special Task				
Unmanned Combat AV (UCAV)	>1.000	1.500	12.000	2
Lethal (LET)	TBD	300	4.000	3 - 4
Decoys (DEC)	150 - 250	0 - 500	50 - 50.000	<4

*Varia de acordo com a legislação nacional

Fonte: Adaptado de (VALAVANIS, 2014)

2.5.1.2 Classificação com base na Autonomia do Veículo

Também é possível classificar o VANT de acordo com o seu nível de autonomia o qual varia de 0, veículo controlado remotamente, à 10, VANT completamente autonomo estes níveis são definidos com base nos seguinte requisitos, consciência situacional, capacidade de realizar análises, coordenação, tomada de decisão e capacidade operacional (CLOUGH, 2002). A Tabela 4 representa os possíveis *Autonomous Control Levels* (ACL).

Tabela 4 – Categorização dos VANTs de acordo com os possíveis ACL

ACL	Descrição do Level
0	Veículo Pilotado de Forma Remota
1	Veículo Executa Missões Pré-Planejadas
2	Missões Variáveis
3	Resposta robusta a falhas em tempo real
4	Veículo adaptável a falhas
5	Coordenação de múltiplos veículos em tempo real
6	Cooperação de múltiplos veículos em tempo real
7	Conhecimento do espaço de batalha
8	Consciência do espaço de batalha
9	Consciência de enxame do espaço de batalha
10	Veículo completamente autônomo

Fonte: Adaptado de (VALAVANIS, 2014)

2.5.2 Aplicações

Inicialmente os VANTs eram utilizados exclusivamente em aplicações militares, sendo os Micro e Mini VANTs muito utilizados em tarefas de reconhecimento para curtas distâncias devido a sua praticidade de utilização e transporte estes possuem menor capacidade da distância em que podem viajar e geralmente são utilizados em LOS com a estação de controle terrestre. Para VANTs maiores as principais aplicações estão relacionadas à tarefas de reconhecimento, vigilância e inteligência em regiões marítimas, estes também podem ser utilizados durante operações para detecção de explosivos (VALAVANIS, 2014).

Quando se considera as aplicações civís, estes veículos podem ser utilizados para busca e resgate, suporte de infraestrutura, fotografias aereas, monitoramento de ambientes e auxiliar em crisis na busca por sobreviventes (VALAVANIS, 2014). Além dessas aplicações, também é possível utilizá-los no transporte de encomendas e no estabelecimento de enlaces de comunicações atuando como estações rádio base provendo conectividade de baixo custo para localidades onde há uma infraestrutura celular limitada (MOZAFFARI et al., 2019).

2.6 Considerações Finais

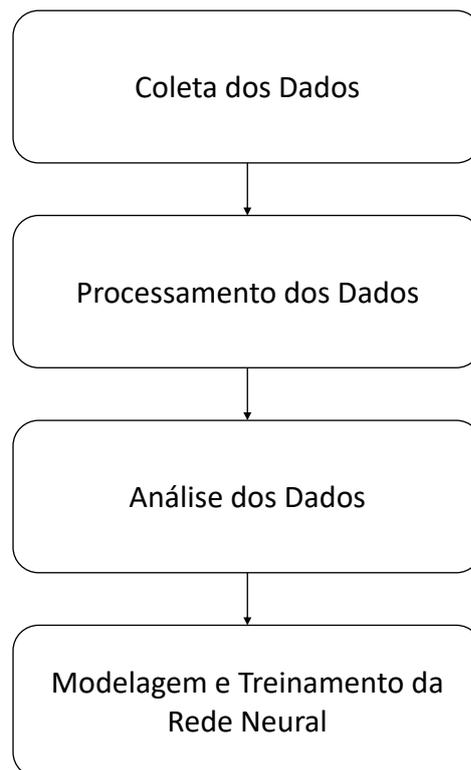
Neste capítulo, os principais temas para auxílio do desenvolvimento da metodologia proposta foram expostos, os conceitos de radio propagação, mecanismos e modelos de propagação, o funcionamento da tecnologia LoRa e do protocolo LoRaWAN, os conceitos fundamentais de redes neurais além de abordar também as possíveis classificações dos veículos aéreos não tripulados e suas aplicações¹.

3 Metodologia Proposta

3.1 Considerações Iniciais

Neste capítulo será apresentada a metodologia utilizada para desenvolvimento da pesquisa, conforme exibido na Figura 5. Começando pela coleta dos dados, onde serão descritos os equipamentos utilizados e o cenário em que ocorreram as campanhas de medições, a seguir no processamento dos dados o cálculo feito para determinar a distância entre os transceptores, após o processamento é possível realizar a análise dos dados coletados e por fim, será explicado de que forma a rede neural foi modelada e como ocorreu o seu treinamento.

Figura 5 – Metodologia de Medição



Fonte: O Autor

3.2 Campanha de Medições

A campanha de medição para coleta dos dados que descrevem a propagação do sinal irradiado no canal aéreo-terrestre e terrestre-aéreo em um meio densamente arborizado, utilizando a tecnologia LoRa em conjunto de um VANT.

3.2.1 Equipamentos e Configurações

Para realizar a pesquisa, optou-se pela utilização da plataforma *open-source* de eletrônica e prototipagem, Arduino. Para realizar a comunicação entre os microcontroladores, foram utilizadas duas antenas helicoidais e omnidirecionais, dois *shields* LoRa Dragino, os quais utilizam o chip *sx1276* da SEMTECH e o protocolo LoRaWAN. Além disso, também foi utilizado um automóvel, para locomoção ao longo das rotas, e VANT modelo Inspire 1.

Durante a coleta dos dados, o VANT atuou como *gateway* LoRa enquanto que uma haste com o LoRa Dragino foi acoplada ao veículo à uma altura de 3m. Ambos os dispositivos recebiam e enviavam mensagens, o que viabilizou a análise dos canais de *downlink* e *uplink*. O VANT foi posicionado em quatro alturas diferentes 6m, 24m, 42m e 60m, enquanto que o automóvel se locomoveu em uma velocidade constante de 35 km/h.

Adicionalmente, visto que o tempo no ar de um pacote LoRa é variável, optou-se por fixar o intervalo de transmissão em 2 segundos, deste modo o tempo no ar é respeitado para todos os valores de SF. O intervalo de 2 segundos foi selecionado de acordo com o maior tempo no ar referente ao SF 12, desta forma considerando a velocidade de 35 km/h coletou-se uma amostra a cada 20 metros aproximadamente. A Tabela 5 define as demais configurações utilizadas na transmissão.

Tabela 5 – Configurações utilizadas na transmissão.

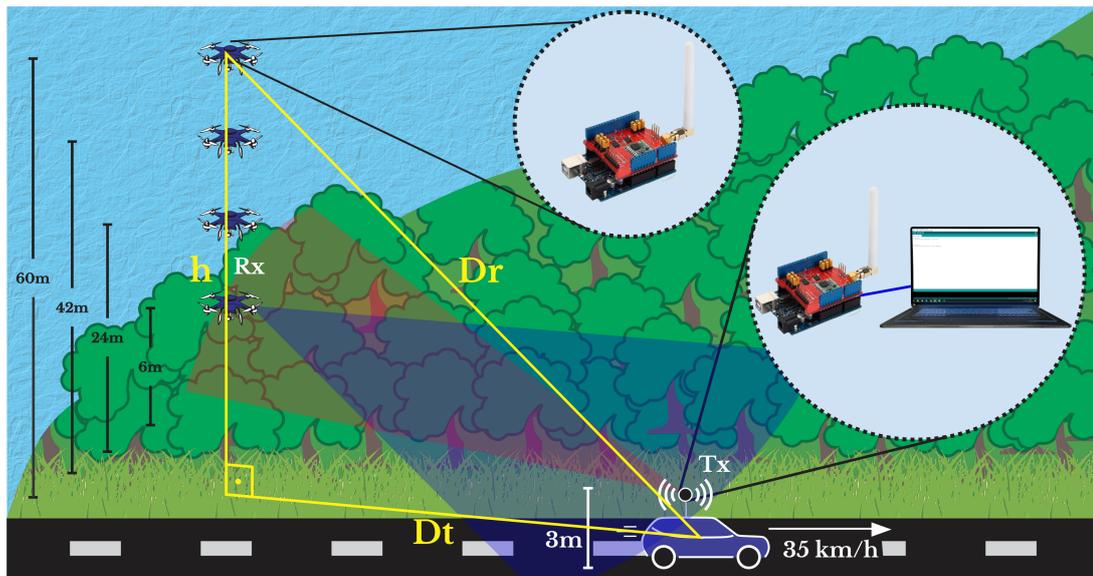
Frequência de Operação	915 MHz
Potência de Transmissão	20 dBm
Spreading Factor	8,9,10,11
Largura de Banda	500 KHz
Coding Rate	4/5

Fonte: O Autor

3.2.2 Cenário

A campanha de medições foi realizada em Belém, na Universidade Federal do Pará (UFPA), um local constituído de prédios e densamente arborizado às margens do rio Guamá. A Figura 6 ilustra a metodologia utilizada para medição, na qual o automóvel estava em movimento e o VANT em um ponto fixo com altura variável.

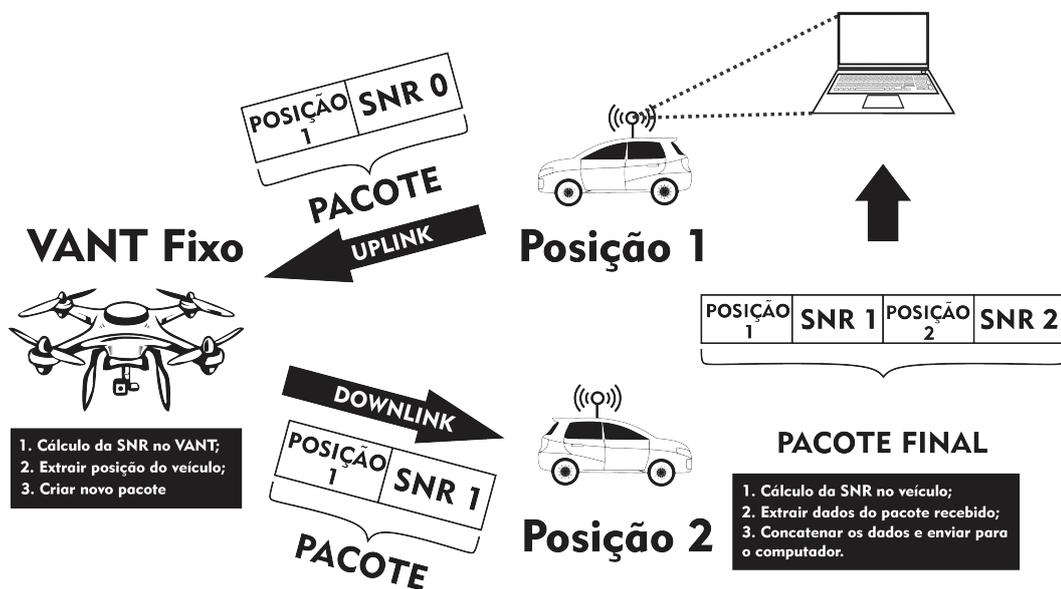
Figura 6 – Metodologia de Medição



Fonte: (CARDOSO et al., 2022)

Onde, h é a altura do VANT em relação ao solo, D_t é a distância terrestre e D_r é a distância rádio entre o automóvel e o VANT. Em seguida a Figura 7 apresenta a lógica utilizada para comunicação e armazenamento das informações coletadas.

