



**INSTITUTO FEDERAL DE EDUCAÇÃO,
CIÊNCIA E TECNOLOGIA DO CEARÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
TELECOMUNICAÇÕES**

Sarah Sales Menezes Aragão

**Um Modelo de Predição Baseado em Rede Neural Recorrente para Cobertura de
Rede Sem Fio em Ambiente Indoor**

Fortaleza, Ceará

2023

Sarah Sales Menezes Aragão

Um Modelo de Predição Baseado em Rede Neural Recorrente para Cobertura de Rede
Sem Fio em Ambiente Indoor

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Telecomunicações do Instituto Federal de Educação, Ciência e Tecnologia do Ceará como requisito parcial para a obtenção do título de Mestre em Engenharia de Telecomunicações. Área de concentração: Processamento de Sinais.

Prof. Dr. Regis Cristiano Pinheiro Marques
Orientador

Fortaleza, Ceará

2023

Sarah Sales Menezes Aragão

Um Modelo de Predição Baseado em Rede Neural Recorrente para Cobertura de Rede Sem Fio em Ambiente Indoor

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Telecomunicações do Instituto Federal de Educação, Ciência e Tecnologia do Ceará como requisito parcial para a obtenção do título de Mestre em Engenharia de Telecomunicações. Área de concentração: Processamento de Sinais.

Aprovado em: 18 / 09 / 2023 .

Banca Examinadora

Prof. Dr. Regis Cristiano Pinheiro Marques
Orientador

Instituto Federal do Ceará - PPGET

Prof. Dr. Auzuir Ripardo de Alexandria

Instituto Federal do Ceará - PPGET

Prof. Dr. Clauson Sales do Nascimento Rios

Instituto Federal do Ceará - DTEL

Prof. Dr. João Batista Rosa Silva

Universidade Federal do Ceará - DETI

Fortaleza, Ceará

2023

AGRADECIMENTOS

Agradeço, em primeiro lugar, a Deus pelo dom da vida e por sempre me fortalecer.

À minha mãe e à minha tia, que serviram como base e sempre me apoiaram, bem como à minha prima, que sempre me auxiliou nos textos, assim como a todos os familiares que estiveram ao meu lado nessa jornada.

Aos grandes amigos que fiz ao longo do meu tempo no IFCE, dos quais posso destacar: Raiane, Isaias, Joyce, Brenon, Luzyane, Emiliane, Calina e todos que tornaram a minha passagem pelo IFCE única.

Aos amigos e professores Regis e Clauson, por toda paciência e por acreditarem na minha capacidade e no potencial do projeto, além de todo o apoio que me proporcionaram ao longo do mestrado.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

“O sucesso é a soma de pequenos esforços repetidos dia após dia.”
(Robert Collier)

RESUMO

A garantia da cobertura é um desafio das comunicações sem fio. Com o avanço das redes industriais, IoT, redes Wi-Fi e 5G, as aplicações em ambientes internos (*indoor*) são cada dia mais relevantes. Uma vez que as novas redes Wi-Fi, industriais e 5G visam aumentar as taxas e a eficiência da cobertura, ferramentas de diagnóstico e predição tornam-se indispensáveis para atingir esse objetivo. O aprendizado de máquina tem sido amplamente utilizado para propor modelos de predição da propagação de ondas eletromagnéticas no ar livre (*outdoor*). O presente trabalho, propõe um modelo genérico de predição para ambientes *indoor*, utilizando uma rede *Long Short-Term Memory* (LSTM), com baixo percentual de erro e uma implementação mais simples, sendo eficaz para locais distintos. Este método é baseado em cinco parâmetros de entrada, são estes: distância, número de paredes, ângulos vertical e de azimute e o *Free Space Path Loss* (FSPL). Propõe-se ainda um algoritmo de processamento de imagens para aquisição automática de dados, a partir da planta baixa do local, e outro para geração de amostras sintéticas, segundo o diagrama de irradiação da antena transmissora. O objetivo deste último é aumentar a base de treinamento sem a necessidade de realizar inúmeras medições *in loco*. Destaca-se, também, um *framework* para extração automática dos atributos espaciais, a partir da imagem digital da planta baixa, e como o modelo pode ser utilizado no planejamento de redes sem fio. Na preparação da rede foram adotados quatro ambientes distintos, sendo dois para treinamento e dois para testes. Nestes foram computados os erros de estimação, comparando o método proposto aos modelos empíricos de predição ITU, Log-Distance e Cost-321. A avaliação foi realizada seguindo a metodologia comumente adotada na literatura para validação de modelos de predição, que se baseia no erro quadrático médio (RMSE), erro absoluto médio (MAE) e erro percentual absoluto médio (MAPE), para os quais o método proposto alcançou 4,87 dBm, 3,71 dBm e 0,05, respectivamente. Erros estes até 3 vezes menores que dos modelos empíricos testados, e que confirmam a eficácia do método proposto. Assim, desenvolveu-se um modelo de predição baseado em LSTM para a cobertura de redes sem fio em ambientes internos, o qual auxilia no planejamento dessas redes.