Figura 7 – Configuração para Transmissão e Coleta das Informações



Fonte: adaptado de (CARDOSO et al., 2022)

O processo é inicializado com a informação de posição do carro sendo enviada para o VANT através da tecnologia LoRa (*uplink*), após o recebimento do pacote o *Gateway* LoRa, acoplado ao VANT, realiza o cálculo da SNR referente a este pacote e extrai a posição do carro para associar com o valor de SNR calculado. Em seguida, um novo pacote é criado com as informações de SNR e posição do carro e enviado de volta para o automóvel (*downlink*).

Quando o pacote é recebido no automóvel, a sua posição é coletada e o mesmo procedimento é realizado, extração das informações contidas no pacote e calculo da SNR referente a pacote recebido. Por fim, as informações coletadas são enviadas via comunicação serial para armazenamento no computador. A Figura 8 ilustra o automóvel utilizado na campanha de medição com o transmissor acoplado a haste.

Figura 8 – Automóvel percorrendo a rota



Fonte: (CARDOSO et al., 2022)

O carro percorreu duas rotas dentro da UFPA, ilustradas na Figura 9, para realizar a coleta de dados. A primeira rota possui aproximadamente 680m de distância e está representada em azul, enquanto que a segunda rota possui 1050m e está representada em amarelo. Os círculos vermelhos presentes na imagem destacam a área arborizada. Para cada rota foram efetuadas quatro medições por SF e altura do VANT, totalizando 128 medições.

Figura 9 – Rotas de Medição



Fonte: Adaptado de (CARDOSO et al., 2022)

3.2.3 Pré-Processamento dos Dados

Após a realização da campanha de medições, foi necessário analisar os dados para calcular a perda de propagação através da equação 2.2 e a distância entre o VANT e o automóvel, métricas utilizadas como entrada da rede neural.

3.2.3.1 Distância entre os Dispositivos LoRa

As coordenadas geográficas são utilizadas para calcular a distância entre o carro e o VANT, os valores de latitude e longitude obtidos são aplicados à equação 3.1 baseada na equação de Haversine.

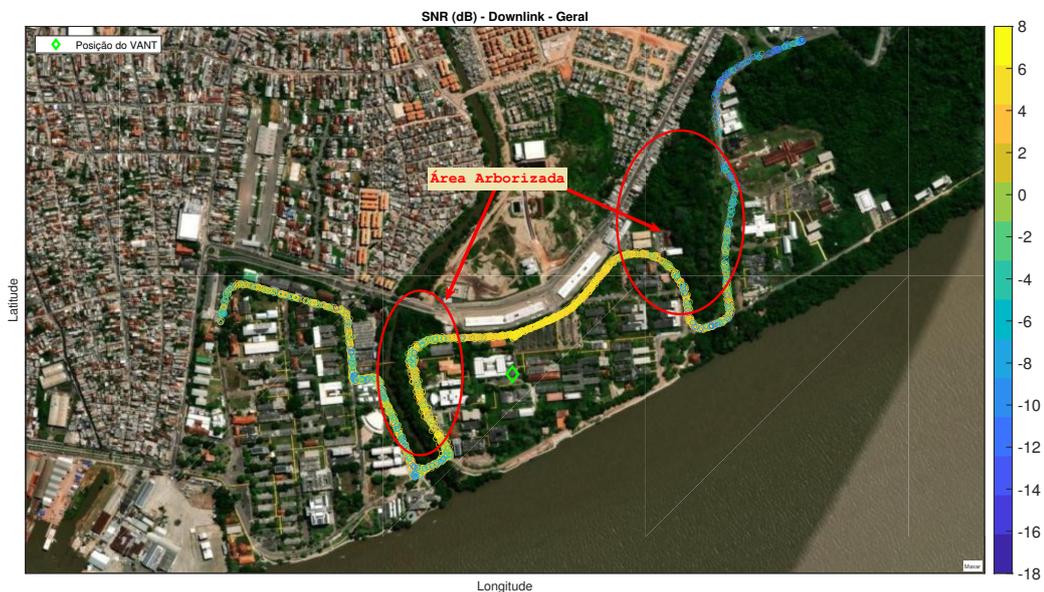
$$D_r = \sqrt{(2r \arcsin\left(\sqrt{\sin^2\left(\frac{\varphi_2 - \varphi_1}{2}\right) + \cos(\varphi_1) \cos(\varphi_2) \sin^2\left(\frac{\lambda_2 - \lambda_1}{2}\right)}\right))^2 + h^2}, \quad (3.1)$$

Onde φ_1 , λ_1 representam a latitude e longitude do ponto 1; φ_2 , λ_2 representa a latitude e longitude do ponto 2; h é a altura do VANT em relação ao solo; D_r é a distância rádio entre os transceptores e r é o raio da terra em metros (6,371,000m).

3.2.4 Dados Coletados

Como dito previamente, foram realizadas 128 medições sendo 4 medições para cada SF e cada altura do VANT, ao todo foram coletadas 3614 amostras divididas entre *uplink* e *downlink*. A Figura 10 ilustra a distribuição de todos os dados de *downlink* pelas rotas.

Figura 10 – Dados de *Downlink*



Fonte: Adaptado de (CARDOSO et al., 2022)

A partir da análise da Figura 10, pode-se observar que os valores de SNR medidos reduzem conforme o automóvel se afasta do VANT, localizado aproximadamente no centro das duas rotas, os valores de SNR medidos estão na faixa de -18 dB à 8 dB. As regiões em amarelo representam áreas onde o sinal é mais forte, enquanto que as regiões em azul representa áreas onde o sinal é mais fraco, ou seja, possui valores de SNR próximos ao limiar de demodulação descrito no datasheet (SEMTECH, 2016), o qual varia de acordo com o SF entre -10 dB e -17,5

dB (SF8-SF11). A Figura 11, a seguir, ilustra a distribuição de todos os dados para a situação de *uplink* ao longo das rotas.

Figura 11 – Dados de *Uplink*



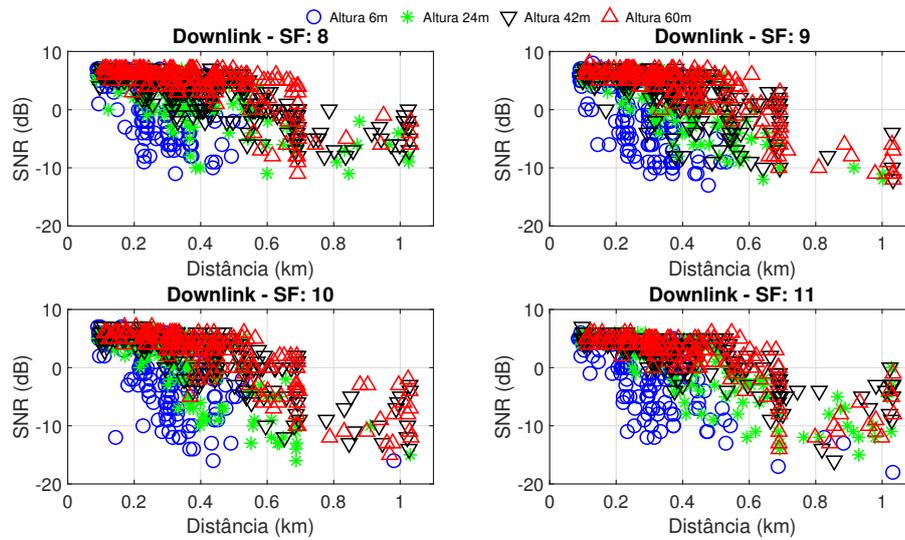
Fonte: Adaptado de (CARDOSO et al., 2022)

Para o cenário de *uplink*, o comportamento se mantém o mesmo do cenário de *downlink*. Além disso, é possível observar que em alguns pontos ao longo das rotas o sinal de *uplink* sofre atenuação, destacado pela drástica redução no alcance do sinal. Em ambas as rotas, a área arborizada (representada pelos círculos vermelhos) possuem um impacto considerável na recepção do sinal. Para a rota 1, o sinal recebido se torna intermitente logo após atravessar a região arborizada e para a rota 2 o impacto das árvores fica ainda mais evidente, visto que o sinal desaparece após a área arborizada.

Outro ponto de destaque são os locais em que os menores valores de SNR foram encontrados, atrás das regiões arborizadas. Nestes locais, as árvores foram responsáveis por obstruir o sinal entre o transmissor e o receptor, principalmente nos pontos em que a vegetação era mais densa. O menor valor de SNR medido foi de 0 dB, na altura de 42m, ilustrados pelos triângulos de cor magenta na Figura 11. Na análise de *uplink*, em específico, devido a atenuação e espalhamento do sinal ocasionado pelas árvores, não foram coletados valores de SNR negativos, pois o nível de SNR estava abaixo dos limiares estabelecidos no datasheet do transceptor LoRa sx1276 (SEMTECH, 2016).

A Figura 12 representa todos os dados coletados para a análise de *downlink*, ao visualizar a figura, pode-se observar a SNR reduzindo de acordo com a distância entre o automóvel e o VANT, a altura e o SF utilizados. Conseqüentemente, a área de cobertura varia de acordo com esses parâmetros, para uma altura de 6 m o alcance do sinal ficou em torno de 500 m, enquanto que para outros valores foi possível realizar a comunicação ao longo de toda a rota.

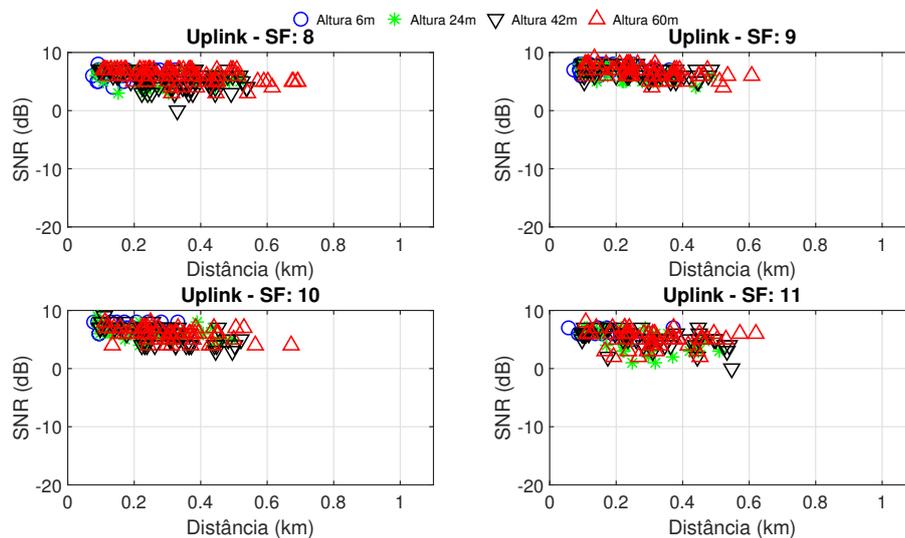
Figura 12 – Downlink: SNR x Distância



Fonte: Adaptado de (CARDOSO et al., 2022)

Para a situação de *uplink*, ilustrado na Figura 13, ao analisar o posicionamento do *gateway* verificou-se que a altura de 6 m é inviável para prover cobertura aos *endnodes*, poucos dados foram coletados e o alcance ficou entorno de 400 m. Adicionalmente, quando se observa as outras alturas foi obtido um alcance de 600 m, sendo possível prover cobertura para o setor profissional inteiro da UFPA, o comportamento do sinal se manteve similar para todos os SFs.

Figura 13 – Uplink: SNR x Distância

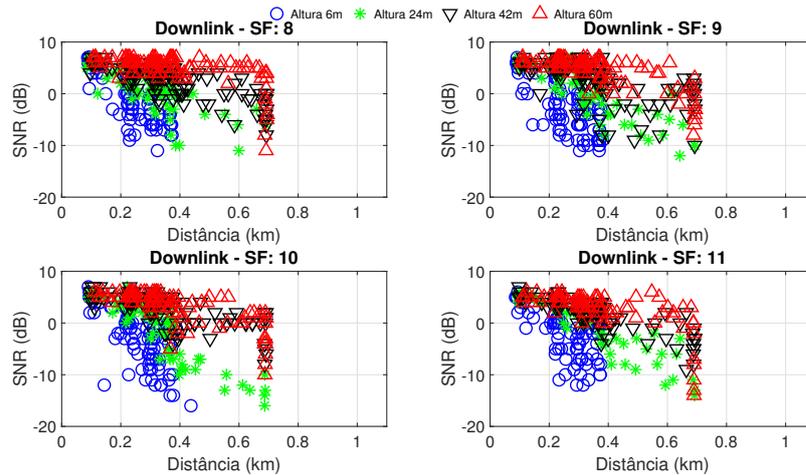


Fonte: Adaptado de (CARDOSO et al., 2022)

3.2.4.1 Rota 1

As Figuras 14 e 15 ilustram os pontos coletados para rota 1. Na análise de *downlink*, Figura 14, observa-se que o comportamento caótico do sinal se deve principalmente as medidas efetuadas à 6 m de altura, pois o enlace entre os dois transceptores se encontrava obstruídos por diversos prédios presentes na UFPA.

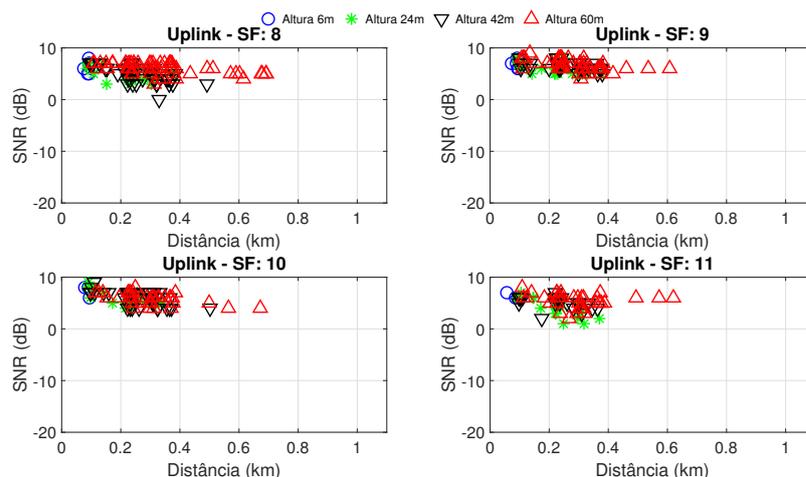
Figura 14 – *Downlink*: SNR x Distância



Fonte: O Autor

Do mesmo modo, ao analisar o *uplink*, Figura 15, observa-se que para a altura de 6 m o sinal não conseguiu atravessar os prédios e chegar ao *gateway* no VANT após os 100 primeiros metros da rota, ao todo foram coletados 21 amostras nessa altura.

Figura 15 – *Uplink*: SNR x Distância



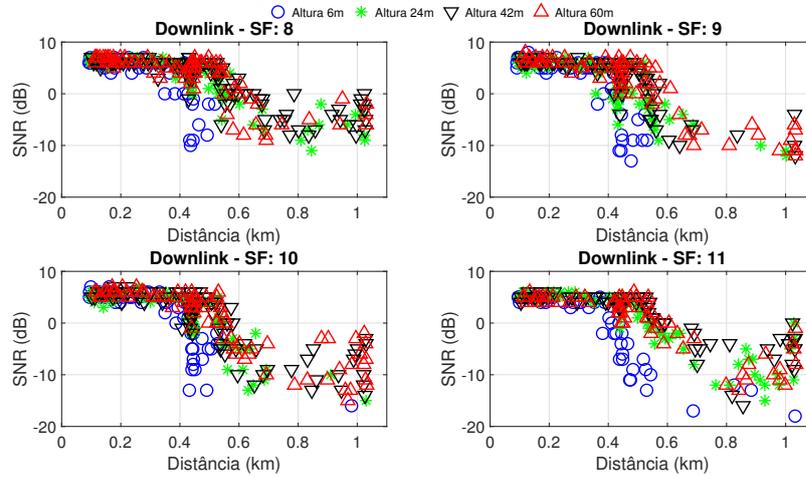
Fonte: O Autor

3.2.4.2 Rota 2

As Figuras 16 e 17 ilustram os pontos coletados para rota 2. No *downlink* é observado um comportamento distinto do visualizado na rota 1, não há uma grande variabilidade da SNR

durante os primeiros 400 m da rota e o sinal possui um comportamento bem definido, se mantém estável até 400 m, em seguida a SNR começa a reduzir até atingir o ponto final da rota 2.

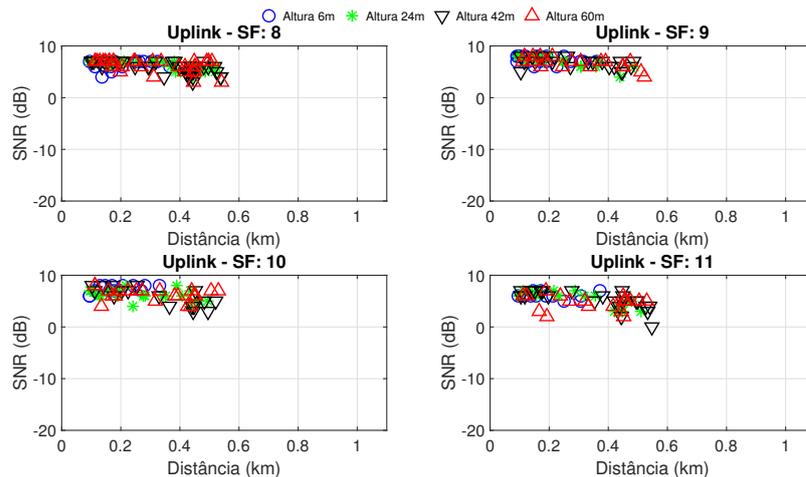
Figura 16 – Uplink: SNR x Distância



Fonte: O Autor

Ao analisar o *uplink*, é possível observar que mais dados foram coletados para a altura de 6 m, 118 amostras ao todo, além disso o alcance foi maior, ultrapassando 200 m. Adicionalmente, ao observar as Figuras 16 e 17 verifica-se que o sinal sofre menos atenuação na parte inicial da rota, pois nesta parte existe uma região em que *gateway* e *endnode* ficam em linha de visada, diferente da rota 1 que o enlace fica obstruído pelos prédios como visualizado em 9.

Figura 17 – Uplink: SNR x Distância



Fonte: O Autor

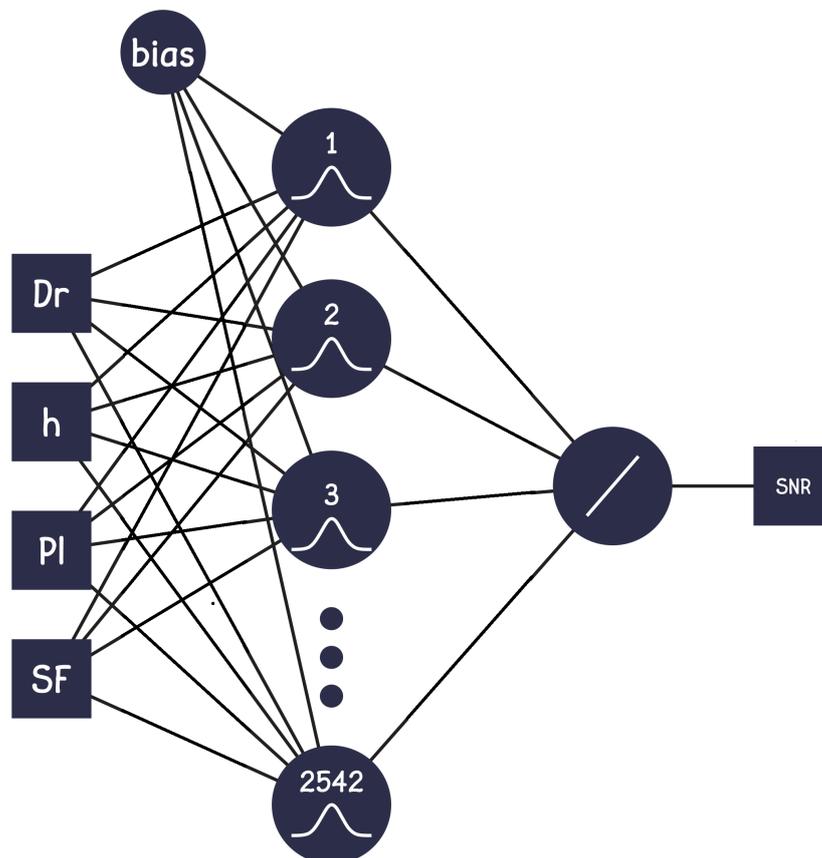
Ao analisar os dados coletados para *uplink* e *downlink*, fica evidente que os canais de comunicação possuem comportamento diferentes. Desta forma, é necessário realizar a modelagem do canal de propagação nos dois sentidos de comunicação (*gateway - endnode*, *endnode - gateway*), considerando um ambiente suburbano e densamente arborizado localizado na região amazônica.

3.3 Treinamento da Rede Neural

A RNRG utilizada neste estudo possui apenas um parâmetro ajustável, o *spread*, ele é responsável por determinar se a aproximação da função será suave ou não. O valor de *spread* selecionado foi 8, para que a aproximação da função seja mais suave, valores menores ajustam a função aos dados de forma mais aproximada ocasionando em *overfitting*.

A RNRG é composta por quatro entradas (Dr , h , Pl e SF) e duas camadas ocultas, a primeira contém 2542 neurônios os quais utilizam função de transferência de base radiais. Na primeira camada, o número de neurônios é equivalente ao número de amostras presentes no conjunto de treino. Adicionalmente, a segunda camada possui apenas um neurônio, cuja a função de transferência é a *purelin* e produz a saída da rede (SNR). A Figura 18 ilustra a arquitetura da RNRG proposta.