Palavras-chaves: Modelo de Predição; LSTM; Rede Sem Fio; Aprendizado de Máquina.

ABSTRACT

Ensuring coverage is a challenge for wireless communications. With the advancement of industrial networks, IoT, Wi-Fi and 5G networks, indoor applications are becoming more relevant every day. As new Wi-Fi, industrial and 5G networks aim to increase coverage rates and efficiency, diagnostic and prediction tools become indispensable to achieve this goal. Machine learning has been widely used to propose models for predicting the propagation of electromagnetic waves in the open air (*outdoor*). The present work proposes a generic prediction model for *indoor* environments, using a *Long Short-Term Memory* (LSTM) network, with a low percentage of error and a simpler implementation, being effective for different locations. This method is based on five input parameters: distance, number of walls, vertical and azimuth angles and *Free Space Path Loss* (FSPL). An image processing algorithm is also proposed for automatic data acquisition, based on the site's floor plan, and another for generating synthetic samples, according to the irradiation diagram of the transmitting antenna. The objective of the latter is to increase the training base without the need to carry out countless *on-site* measurements. Also noteworthy is a *framework* for automatic extraction of spatial attributes, from the digital image of the floor plan, and how the model can be used in planning wireless networks. When preparing the network, four different environments were adopted, two for training and two for testing. In these, estimation errors were computed, comparing the proposed method to the empirical prediction models ITU, Log-Distance and Cost-321. The evaluation was carried out following the methodology commonly adopted in the literature for validating prediction models, which is based on mean squared error (RMSE), mean absolute error (MAE) and mean absolute percentage error (MAPE), for which the proposed method reached 4.87 dBm, 3.71 dBm and 0.05, respectively. These errors are up to 3 times smaller than those of the empirical models tested, and confirm the effectiveness of the proposed method. Thus, a prediction model based on LSTM was developed for the coverage of wireless networks in indoor environments, which helps in the planning of these networks.

Keywords: Prediction Model; LSTM; Wireless Network; Machine Learning.