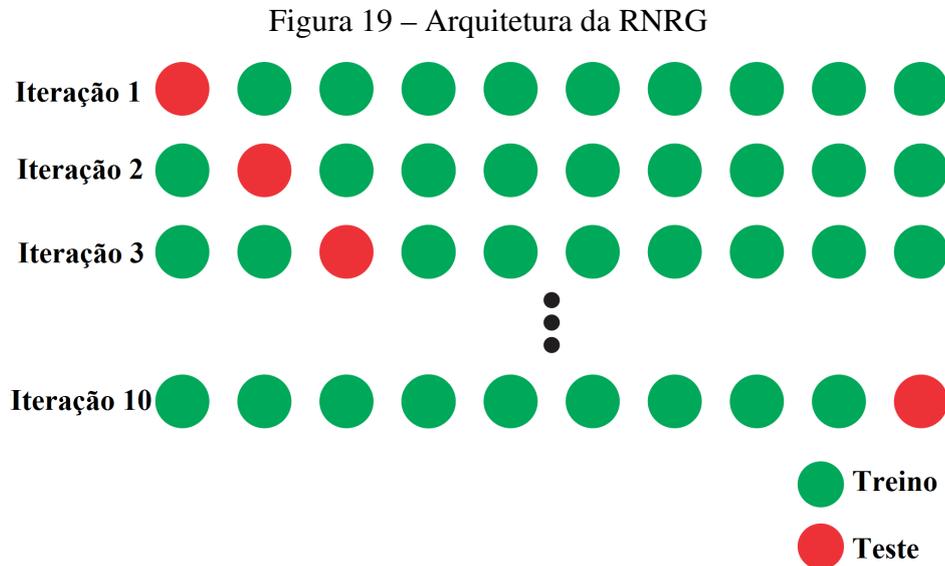
Figura 18 – Arquitetura da RNRG



Fonte: Adaptado de (CARDOSO et al., 2022)

Após definida a arquitetura da rede RNRG utilizada, foi realizado o processo de treinamento através da utilização da técnica de validação cruzada. Esta técnica foi selecionada, pois ela atenua o viés ocasionado pela escolha de um conjunto de amostras particular para treinamento (WITTEN et al., 2017). O processo de validação cruzada gera 10 modelos RNRG, considerando $k = 10$, contudo para garantir a variabilidade estatística (JAIN, 1991), o processo foi realizado 1.000 vezes. Deste modo, foram gerados 10.000 modelos RNRG dos quais foram calculado a

média dos erros para obtenção da performance final do modelo. A Figura 19 ilustra o processo de validação cruzada.



Fonte: Adaptado de (CARDOSO et al., 2022)

Por fim, é apresentado a seguir o algoritmo 1 utilizado para realizar o treinamento da RNRG e cálculo das métricas apresentadas no capítulo 4.

Algoritmo 1: Algoritmo de treinamento da RNRG

```

for época ≤ número-de-epocas do
  for partição ≤ número-de-particoes do
    Separa partição para teste
    Separar número de partições - 1 para treino
    Treinar a RNRG
    Calcular o RMSE:  $\sqrt{\frac{1}{2}(\text{medido}_i - \text{predito}_i)^2}$ 
    Armazenar o RMSE no vetor RMSE_KFold
  end
  Calcular a média do RMSE:  $\frac{\sum \text{RMSE\_KFold}}{\text{número-de-particoes}}$ 
  Armazenar a média do RMSE no vetor media_RMSE_epocas
end
Calcular a média final após o número-de-epocas:  $\frac{\sum \text{media\_RMSE\_epocas}}{\text{número-de-epocas}}$ 

```

3.4 Considerações Finais

Neste capítulo, o passo a passo da metodologia utilizada para desenvolvimento do trabalho foi apresentado. Começando pelos equipamentos e configurações utilizados, o cenário em que as campanhas de medições ocorreram, a metodologia de transmissão e recepção dos dados, finalizando com o processamento, análise dos dados coletados, a modelagem da rede neural treinada e o algoritmo de treinamento da mesma.

4 Resultados

4.1 Considerações Iniciais

Neste capítulo serão apresentados os resultados obtidos para o modelo de rede neural cujo objetivo é prever a SNR em um ambiente suburbano densamente arborizado, utilizando como ponto de partida os dados coletados e os modelos de linha de base desenvolvidos para comparação.

4.2 Modelos de Linha de Base

Três funções simples (Linear, Sigmoid e *Power*) foram ajustadas utilizando os dados medidos, com o objetivo de verificar se alguma delas é capaz de representar o comportamento do sinal e ter um parâmetro para a avaliação do modelo de rede neural proposto. A seguir as equações 4.1, 4.2 e 4.3 representam as três funções respectivamente.

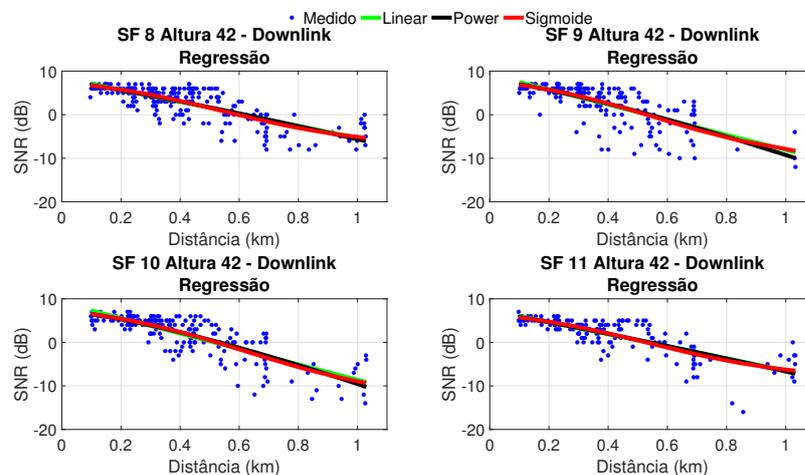
$$y = a \cdot x + b \quad (4.1)$$

$$y = a \cdot x^b + c \quad (4.2)$$

$$y = a + \frac{b - a}{1 + a \cdot e^{-c \cdot x}} \quad (4.3)$$

Desta forma, as funções foram ajustadas para cada altura e SF utilizados durante a campanha de medições, visto que foram consideradas 4 alturas, 4 SFs e 3 regressões, foram realizadas ao todo 48 regressões. A seguir é apresentada na Figura 20 a regressão sobre os dados de *downlink* para a altura de 42 m, as demais regressões podem ser visualizadas no Apêndice A.

Figura 20 – *Downlink*: Modelos de Linha de Base



Fonte: Adaptado de (CARDOSO et al., 2022)

Ao analisar a Figura 20, pode-se observar que todas as três funções se ajustaram bem aos dados medidos, ou seja, as curvas acompanharam a tendência dos dados coletados. A seguir na Tabela 6 são apresentadas as raízes dos erros médio quadrático (RMSE) de cada regressão em conjunto dos coeficientes utilizados e o desvio padrão do erro (DP).

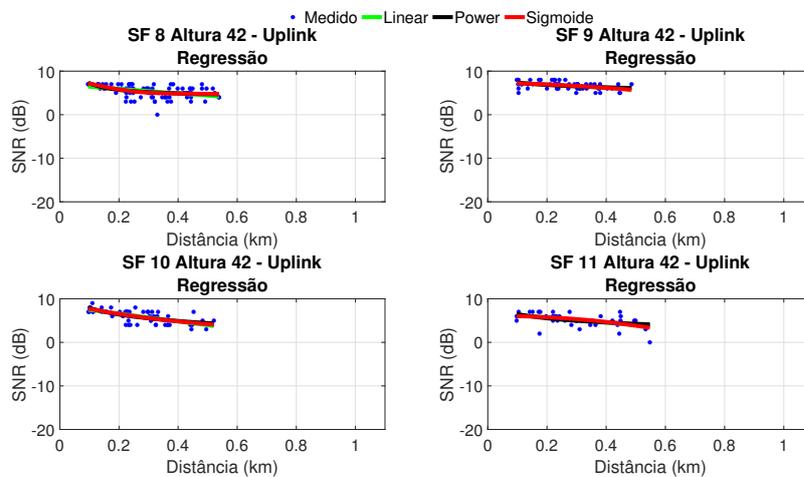
Tabela 6 – *Downlink*: Coeficientes e RMSE para a altura de 42 m.

SF	Regressão	Coeficientes (a, b, c)			RMSE	DP
8	Linear	-13,79	8,467		2,4249	2,4199
	Power	-13,38	1,147	7,734	2,4254	2,4154
	Sigmoide	9,005	-7,326	4,042	2,3673	2,3575
9	Linear	-17,33	9,243		3,0311	3,0232
	Power	-17,18	1,259	7,932	3,0260	3,0102
	Sigmoide	9,62	-10,96	4,029	3,0098	2,9941
10	Linear	-17,67	9,082		2,7153	2,7085
	Power	-16,82	1,335	7,261	2,6911	2,6775
	Sigmoide	9,528	-13,61	3,631	2,6569	2,6435
11	Linear	-13,88	7,4222		2,5616	2,5537
	Power	-13,57	1,107	6,88	2,5670	2,5511
	Sigmoide	8,27	-8,636	3,926	2,5074	2,4918

Fonte: Adaptado de (CARDOSO et al., 2022)

Observando a Tabela 6 verifica-se que todos os erros ficaram próximos, com o menor erro, 2,4249 dB, relacionado à regressão linear no SF 8 e o maior, 3,3228 dB, para a regressão *power* no SF 9. Isto ocorre, pois o desvio padrão dos dados coletados no SF 9 foi maior que os demais, tornando difícil o ajuste das curvas aos dados. Os demais coeficientes e erros para as 36 regressões restantes estão presentes no Apêndice C. A seguir é apresentada na Figura 21 a regressão sobre os dados de *uplink* para a altura de 42 m.

Figura 21 – *Uplink*: Modelos de Linha de Base



Fonte: Adaptado de (CARDOSO et al., 2022)

A Figura 21 evidencia que, para o *uplink* o desvio padrão dos dados coletados foi menor o que ajudou as curvas se ajustaram com precisão ao dados medidos. As demais regressões para o *uplink* estão presentes no Apêndice B. A Tabela 7, ilustra as as raízes dos erros médio quadrático (RMSE) de cada regressão em conjunto dos coeficientes utilizados e o desvio padrão do erro (DP) para o cenário de *uplink*.

Tabela 7 – *Uplink*: Coeficientes e RMSE para a altura de 42 m.

SF	Regressão	Coeficientes (a, b, c)			RMSE	DP
8	Linear	-5,093	6,947		1,3183	1,3104
	Power	0,4058	-0,9042	3,964	1,2729	1,2576
	Sigmoide	8,441	4,788	15,41	1,2576	1,2425
9	Linear	-3,739	7,675		0,8245	0,8171
	Power	79,88	-0,0098	-74,31	0,8496	0,8343
	Sigmoide	0,0834	8,063	-3,317	0,8296	0,8146
10	Linear	-8,829	8,343		1,1521	1,1411
	Power	67,43	-0,031	-64,46	1,166	1,1438
	Sigmoide	2,136	23,65	-2,993	1,155	1,133
11	Linear	-5,828	6,877		1,2702	1,256
	Power	124,9	-0,011	-121,6	1,3233	1,2936
	Sigmoide	0,0296	6,358	-6,235	1,2753	1,2466

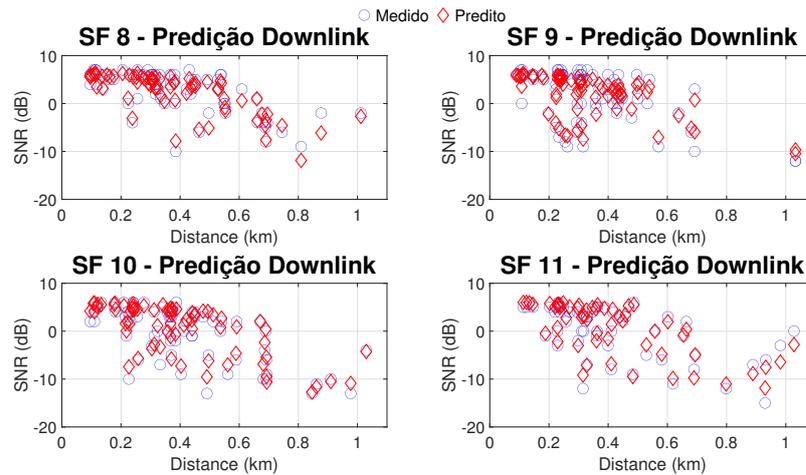
Fonte: Adaptado de (CARDOSO et al., 2022)

Para o *uplink* pode-se observar que todos os erros calculados estão abaixo de 2 dB. Os menores erros estão associados ao SF 9, o qual possui menor desvio padrão dentro todos os SFs. O menor erro obtido foi de 0,8245 dB para a regressão linear no SF 9 e o maior de 1,3233 dB para a regressão *power* no SF 11. O Apêndice D apresenta os demais coeficientes e erros para as outras regressões.