LISTA DE ILUSTRAÇÕES

1	Arquitetura RNR padrão.	22
2	Arquitetura LSTM.	22
3	Topologia dos equipamentos utilizados nas medições.	28
4	Planta baixa do Local 1 em que dados de treinamento foram adquiridos, com indicação da antena de transmissão (Tx ■), pontos de medição (Rx ●), e 0° direção de referência ($\mathbf{d}_x$ - -).	29
5	Planta baixa do Local 2 em que dados de treinamento foram adquiridos, com indicação da antena de transmissão (Tx ■), pontos de medição (Rx ●), e 0° direção de referência ($\mathbf{d}_x$ - -).	29
6	Planta baixa do Local 3 em que dados de teste foram adquiridos, com indicação da antena de transmissão (Tx ■), pontos de medição (Rx ●), e 0° direção de referência ($\mathbf{d}_x$ - -).	30
7	Planta baixa do Local 4 em que dados de teste foram adquiridos, com indicação da antena de transmissão (Tx ■), pontos de medição (Rx ●), e 0° direção de referência ($\mathbf{d}_x$ - -).	30
8	Ângulo de Azimute.	31
9	Ângulo Vertical.	31
10	Distribuição espacial (distância x ângulo de azimute) de amostras de treino reais (●) e sintéticas (*) do Local 1.	33
11	Distribuição espacial (distância x ângulo de azimute) de amostras de treino reais (●) e sintéticas (*) do Local 2.	33
12	Diagrama de radiação da antena transmissora.	34
13	Representação das camadas da rede neural do modelo	36
14	Predição do RSS e PL utilizando o modelo de predição ITU.	39
15	Predição do RSS e PL utilizando o modelo de predição Cost-321.	40
16	Predição do RSS e PL utilizando o modelo de predição Log-Distance.	40
16	Predição do RSS e PL utilizando o modelo de predição Log-Distance.	41
17	Predição do RSS e PL utilizando o modelo de predição proposto.	41
18	Colormap do RSS predito pelo método proposto em cada local de teste, com indicação da antena de transmissão (Tx ■).	43
19	Fluxograma do método baseado em PDI para análise da planta baixa.	51
20	Exemplo de uma planta baixa de 534x1103 pixels e resolução de 0,06 m/pixel.	52
21	Distância de cada ponto do ambiente a antena transmissora localizada na linha 230 e coluna 460 da imagem.	53
22	Resultado do afinamento da planta baixa e contagem de paredes entre Tx e Rx (pontos amarelos).	53

23	Mapa de ângulos horizontais.	54
24	Mapa de ângulos verticais.	54
25	Mapa do número de paredes.	54

LISTA DE TABELAS

1	Exemplos de escolha dos parâmetros de entrada e do modelo de ML.	20
2	Trabalhos mais recentes relacionados ao presente projeto.	26
3	Influência dos dados de treinamento no desempenho do método, usando o Local 3 como referência.	37
4	Parâmetros dos modelos ITU, Cost-321 e Log-Distance.	38
5	Performance dos modelos de predição.	38

LISTA DE ABREVIATURAS E SIGLAS

4G	Quarta Geração de Telefonia Móvel
5G	Quinta Geração de Telefonia Móvel
FSPL	Free Space Path Loss
IoT	Internet das Coisas
LSTM	Long Short-Term Memory
MAE	Erro Absoluto Médio
MAPE	Erro Percentual Absoluto Médio
ML	Aprendizado de Máquina
PL	Path Loss
RMSE	Erro Quadrático Médio
RNA	Redes Neurais Artificiais
RNR	Rede Neural Recorrente
RSS	Intensidade do Sinal Recebido

LISTA DE SÍMBOLOS

b	Bias calibrados pela rede neural
C_t	Estado variável na arquitetura LSTM
C_{t-1}	Estado anterior de C_t
$\tilde{C}_t$	Vetor de novos valores candidatos criados pela camada <i>tanh</i>
d	Distância entre o transmissor e receptor
d_0	Distância de referência
$\mathbf{d}_x$	Direção de referência
E_{irp}	Potência irradiada isotrópica efetiva
f	Frequência
$FSPL$	Perda de potência do sinal, levando em consideração o espaço livre
f_t	Filtro
h	Altura da antena receptora
H	Altura da antena transmissora
h_t	Estado gerado por x_t
h_{t-1}	Estado anterior de h_t
i_t	Filtro
K_f	Número de andares entre o transmissor e receptor
K_{wi}	Número de paredes do tipo i
L_f	Valor de atenuação do andar
L_{wi}	Valor de atenuação de paredes do tipo i
n	Distância entre o transmissor e receptor
N	Coeficiente de perda de potência
o_t	Filtro
P_f	Fator de penetração de perda por andar
PL_0	Perda no espaço livre a uma distância de referência d_0
PL_d	Perda no espaço livre a uma distância d
$PL_{Cost-321}$	<i>Path Loss</i> obtido a partir do modelo Cost-321 de predição
PL_{ITU}	<i>Path Loss</i> obtido a partir do modelo ITU de predição
$PL_{Log-distance}$	<i>Path Loss</i> obtido a partir do modelo Log-distance de predição
q	Número de andares entre o transmissor e o receptor