4.3 Modelo de Rede Neural

Após definidos os modelos de linha de base, os quais servirão de parâmetro para a avaliação do modelo de rede neural proposto, serão apresentados os resultados obtidos pela rede neural. A Figura 22 ilustra o desempenho do modelo para o cenário de *downlink* de forma geral utilizando os dados separados para teste, ou seja, dados que a rede não teve acesso durante o processo de aprendizagem.

Figura 22 – *Downlink*: Rede Neural.



Fonte: Adaptado de (CARDOSO et al., 2022)

Ao analisar a Figura 22 verifica-se que a rede foi capaz de reproduzir o comportamento do canal, contido nos dados de teste, a rede teve uma acurácia boa, principalmente nos quando se considera os momentos em que a variabilidade dos dados foi maior. A seguir a Tabela 8 ilustra o RMSE e DP do erro para os dados de *downlink*, considerando cada SF.

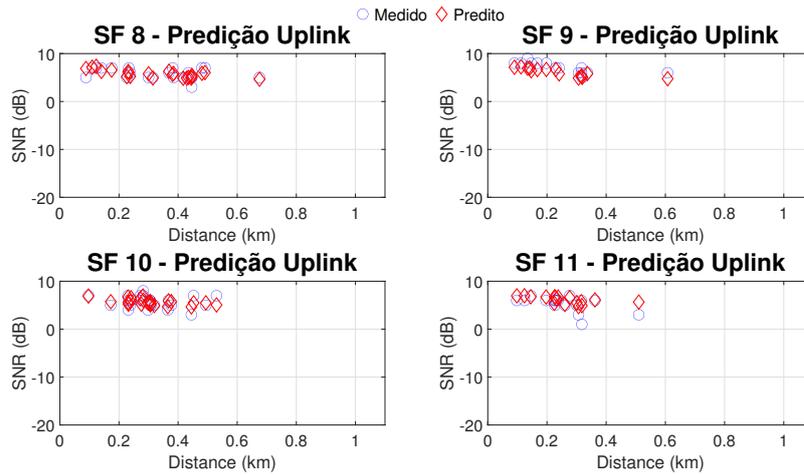
Tabela 8 – *Downlink*: Resultados da Rede Neural.

SF	RMSE	DP
8	1,2322	1,2010
9	1,6623	1,6730
10	1,3511	1,2600
11	1,3183	1,2819

Fonte: Adaptado de (CARDOSO et al., 2022)

Analizando a Tabela 8, verifica-se que o melhor desempenho ocorreu para o SF 8 com RMSE de 1,2322 dB e o pior para o SF 9 com 1,6623 dB, assim como o ocorrido para os modelos de linha de base no *downlink*. Adicionalmente, ao comparar as Tabelas 6 e 8 verifica-se que o modelo de rede neural teve desempenho superior de aproximadamente 1 dB. A Figura 23 ilustra o comportamento da rede para o *uplink*.

Figura 23 – *Uplink*: Rede Neural.



Fonte: Adaptado de (CARDOSO et al., 2022)

Assim como no *downlink*, observa-se que o modelo obteve uma boa performance para o *uplink*. Os resultados mostram que a rede acompanhou a tendência dos dados e obteve erro RMSE abaixo de 1,4 dB para todos os SFs, como visualizado na Tabela 9 a seguir.

Tabela 9 – *Uplink*: Resultados da Rede Neural.

SF	RMSE	SD
8	0,8714	0,8905
9	1,1335	0,6295
10	0,9211	0,9409
11	1,3891	1,1706

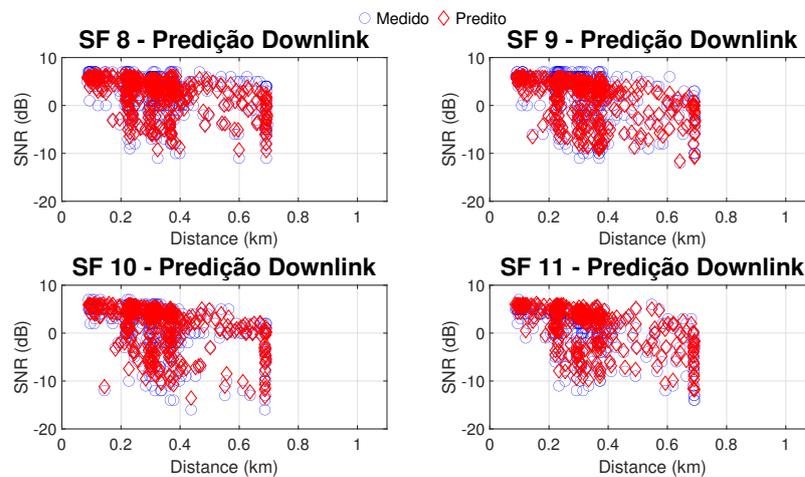
Fonte: Adaptado de (CARDOSO et al., 2022)

A Tabela 9 mostra que assim como no *downlink* o menor erro, 0,8714 dB, se manteve associado ao SF 8, enquanto que o maior erro, 1,3891 dB, ocorreu para o SF 11. Quando se compara as Tabelas 7 e 9 verifica-se que o modelo proposto teve melhor desempenho em 3 dos 4 SFs.

4.3.1 Rota 1

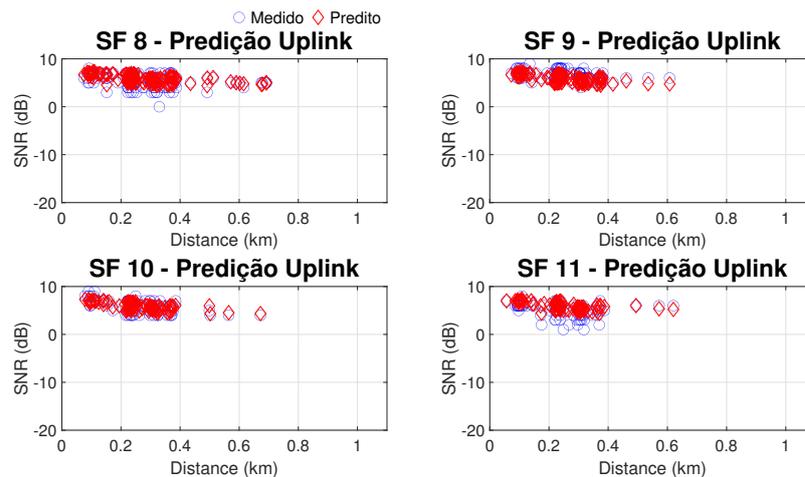
A seguir as Figuras 24 e 25 representam o desempenho do modelo proposto quando se considera apenas os dados da rota 1.

Figura 24 – *Downlink*: Rede Neural Rota 1.



Fonte: O Autor

Figura 25 – *Uplink*: Rede Neural Rota 1.



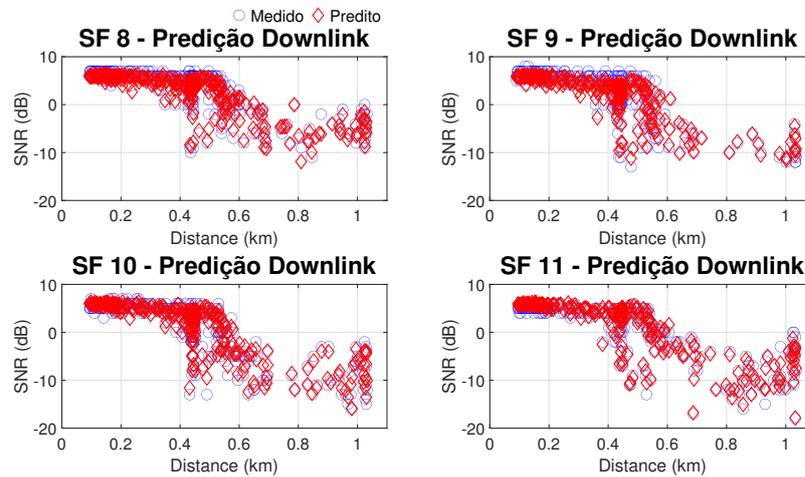
Fonte: O Autor

O principal destaque desta análise é o fato de o modelo proposto apontar com precisão a variabilidade dos dados decorrente da presença de obstruções na faixa de 200 à 400 metros de distância, diferente do que ocorre nos modelos de linha de base, os quais apenas acompanham a tendência dos dados.

4.3.2 Rota 2

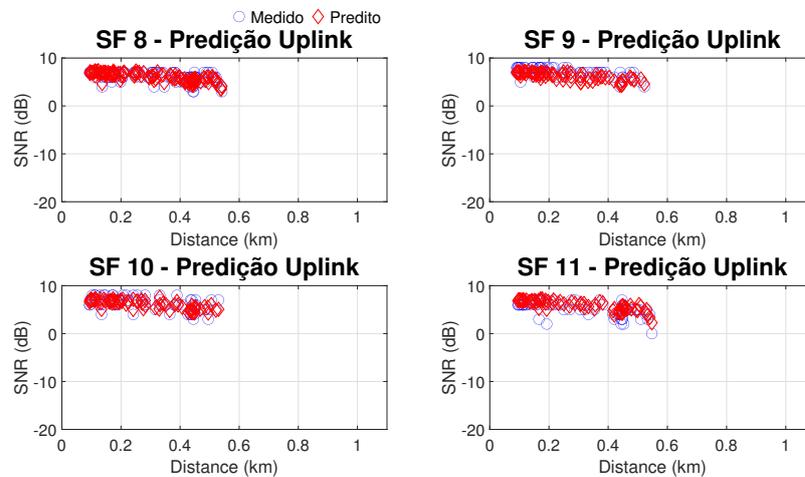
A seguir as Figuras 26 e 27 representam o desempenho do modelo proposto quando se considera apenas os dados da rota 2.

Figura 26 – *Downlink*: Rede Neural Rota 2.



Fonte: O Autor

Figura 27 – *Uplink*: Rede Neural Rota 2.



Fonte: O Autor

Novamente, se observa que o modelo proposto foi capaz de realizar com precisão a predição dos valores de SNR, para *uplink* e *downlink*. Desta forma observa-se que a rede apresentou resultados relevantes tanto para as comunicações de *uplink*, quanto para as de *downlink*. Portanto, a utilização do modelo proposto para predição de SNR de forma a entender o comportamento do canal de comunicação em um ambiente suburbano densamente arborizado se mostrou viável.

4.4 Considerações Finais

Neste capítulo foram apresentados os resultados obtidos ao longo do trabalho. Os modelos de linha de base desenvolvidos e a comparação com o modelo de predição de SNR proposto. Adicionalmente, foram apresentados o desempenho do modelo proposto considerando diferentes situações, com os dados de teste, com os dados referentes a rota 1 e os dados da rota 2.