Rx	Pontos de medição/Antena receptora
$\tanh$	Função tangente hiperbólica
Tx	Antena transmissora
W	Pesos calibrados pela rede neural
x_t	Entrada que passa por todo o circuito da arquitetura LSTM
X_σ	Variável aleatória Gaussiana com média zero e desvio padrão σ
θ	Ângulo vertical
λ	Comprimento de onda do sinal
σ	Função sigmoide
ϕ	Ângulo de Azimute

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Justificativa	16
1.2	Objetivo Geral	17
1.2.1	<i>Objetivos Específicos</i>	17
1.3	Organização da Dissertação	17
2	MODELOS DE PREDIÇÃO	18
2.1	Modelos de Predição Empíricos e Determinísticos	18
2.1.1	<i>Modelo ITU</i>	18
2.1.2	<i>Modelo Log-Distance</i>	18
2.1.3	<i>Modelo Cost-231 Multi-Wall</i>	19
2.2	Modelos baseados em aprendizado de máquina	19
2.2.1	<i>Desenvolvimento de um modelo de predição de propagação de ondas</i> .	20
2.2.2	<i>Tipos de modelos de ML</i>	20
2.3	Redes Neurais Recorrentes	21
2.3.1	<i>Long Short-Term Memory-LSTM</i>	21
2.4	Métricas de Validação	23
2.5	Revisão Bibliográfica	24
2.5.1	<i>Discussão</i>	26
3	IMPLEMENTAÇÃO DO MODELO DE PREDIÇÃO	28
3.1	Equipamentos	28
3.2	Locais de Medição	28
3.3	Parâmetros	30
3.4	Dados Sintéticos	32
3.5	PL versus RSS	34
3.6	Configuração da Rede Neural do Modelo	35
4	RESULTADOS E COMPARAÇÃO COM OUTROS MODELOS . . .	37
4.1	Avaliação dos dados sintéticos	37
4.2	Comparação com outros modelos	37
4.3	<i>Mapa de intensidade RSS</i>	42
5	CONCLUSÕES	44
5.1	Trabalhos Futuros	44

REFERÊNCIAS	46
APÊNDICES	50
APÊNDICE A – USO DE PDI PARA AUTOMAÇÃO DA EXTRA- ÇÃO DE INFORMAÇÕES DA PLANTA BAIXA DOS AMBIENTES	51

1 INTRODUÇÃO

As comunicações em ambientes *indoor* têm avançado constantemente, como no caso do Wi-Fi 5 e o mais recente padrão, Wi-Fi 6, Internet das Coisas (*IoT*), redes para automação industrial e doméstica. Em todo o mundo, a utilização da comunicação sem fio vem se tornando mais comum nas últimas décadas. O aumento do número de dispositivos conectados e a demanda por maiores taxas levaram a evolução das redes móveis, do 4G para o 5G (GUPTA; JHA, 2015; GUPTA; QUAMARA, 2020).

As redes 5G utilizam frequências de rádio mais altas, conhecidas como ondas milimétricas. Duas das principais faixas de frequências que serão usadas no 5G no Brasil são a de 2,3 GHz, frequência de operação padrão para dispositivos em geral, e a de 3,5 GHz, frequência usada no mundo (MOURÃO, 2021).

O uso de altas frequências se faz necessário para fornecer maior largura de banda e mais velocidade. No entanto, essas ondas têm uma propagação limitada e são facilmente bloqueadas por obstáculos, como edifícios e vegetação densa, ocasionando uma cobertura menor e uma maior atenuação do sinal. Esses efeitos podem comprometer a cobertura interna por meio das redes 5G.

Dispositivos *hotspot* internos, estrategicamente distribuídos, garantem a cobertura por meio de tecnologias Wi-Fi ou 5G. Para tanto, é fundamental otimizar recursos ao mesmo tempo que é garantida a cobertura em todos os ambientes internos de uma edificação. Neste caso, é de grande utilidade realizar a predição do campo de cobertura das células Wi-Fi ou 5G. Desta forma, o 5G, por exemplo, poderá atender tanto ambientes externos quanto ambientes internos de forma definitiva.

Diferentemente da predição de campo para redes celulares, a predição em redes internas tem sido pouco explorada com relação a modelos de propagação de ondas. A predição de campo desempenha um papel essencial na implantação e otimização de redes de comunicação móvel. Nos sistemas 5G, em particular, em que a cobertura e a capacidade são fatores críticos, os modelos de propagação são usados para prever o comportamento das ondas de rádio e estimar a intensidade do sinal em diferentes áreas geográficas. Esses modelos fornecem tanto informações valiosas para a concepção de redes eficazes, quanto planejamento da disposição de antenas e alocação de recursos, sendo indispensáveis para um gerenciamento eficiente e garantia da qualidade de serviço nas redes 5G (SERETIS; SARRIS, 2022).

Neste contexto, o presente trabalho propõe a criação de um modelo de predição para ambientes internos. O projeto tem como objetivo criar um modelo mais prático e de fácil implementação para tornar o planejamento de redes sem fio internas mais rápido e eficaz.

1.1 Justificativa

Modelos de predição empíricos e determinísticos de propagação foram amplamente estudados e aplicados durante os anos (AKHPASHEV; ANDREEV, 2016; FARHOUD; EL-KEYI; SULTAN, 2013; SCHAUBACH; DAVIS; RAPPAPORT, 1992; THEOFILOLOGIANNAKOS; XENOS; YIOULTSIS, 2009). Entretanto, mesmo mostrando algum nível de eficiência, esses modelos apresentam dificuldades de capturar toda a complexidade do efeito das ondas e do ambiente que elas se propagam e também possuem uma alta demanda de processamento computacional (SERETIS; SARRIS, 2022).

Técnicas de aprendizado de máquina (ML) foram desenvolvidas e aprimoradas para substituir os modelos de predição empíricos e determinísticos de propagação de ondas. Os modelos de ML são geralmente voltados para a predição do *Path Loss* (PL), que é a redução na densidade de potência de uma onda eletromagnética à medida que ela se propaga pelo espaço, principalmente nos casos de ambientes *outdoor* (JO *et al.*, 2020; SOTIROUDIS; SIAKAVARA, 2015), e se estendendo ao auxílio do planejamento da rede em ambientes *indoor* (SANTANA *et al.*, 2022). Existem ainda modelos de propagação para ambientes externos com uso de técnicas de ML que utilizam o mesmo local de mapeamento e de coleta de dados para treinamento e teste (JO *et al.*, 2020; NAGAO; HAYASHI, 2020; SOTIROUDIS; SIAKAVARA, 2015), não permitindo a comprovação da generalidade destes modelos.

Em Bakirtzis *et al.* (2022a) e Santana *et al.* (2022), são implementados modelos genéricos eficazes para ambientes *indoor*, nos quais são utilizados uma U-NET modificada e algoritmo genético respectivamente.

Inspirado nestes trabalhos, é proposto um modelo genérico de predição de propagação de ondas em um ambiente interno utilizando *Long Short-Term Memory* (LSTM), este já vem sendo usado para predição em ambientes externos (SASAKI *et al.*, 2021; JIANG; SCHOTTEN, 2020) e localização em ambientes internos (FAN *et al.*, 2020; XU; ZHU; ZHU, 2019).

O modelo genérico proposto utiliza cinco parâmetros de entrada: distância, número de paredes, ângulos vertical e de azimute, e *Free Space Path Loss* (FSPL); e um parâmetro de saída: Intensidade do Sinal Recebido (RSS). São realizadas leituras de potência em quatro ambientes diferentes para, juntamente com os outros 5 parâmetros, montar uma base de dados. Inspirado em Bakirtzis *et al.* (2022a), são utilizadas técnicas de processamento de imagens para automatizar a extração de parâmetros, como ângulo, distância e número de paredes, a partir da imagem digital da planta baixa do ambiente.