5 Conclusão

Este estudo teve como objetivo propor um modelo de predição de SNR para caracterizar o comportamento do canal em um ambiente suburbano densamente arborizado através da utilização de redes neurais. Para atingir o objetivo, foram realizadas medições na Universidade Federal do Pará que permitiram o entendimento do comportamento do sinal nesse meio.

A análise evidenciou o comportamento distinto do sinal nos canais de *uplink* e *downlink*, ocorrido devido as diferenças nos meios de propagação, ou seja, a presença de caminhos com e sem visada direta que impactam de forma direta na propagação das ondas de rádio entre os transceptores. Para o *downlink* foi possível prover cobertura em toda a rota, enquanto que para o *uplink* apenas até 600 m de distância.

A partir da observação dos dados, pode-se verificar o impacto que a alteração dos valores de SF e altura tem no alcance do sinal propagado. Valores de SF maiores incrementam a sensibilidade de recepção permitindo uma maior área de cobertura, assim como o aumento da altura em que o VANT está posicionado.

Após a coleta dos dados, foram desenvolvidos três modelos de linha de base através de regressões, os quais serviram de parâmetro para o modelo de rede neural proposto. O modelo proposto demonstrou ter capacidade de trabalhar com dados complexos, visto o elevado desvio padrão presente nos dados principalmente na altura de 6 m, realizando predições com precisão para cada ponto das rotas.

Adicionalmente, os resultados mostraram que o modelo proposto teve desempenho melhor tanto para a situação de *downlink* quanto *uplink* ao comparado com os modelos de linha de base, os quais apenas acompanharam a tendência dos dados medidos. Por fim, o modelo proposto teve erro RMSE mínimo de 1,6623 dB para o *downlink* e 1,3891 dB para o *uplink*.

Os resultados obtidos neste trabalho demonstram a capacidade do modelo proposto em representar o comportamento do sinal, permitindo sua utilização para otimização de redes LoRa que contam com a utilização de VANTs e a análise do canal de comunicação em ambientes suburbanos densamente arborizados.

5.1 Trabalhos Futuros

- Realização a otimização do posicionamento do VANT a partir da utilização do modelo proposto e técnicas de meta-heurísticas.
- Criar a representação em 3D do ambiente de estudo para determinar pontos de LOS e NLOS os quais podem ser utilizados como entrada do modelo de rede neural.

5.2 Publicações

1. CARDOSO, CAIO M. M.; BARROS, FABRÍCIO J. B.; CARVALHO, JOEL A. R.; MACHADO, ARTUR A.; CRUZ, HUGO A. O.; DE ALCÂNTARA NETO, MIÉRCIO C.; ARAÚJO, JASMINE P. L. . **SNR Prediction with ANN for UAV Applications in IoT Networks Based on Measurements**. SENSORS, v. 22, p. 5233, 2022.
2. CARDOSO, C. M. M.; CARVALHO, J. A. R.; MACHADO, A. A.; CRUZ, H. A. O.; MACEDO, A. S.; CAVALCANTE, G. P. DOS S.; BARROS, F. J. B.; ARAÚJO, J. P. L. . **Predição de perda de qualidade de vídeos 4K em ambientes indoor com RNA**. Anais do 20o SBMO – Simpósio Brasileiro de Micro-ondas e Optoeletrônica, 2022, Natal - RN.
3. CARVALHO, J. A. R.; CARDOSO, C. M. M.; ; MACHADO, A. A.; CRUZ, H. A. O.; MACEDO, A. S.; CAVALCANTE, G. P. DOS S.; TOSTES, M. E. L.; NASCIMENTO, A. A.; BARROS, F. J. B. . **Transmissão de Dados em um Sistema IoT Utilizando Tecnologia LoRaWAN**. Anais do 20o SBMO – Simpósio Brasileiro de Micro-ondas e Optoeletrônica, 2022, Natal - RN.
4. CRUZ, H. A. O.; CARDOSO, C. M. M.; MACEDO, A. S.; CARVALHO, J. A. R.; MACHADO, A. A.; BARROS, F. J. B.; ARAÚJO, J. P. L.; CAVALCANTE, G. P. DOS S. . **Predição de QoS para Tecnologia LoRa (915MHz) por meio de RNA em ambiente de corredores com Múltiplos Pisos**. Anais do 20o SBMO – Simpósio Brasileiro de Micro-ondas e Optoeletrônica, 2022, Natal - RN.
5. MACEDO, A. S.; MACHADO, A. A.; CRUZ, H. A. O.; CARDOSO, C. M. M.; CARVALHO, J. A. R.; ARAÚJO, J. P. L.; BARROS, F. J. B.; CAVALCANTE, G. P. DOS S. . **Análise de Modelos de Propagação LoRa em Ambientes de Corredor com Múltiplos Andares**. Anais do 20o SBMO – Simpósio Brasileiro de Micro-ondas e Optoeletrônica, 2022, Natal - RN.
6. MACHADO, A. A.; BARROS, F. J. B.; MACEDO, A. S.; CARDOSO, C. M. M.; CARVALHO, J. A. R.; CRUZ, H. A. O.; DE A. NETO, M. C.; CAVALCANTE, G. P. DOS S. . **LCT LoRa Messenger: Uma Solução de Telecomunicações para Regiões Isoladas**. Anais do 20o SBMO – Simpósio Brasileiro de Micro-ondas e Optoeletrônica, 2022, Natal - RN.

Referências

- ABIRESEARCH. *LoRaWAN and NB-IoT: Competitors or Complementary?* [S.l.], 2019. 6 p. Disponível em: <<https://resources.lora-alliance.org/whitepapers/lorawan-and-nb-iot-competitors-or-complementary>>. Citado na página 15.
- ABIRESEARCH. *LoRaWAN and Multi-RAN Architecture Connecting the Next Billion IoT Devices*. [S.l.], 2020. 6 p. Disponível em: <<https://info.semtech.com/hubfs/LoRaWAN%20and%20Multi-RAN%20Architecture%20Connecting%20the%20Next%20Billion%20IoT%20Devices-web.pdf?hsCtaTracking=ee917aa6-329a-4660-b682-7a4e68b470d5%7C42a5b508-4487-4030-8dca-3877fbbf6108>>. Citado na página 21.
- AHMAD, A.; CHEEMA, A. A.; FINLAY, D. A survey of radio propagation channel modelling for low altitude flying base stations. *Computer Networks*, Elsevier BV, v. 171, p. 107122, 04 2020. Citado na página 17.
- AL-MAHASNEH, A. J. et al. Applications of general regression neural networks in dynamic systems. In: ASADPOUR, V. (Ed.). *Digital Systems*. Rijeka: IntechOpen, 2018. cap. 8. Disponível em: <<https://doi.org/10.5772/intechopen.80258>>. Citado na página 33.
- ALLIANCE, L. *LoRaWAN™ What is it? A technical overview of LoRa® and LoRaWAN™*. 2015. Acessado: 11-11-2022. Disponível em: <<https://lora-alliance.org/wp-content/uploads/2020/11/what-is-lorawan.pdf>>. Citado 3 vezes nas páginas 27, 29 e 30.
- ALLIANCE, L. *What is LoRaWAN® Specification*. 2015. <<https://lora-alliance.org/about-lorawan/>>. Acessado: 10-11-2022. Citado na página 15.
- ALMEIDA, D. N.; NETO, R. M. R. Análise da arborização urbana de três cidades da região norte do estado de mato grosso. *Acta Amazonica*, FapUNIFESP (SciELO), v. 40, n. 4, p. 647–656, dec 2010. Citado na página 20.
- ANATEL. *Compromissos de Abrangência do Leilão do 5G*. 2022. Acessado: 14-07-2022. Disponível em: <<https://www.gov.br/anatel/pt-br/regulado/universalizacao/compromissos-do-leilao-do-5g>>. Citado na página 15.
- AUGUSTIN, A. et al. A study of lora: Long range amp; low power networks for the internet of things. *Sensors*, v. 16, n. 9, 2016. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/16/9/1466>>. Citado na página 30.
- AYADI, M.; ZINEB, A. B.; TABBANE, S. A uhf path loss model using learning machine for heterogeneous networks. *IEEE Transactions on Antennas and Propagation*, v. 65, n. 7, p. 3675–3683, 2017. Citado 2 vezes nas páginas 19 e 20.
- BALANIS, C. A. *Antenna Theory*. Fourth. [S.l.]: John Wiley & Sons, 2015. ISBN 978-1-118-642060-1. Citado na página 19.
- BENMUS, T. A.; ABOUD, R.; SHATTER, M. K. Neural network approach to model the propagation path loss for great tripoli area at 900, 1800, and 2100 mhz bands. In: *2015 16th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA)*. [S.l.: s.n.], 2015. p. 793–798. Citado 2 vezes nas páginas 19 e 20.

- BOCKER, S. et al. LPWAN in the context of 5g: Capability of LoRaWAN to contribute to mMTC. In: *2019 IEEE 5th World Forum on Internet of Things (WF-IoT)*. [S.l.]: IEEE, 2019. Citado na página 16.
- BRAGA, A. D. S. et al. Radio propagation models based on machine learning using geometric parameters for a mixed city-river path. *IEEE Access*, v. 8, p. 146395–146407, 2020. Citado 2 vezes nas páginas 19 e 20.
- CARDOSO, C. M. M. et al. Snr prediction with ann for uav applications in iot networks based on measurements. *Sensors*, v. 22, n. 14, 2022. ISSN 1424-8220. Disponível em: <<https://www.mdpi.com/1424-8220/22/14/5233>>. Citado 12 vezes nas páginas 38, 39, 40, 41, 42, 45, 46, 47, 48, 49, 50 e 51.
- CASTRO, B. S. L. *Modelo de propagação para redes sem fio fixas na banda de 5,8 GHz em cidades típicas da região amazônica*. Dissertação (Mestrado) — Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2010. Citado na página 24.
- CHALL, R. E.; LAHOUD, S.; HELOU, M. E. LoRaWAN network: Radio propagation models and performance evaluation in various environments in lebanon. *IEEE Internet of Things Journal*, Institute of Electrical and Electronics Engineers (IEEE), v. 6, n. 2, p. 2366–2378, 04 2019. Citado 2 vezes nas páginas 18 e 20.
- CLOUGH, B. Metrics, schmetrics! how do you track a uav's autonomy? In: _____. *1st UAV Conference*. [s.n.], 2002. Disponível em: <<https://arc.aiaa.org/doi/abs/10.2514/6.2002-3499>>. Citado na página 34.
- DAMBAL, V. A. et al. Improving LoRa signal coverage in urban and sub-urban environments with UAVs. In: *2019 International Workshop on Antenna Technology (iWAT)*. [S.l.]: IEEE, 2019. Citado 3 vezes nas páginas 19, 20 e 33.
- DUANGSUWAN, S.; JUENGKITTIKUL, P.; MAW, M. M. Path loss characterization using machine learning models for GS-to-UAV-enabled communication in smart farming scenarios. *International Journal of Antennas and Propagation*, Hindawi Limited, v. 2021, p. 1–13, jul 2021. Citado 3 vezes nas páginas 19, 20 e 33.
- GHAMARI, M. et al. Unmanned aerial vehicle communications for civil applications: A review. *IEEE Access*, Institute of Electrical and Electronics Engineers (IEEE), v. 10, p. 102492–102531, 2022. Citado na página 17.
- GHAZALI, M. H. M.; TEOH, K.; RAHIMAN, W. A systematic review of real-time deployments of uav-based lora communication network. *IEEE Access*, v. 9, p. 124817–124830, 2021. Citado na página 18.
- HAYKIN, S. S. *Neural networks and learning machines*. Third. Upper Saddle River, NJ: Pearson Education, 2009. Citado na página 31.
- JAIN. *The Art of Comp Systems Perform Analysis*. John Wiley Sons, 1991. ISBN 0471503363. Disponível em: <https://www.ebook.de/de/product/4415910/jain_the_art_of_comp_systems_perform_analysis.html>. Citado na página 45.
- KYÖSTI, P. et al. Winner ii channel models. *IST-4-027756 WINNER II D1.1.2 VI.2*, 02 2008. Citado na página 26.