A base gerada foi então dividida em conjuntos de teste e treinamento, de acordo com os locais de medição. Uma das contribuições deste trabalho é propor uma abordagem para extrapolar a base de treino, em que dados sintéticos são gerados com base na potência medida e no diagrama de irradiação da antena de transmissão. Essa abordagem permitiu aumentar em 8 vezes a base de treinamento e reduzir significativamente o erro de predição da rede treinada.

Assim, com parâmetros bem definidos e uma rede neural bem treinada, tem-se a possibilidade da implantação e o uso do modelo para predição, podendo ser usado no planejamento da rede sem fio.

1.2 Objetivo Geral

O objetivo geral deste trabalho é desenvolver um modelo de predição para propagação de ondas eletromagnéticas em ambientes internos, utilizando redes neurais recorrentes *Long Short-Term Memory (LSTM)*.

1.2.1 Objetivos Específicos

- Desenvolver um modelo de predição com baixo percentual de erro, com uma implementação mais simples e que seja eficaz para locais distintos;
- Propor uma metodologia para aumentar sinteticamente a base de amostras de treinamento, sem a necessidade de medições in loco;
- Apresentar um *framework* para extração automática dos atributos espaciais a partir da imagem digital da planta baixa;
- Propor uma metodologia que auxilie o planejamento de redes sem fio.

1.3 Organização da Dissertação

O Capítulo 2 explora os conceitos utilizados no desenvolvimento do modelo de predição proposto. Inicialmente os modelos clássicos, empíricos e determinísticos, são apresentados, seguidos dos modelos baseados em aprendizagem de máquina e da rede LSTM.

O Capítulo 3 traz a metodologia proposta e a obtenção dos parâmetros utilizados na rede neural. Neste é apresentado o algoritmo para automação da extração de parâmetros a partir da imagem da planta baixa do ambiente. Em seguida, é explicada a técnica proposta para geração de amostras sintéticas de treinamento.

No Capítulo 4 são apresentados e discutidos os resultados obtidos, comparando o modelo proposto com os modelos clássicos, para melhor avaliação.

Por fim, o Capítulo 5 expõe as conclusões relacionadas aos resultados obtidos, além de apresentar sugestões para trabalhos futuros.

2 MODELOS DE PREDIÇÃO

Neste capítulo são introduzidos conceitos e definições importantes presentes na literatura, sendo fundamentais para este trabalho. Inicialmente são apresentados alguns modelos de predição empíricos para ambientes internos, seguidos de exemplos utilizando aprendizado de máquina e também será abordada a rede neural que é utilizada no modelo de predição proposto. Por fim, são apresentadas as métricas de validação e a revisão bibliográfica.

2.1 Modelos de Predição Empíricos e Determinísticos

Vários modelos de predição empíricos e determinísticos foram criados com o passar dos anos. Os modelos empíricos são baseados em medições e os modelos determinísticos, ou teóricos, utilizam a teoria eletromagnética de propagação de ondas (SANTOS, 2016). Os modelos empíricos são computacionalmente eficientes, mas não conseguem capturar todo o espectro dos efeitos de onda complexos que geralmente determinam o desempenho de um link sem fio. Já os modelos determinísticos, embora com o passar dos anos apresentem certa preferência de uso por obter predições mais exatas, possuem uma alta demanda computacional (SERETIS; SARRIS, 2022; LÓPEZ-BARRANTES *et al.*, 2012). Os modelos empíricos ITU, Log-Distance e *Cost-231 Multi-Wall* (RATH *et al.*, 2017; HOSSEINZADEH *et al.*, 2017; MUKTI *et al.*, 2021), são apresentados a seguir.

2.1.1 Modelo ITU

O modelo ITU, para atenuação interna, estima o *Path Loss* dentro de uma área de um edifício. Pode ser aplicado a frequências de 900 MHz a 5,2 GHz e é dado por

$$PL_{ITU}(dB) = 20\log_{10}(f) + N\log_{10}(d) + P_f(q) - 28, \quad (2.1)$$

em que PL é o *Path Loss*, f é a frequência em MHz, N é o coeficiente de perda de potência à distância, d é a distância entre o transmissor e o receptor em metros, q é o número de andares entre o transmissor e o receptor e P_f é o fator de penetração de perda por andar, que, por sua vez, é igual a zero quando há um transmissor e um receptor no mesmo andar.

2.1.2 Modelo Log-Distance

O modelo Log-Distance é muito semelhante ao ITU, tendo apenas uma diferença no uso de um termo adicional que considera os efeitos de sombreamento. Estes são efeitos das flutuações

na potência do sinal recebido devido à obstrução entre o transmissor e o receptor . O modelo Log-distance é dado por

$$PL_{Log-Distance}(dB) = PL_0 + 10n \log_{10}\left(\frac{d}{d_0}\right) + X_\sigma, \quad (2.2)$$

em que PL é o *Path Loss*, PL_0 é a perda no espaço livre (dB) a uma distância de referência, d_0 , de 1 metro, n é o expoente de perda de caminho, d é a distância entre o transmissor e o receptor em metros e X_σ é uma variável aleatória Gaussiana (dB) com média zero e desvio padrão σ (dB).

2.1.3 Modelo Cost-231 Multi-Wall

O modelo *Cost-231 Multi-Wall* é usado para predição do *Path Loss* em ambientes *indoor* e tem como diferencial o uso de termos relacionados ao tipo de material e a quantidade dos obstáculos entre o transmissor e o receptor, sendo mostrado a seguir:

$$PL_{Cost-321}(dB) = PL_d + \sum_{i=1}^T K_{wi} L_{wi} + K_f L_f. \quad (2.3)$$

em que PL é o *Path Loss*, PL_d é a perda no espaço livre (dB) a uma distância, d , a distância em metros entre o transmissor e o receptor, K_{wi} é o número de paredes do tipo i , L_{wi} é o valor de atenuação de paredes do tipo i (dB), K_f é o número de andares entre o transmissor e receptor, e L_f é o valor de atenuação do andar (dB).

2.2 Modelos baseados em aprendizado de máquina

Os modelos de propagação orientados por aprendizado de máquina são ferramentas promissoras para solucionar a divisão entre acurácia e eficiência presente nos modelos de predição. Estes podem ser treinados de modo *offline*, utilizando dados medidos ou sintéticos (simulados) (SERETIS; SARRIS, 2022).

Várias técnicas de aprendizado de máquina (ML) foram desenvolvidas e aprimoradas durante os anos, visando sempre aumentar os níveis de acurácia e eficiência dos modelos e substituir os modelos empíricos e determinísticos. Esses modelos foram aplicados tanto em ambientes externos (JO *et al.*, 2020; SOTIROUDIS; SIAKAVARA, 2015), quanto em ambientes internos (SANTANA *et al.*, 2022; BAKIRTZIS *et al.*, 2022a). Entretanto, as aplicações em ambientes externos têm sido mais amplamente estudadas, se comparadas às em ambientes internos.

2.2.1 Desenvolvimento de um modelo de predição de propagação de ondas

Ao propor um modelo de predição de propagação de ondas baseado em ML, deve-se ter em mente a escolha dos parâmetros de entrada, do modelo de ML e do parâmetro de saída (SERETIS; SARRIS, 2022). Os parâmetros de entrada devem conter características relevantes ao problema, sendo compactos para evitar um longo período de processamento. Esses dados podem ser medidos ou gerados (sintéticos). A escolha do modelo de ML é muito importante e complexa, pois existem inúmeras opções de técnicas que podem ser utilizadas e por meio de testes é possível escolher a que melhor se adequa à resolução do problema. Finalmente, o parâmetro de saída deve conter informações úteis sobre as características de propagação do canal de comunicação. Alguns exemplos de escolhas desses tópicos são mostrados na Tabela 1, em que o parâmetro de saída de todos é o *Path Loss*.