- MARCHESE, M.; MOHEDDINE, A.; PATRONE, F. Towards increasing the LoRa network coverage: A flying gateway. In: *2019 International Symposium on Advanced Electrical and Communication Technologies (ISAECT)*. [S.l.]: IEEE, 2019. Citado 2 vezes nas páginas 16 e 33.
- MOHEDDINE, A.; PATRONE, F.; MARCHESE, M. UAV and IoT integration: A flying gateway. In: *2019 26th IEEE International Conference on Electronics, Circuits and Systems (ICECS)*. [S.l.]: IEEE, 2019. Citado 3 vezes nas páginas 18, 20 e 33.
- MOZAFFARI, M. et al. A tutorial on UAVs for wireless networks: Applications, challenges, and open problems. *IEEE Communications Surveys Tutorials*, Institute of Electrical and Electronics Engineers (IEEE), v. 21, n. 3, p. 2334–2360, 2019. Citado 2 vezes nas páginas 17 e 35.
- NETO, N. C. M. *Fuzzy C-Means Based Gateway Placement Algorithm for LoRaWAN*. Dissertação (Mestrado) — Universidade Federal do Pará, Instituto de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica, Belém, 2020. Citado na página 28.
- NIELSEN, M. *Neural Networks and Deep Learning*. [S.l.]: Determination Press, 2015. Citado na página 16.
- OKUMURA, Y. Field strength and its variability in vhf and uhf land-mobile radio service. *Rev. Electr. Commun. Lab.*, v. 16, p. 825–873, 1968. Disponível em: <<https://cir.nii.ac.jp/crid/1572824499680561152>>. Citado na página 25.
- PARK, S. et al. Forestry monitoring system using LoRa and drone. In: *Proceedings of the 8th International Conference on Web Intelligence, Mining and Semantics*. [S.l.]: ACM, 2018. Citado 3 vezes nas páginas 18, 20 e 33.
- PARSONS, J. D. *Mobile Radio Propagation Channel*. 2. ed. [S.l.]: Wiley Sons, Incorporated, John, 2001. ISBN 9780470841525. Citado na página 25.
- QUALCOMM. *What is 5G?* 2017. Acessado: 14-07-2022. Disponível em: <<https://www.qualcomm.com/5g/what-is-5g>>. Citado na página 15.
- RAPPAPORT, T. *Wireless Communications: Principles and Practice*. 2nd. ed. USA: Prentice Hall PTR, 2001. ISBN 0130422320. Citado 3 vezes nas páginas 22, 23 e 24.
- RATASUK, R. et al. Nb-iot system for m2m communication. In: *2016 IEEE Wireless Communications and Networking Conference*. [S.l.: s.n.], 2016. p. 1–5. Citado na página 15.
- RODRIGUES, J. et al. Path loss model for densely arboreous cities in amazon region. In: *SBMO/IEEE MTT-S International Conference on Microwave and Optoelectronics, 2005*. [S.l.: s.n.], 2005. p. 629–632. Citado na página 24.
- ROFI, A. S. M. et al. Lora channel propagation modelling using artificial neural network. In: *2021 8th International Conference on Computer and Communication Engineering (ICCCCE)*. [S.l.: s.n.], 2021. p. 58–62. Citado 2 vezes nas páginas 19 e 20.
- SALOUS, S. *Radio Propagation Measurement and Channel Modelling*. John Wiley Sons, 2013. Disponível em: <https://www.ebook.de/de/product/21166654/sana_salous_radio_propagation_measurement_and_channel_modelling.html>. Citado na página 23.
- SEMTECH. *AN1200.22 LoRa™ Modulation Basics*. 2015. Acessado: 10-11-2022. Disponível em: <<https://semtech.my.salesforce.com/sfc/p/#E0000000JelG/a/2R0000001OJk/yDEcfAkD9qEz6oG3PJryoHKas3UMsMDa3TFqz1UQOkM>>. Citado 3 vezes nas páginas 26, 28 e 29.

- SEMTECH. *SX1276/77/78/79 - 137 MHz to 1020 MHz Low Power Long Range Transceiver*. 2016. Disponível em: <<https://www.mouser.com/datasheet/2/761/sx1276-1278113.pdf>>. Citado 3 vezes nas páginas 28, 40 e 41.
- SEMTECH. *LoRa® and LoRaWAN®: A Technical Overview*. 2019. Acessado: 11-11-2022. Disponível em: <https://lora-developers.semtech.com/uploads/documents/files/LoRa_and_LoRaWAN-A_Tech_Overview-Downloadable.pdf>. Citado na página 27.
- SILVA, D. K. N. da et al. VHF–UHF electric field prediction for amazon city using dyadic green’s function. *Wireless Personal Communications*, Springer Science and Business Media LLC, v. 113, n. 4, p. 2301–2326, apr 2020. Citado 2 vezes nas páginas 19 e 20.
- SILVA, F. L. da. *Metodologia para obtenção dos pontos de segmentação do modelo larga escala multi declive usando algoritmo genético*. Dissertação (Mestrado) — Programa de Pós-Graduação em Engenharia Elétrica - UFPA, 2021. Disponível em: <https://ppgee.propesp.ufpa.br/ARQUIVOS/dissertacoes/2021/DM18_2021FlavianeLouzeirodaSilva.pdf>. Citado na página 22.
- SILVA, I. N. da. *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas - Curso Pratico*. [S.l.]: ARTLIBER, 2010. ISBN 9788588098534. Citado 2 vezes nas páginas 31 e 32.
- SIZUN, H. *Radio Wave Propagation for Telecommunication Applications*. Springer-Verlag GmbH, 2006. ISBN 9783540266686. Disponível em: <https://www.ebook.de/de/product/19293285/herve_sizun_radio_wave_propagation_for_telecommunication_applications.html>. Citado na página 22.
- SOARES, A. J. P. *Avaliação da Propagação do Sinal LoRa e Desenvolvimento de um Método para Auxiliar o Planejamento de Redes IoT usando Otimização do Modelo Hata*. Dissertação (Mestrado) — Universidade Federal de Uberlândia,, Uberlândia - MG, 2019. Citado na página 27.
- SUPRAMONGKONSET, J. et al. Empirical path loss channel characterization based on air-to-air ground reflection channel modeling for UAV-enabled wireless communications. *Wireless Communications and Mobile Computing*, Hindawi Limited, v. 2021, p. 1–10, jul 2021. Citado 3 vezes nas páginas 18, 20 e 33.
- VALAVANIS, K. *Handbook of unmanned aerial vehicles*. Dordrecht: SpringerReference, 2014. ISBN 9789048197071. Citado 3 vezes nas páginas 16, 34 e 35.
- WASSERMAN, P. *Advanced methods in neural computing*. New York: Van Nostrand Reinhold, 1993. ISBN 0442004613. Citado na página 33.
- WEIBEL, R.; HANSMAN, R. J. Safety considerations for operation of different classes of uavs in the nas. In: _____. *AIAA 3rd "Unmanned Unlimited" Technical Conference, Workshop and Exhibit*. [s.n.], 2004. Disponível em: <<https://arc.aiaa.org/doi/abs/10.2514/6.2004-6421>>. Citado na página 34.
- WITTEN, I. H. et al. Chapter 5 - credibility: Evaluating what’s been learned. In: WITTEN, I. H. et al. (Ed.). *Data Mining (Fourth Edition)*. Fourth edition. Morgan Kaufmann, 2017. p. 167–168. ISBN 978-0-12-804291-5. Disponível em: <<https://www.sciencedirect.com/science/article/pii/B9780128042915000052>>. Citado na página 45.

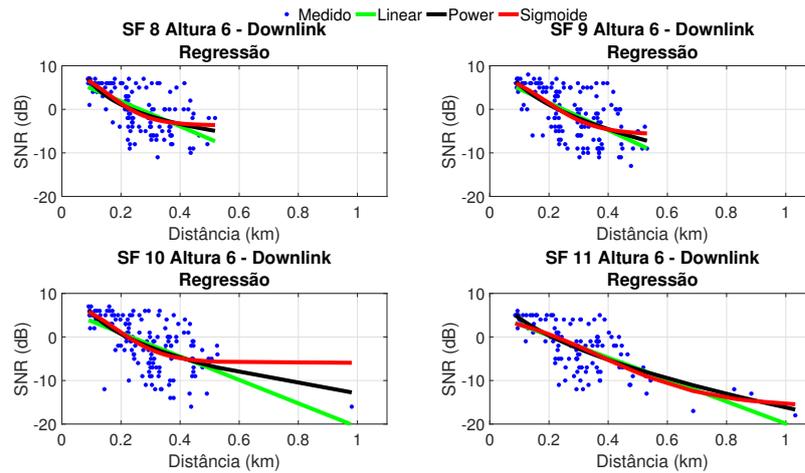
WU, L. et al. Artificial neural network based path loss prediction for wireless communication network. *IEEE Access*, Institute of Electrical and Electronics Engineers (IEEE), v. 8, p. 199523–199538, 2020. Citado na página 16.

ZANDONAI, R. *Começa a Década da ONU da Restauração de Ecossistemas*. 2021. Acessado: 12-09-2022. Disponível em: <<https://brasil.un.org/pt-br/130341-comeca-decada-da-onu-da-restauracao-de-ecossistemas>>. Citado na página 20.

Apêndices

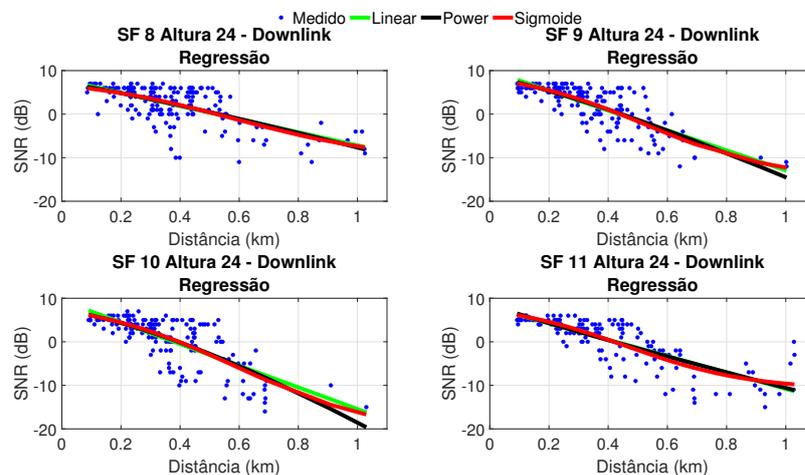
A Downlink: Gráficos Regressões

Figura 28 – Downlink: Modelos de Linha de Base 6 m

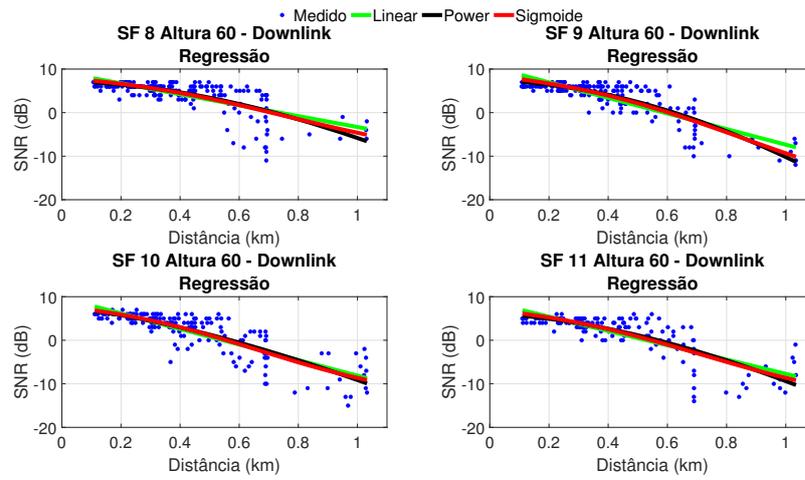


Fonte: O Autor

Figura 29 – Downlink: Modelos de Linha de Base 24 m



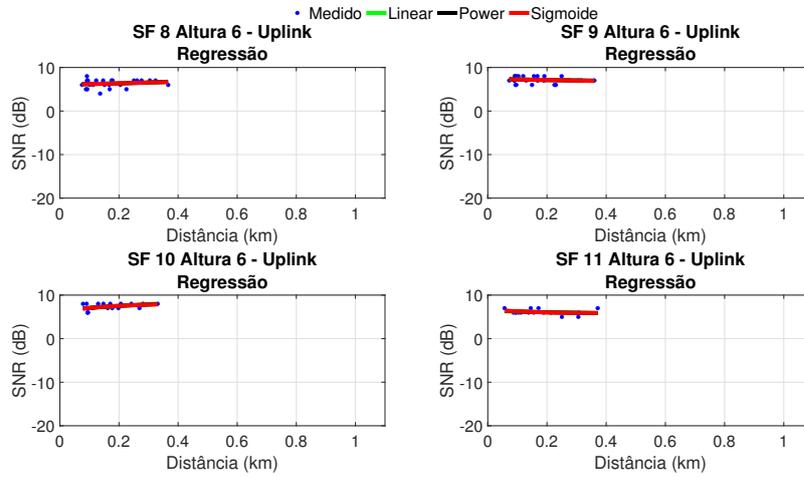
Fonte: O Autor

Figura 30 – *Downlink*: Modelos de Linha de Base 60 m

Fonte: O Autor

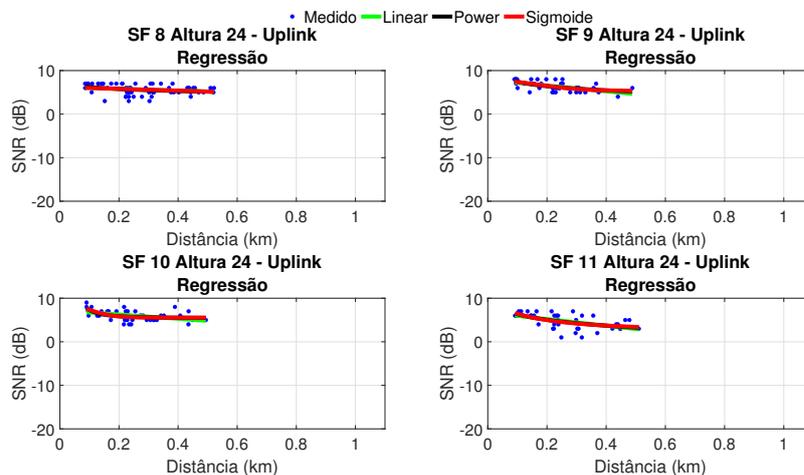
B Uplink: Gráficos Regressões

Figura 31 – Uplink: Modelos de Linha de Base 6 m



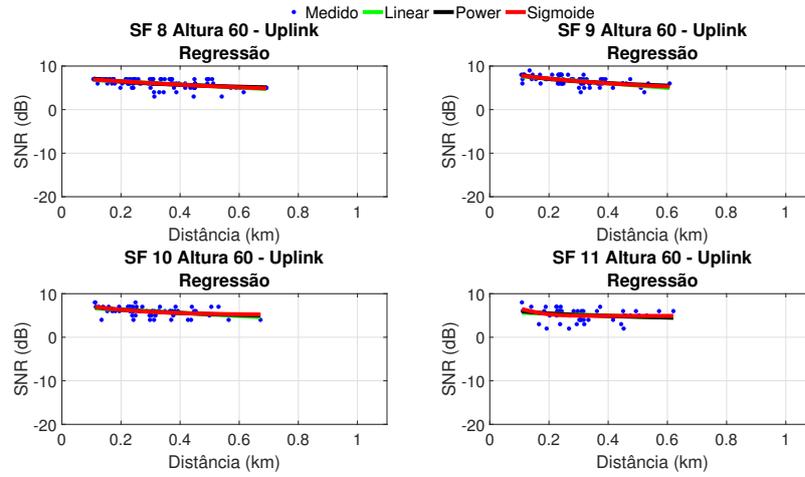
Fonte: O Autor

Figura 32 – Uplink: Modelos de Linha de Base 24 m



Fonte: O Autor

Figura 33 – Uplink: Modelos de Linha de Base 60 m



Fonte: O Autor

C Downlink: Coeficientes e RMSE Regressões

Tabela 10 – *Downlink*: Coeficientes e RMSE para a altura de 6 m.

SF	Regressão	Coeficientes (a, b, c)			RMSE	DP
Linear		-28.870	7.629		4.0472	4.0314
Power	8	34.670	-0.154	-43.290	3.9431	3.9121
Sigmoid		10.210	-3.687	14.440	3.8993	3.8688
Linear		-31.520	7.820		4.5076	4.4925
Power	9	-39.940	0.294	25.940	4.4773	4.4471
Sigmoid		9.462	-5.808	11.780	4.4680	4.4379
Linear		-26.920	6.290		4.7338	4.7178
Power	10	-54.420	0.179	41.500	4.6577	4.6261
Sigmoid		9.434	-5.929	12.130	4.6758	4.6441
Linear		-25.280	5.380		4.0767	4.0597
Power	11	-30.340	0.489	14.150	4.0206	3.987
Sigmoid		7.263	-16.150	5.301	4.1047	4.0703

Fonte: O Autor

Tabela 11 – *Downlink*: Coeficientes e RMSE para a altura de 24 m.

SF	Regressão	Coeficientes (a, b, c)			RMSE	DP
Linear		-15.080	7.904		3.1730	3.1647
Power	8	-14.800	1.151	7.140	3.1779	3.1612
Sigmoid		8.608	-10.870	3.669	3.1681	3.1515
Linear		-22.900	10.000		2.9064	2.8983
Power	9	-23.000	1.230	8.505	2.8970	2.8809
Sigmoid		10.300	-14.980	4.450	2.8423	2.8265
Linear		-24.870	9.432		3.6520	3.6413
Power	10	-25.640	1.381	7.089	3.6237	3.6024
Sigmoid		10.050	-21.470	3.912	3.5858	3.5648
Linear		-18.790	7.989		3.1916	3.1809
Power	11	-19.190	0.925	8.603	3.2002	3.1788
Sigmoid		9.063	-11.030	4.778	3.0645	3.0440

Fonte: O Autor

Tabela 12 – *Downlink*: Coeficientes e RMSE para a altura de 60 m.

SF	Regressão	Coeficientes (a, b, c)			RMSE	DP
Linear	8	-12.530	9.218		2.4909	2.4852
Power		-12.950	1.803	7.128	2.4199	2.4088
Sigmoid		9.971	-11.790	3.012	2.4206	2.4094
Linear	9	-17.890	10.530		2.2726	2.2671
Power		-17.510	1.841	7.320	2.0562	2.0462
Sigmoid		11.300	-22.900	2.844	2.0686	2.0586
Linear	10	-17.850	9.730		2.6396	2.6328
Power		-16.510	1.438	7.379	2.5955	2.5819
Sigmoid		9.972	-14.440	3.466	2.5609	2.5475
Linear	11	-16.400	8.690		2.8043	2.7953
Power		-15.370	1.665	5.990	2.7101	2.6928
Sigmoid		9.441	-15.950	3.148	2.6859	2.6687

Fonte: O Autor

D *Uplink*: Coeficientes e RMSE Regressões

Tabela 13 – *Uplink*: Coeficientes e RMSE para a altura de 6 m.

SF	Regressão	Coeficientes (a, b, c)			RMSE	DP
Linear	8	1.658	6.035		0.9550	0.9349
Power		4.347	2.025	6.168	0.9751	0.9335
Sigmoid		5.935	6.920	7.630	0.9752	0.9337
Linear	9	-1.275	7.382		0.7708	0.7539
Power		7.096	-0.027	-0.303	0.7903	0.7551
Sigmoid		7.682	4.769	2.859	0.7890	0.7538
Linear	10	4.063	6.666		0.7460	0.7222
Power		4.121	0.285	4.917	0.7701	0.7203
Sigmoid		0.322	8.087	7.291	0.7692	0.7194
Linear	11	-1.262	6.345		0.6295	0.6081
Power		-24.850	0.012	30.420	0.6438	0.5993
Sigmoid		6.593	5.889	16.930	0.6418	0.5974

Fonte: O Autor

Tabela 14 – *Uplink*: Coeficientes e RMSE para a altura de 24 m.

SF	Regressão	Coeficientes (a, b, c)			RMSE	DP
Linear		-2.088	6.220		1.1710	1.1605
Power	8	-94.920	0.007	99.610	1.1602	1.1392
Sigmoid		17.180	-182.500	0.186	1.1826	1.1612
Linear		-6.536	7.860		0.9214	0.9106
Power	9	9.627	-0.122	-5.307	0.9172	0.8955
Sigmoid		8.249	5.273	12.330	0.9185	0.8968
Linear		-4.794	7.209		1.1188	1.1057
Power	10	0.014	-2.129	5.426	1.0495	1.0248
Sigmoid		9.350	5.546	23.570	1.0528	1.0281
Linear		-7.573	6.721		1.4725	1.4545
Power	11	-89.050	0.022	90.950	1.4522	1.4163
Sigmoid		-0.689	2.625	2.549	1.4456	1.4099

Fonte: O Autor

Tabela 15 – *Uplink*: Coeficientes e RMSE para a altura de 60 m.

SF	Regressão	Coeficientes (a, b, c)			RMSE	DP
Linear		-3.559	7.190		0.9179	0.9130
Power	8	46.250	-0.023	-41.530	0.9247	0.9148
Sigmoid		3.316	21.100	-1.642	0.9215	0.9117
Linear		-5.322	8.180		0.8728	0.8664
Power	9	76.784	-0.018	-71.984	0.8816	0.8687
Sigmoid		4.069	27.424	-2.471	0.8741	0.8613
Linear		-3.635	7.058		1.0334	1.0244
Power	10	-30.258	0.038	34.800	1.0348	1.0168
Sigmoid		5.131	24.155	-5.361	1.0372	1.0191
Linear		-2.285	5.877		1.3721	1.3594
Power	11	-84.487	0.010	88.584	1.3622	1.3367
Sigmoid		8.323	4.908	21.020	1.3362	1.3112

Fonte: O Autor