Tabela 1 – Exemplos de escolha dos parâmetros de entrada e do modelo de ML.

Artigo	Parâmetros de entrada	Modelo de ML
Bakirtzis <i>et al.</i> (2022a)	Permissividade e condutividade dos materiais, distância entre o transmissor e cada ponto da planta e FSPL	U-NET modificada
Sasaki <i>et al.</i> (2021)	Frequência, altura das antenas transmissora e receptora, e taxa de amostragem	LSTM
Sotiroudis e Siakavara (2015)	Frequência, distância, separação do edifício, largura das estradas, ângulo de orientação, altura do transmissor, altura do receptor e altura média do edifício	MLP

Fonte: Elaborado pela autora.

Outra parte importante no desenvolvimento do modelo de predição é definir o percentual de dados usado na fase de treinamento e na fase de testes. Geralmente um percentual maior do total de dados é destinado para treino e o restante para teste. No caso de modelos desenvolvidos para predição de propagação em ambientes internos, são usados ambientes diferentes como divisão. Por exemplo, Bakirtzis *et al.* (2022a) e Santana *et al.* (2022) usam locais de medição diferentes para treinamento e teste.

2.2.2 Tipos de modelos de ML

Como anteriormente citado, a escolha do modelo de aprendizado de máquina faz parte do desenvolvimento do modelo de predição de propagação de ondas. Os modelos de ML podem ser divididos em três grupos, baseados em Redes Neurais Artificiais (RNA), não baseados em RNA e híbridos, que misturam os grupos anteriormente citados.

O uso de modelos baseados em RNA tem crescido cada vez mais e representam a maioria dos trabalhos mais recentes (JIANG; SCHOTTEN, 2020; SASAKI *et al.*, 2021; BAKIRTZIS *et al.*, 2022a).

Dentro desse grupo de modelos baseado em RNA está presente as Redes Neurais Recorrentes (RNR), que são apresentadas no próximo tópico, e que ganharam popularidade por apresentar um comportamento dinâmico, pelo qual sua saída depende não apenas da entrada atual, mas também das entradas anteriores.

2.3 Redes Neurais Recorrentes


Como introduzido anteriormente, as RNRs são redes neurais que levam em conta as entradas anteriores para a saída atual, diferente dos outros tipos de RNA. Logo, estas são redes com *loops* que permitem que as informações persistam, ou seja, não são descartadas informações de entradas anteriores, criando, assim, um certo tipo de memória.

As RNR são ótimas para os casos que precisam de uma memória a curto prazo, mas não para situações que precisam de uma memória de longo prazo. Assim, quanto maior for o espaço entre a saída atual e a memória anterior necessária, menor será a probabilidade da RNR de aprender a conectar as informações (OLAH, 2015).

2.3.1 Long Short-Term Memory-LSTM


A *Long Short-Term Memory (LSTM)*, inicialmente introduzida por Hochreiter e Schmidhuber (1997) e aprimorada nos anos subsequentes, é uma RNR adequada para classificar, processar e prever séries temporais com intervalos de tempo de duração desconhecida. A LSTM também resolve o problema de longo prazo presente nas RNRs.

As RNRs padrão possuem uma estrutura simples com apenas uma camada $\tanh$, tangente hiperbólica, como é ilustrado na Figura 1, em que é gerado um estado h_t a partir de uma entrada x_t e um estado anterior h_{t-1} .

Figura 1 – Arquitetura RNR padrão.

Fonte: Elaborado pela autora.

A LSTM, por sua vez, apresenta uma arquitetura mais complexa com quatro camadas, ilustrada na Figura 2, em que x_t é a entrada que passa por todo o circuito para gerar um estado h_t . h_{t-1} é um estado anterior, C_t um estado variável e C_{t-1} um estado anterior variável. f_t , i_t e o_t funcionam como filtros, deixando ou não passar informações. $\tilde{C}_t$ é um vetor de novos valores candidatos criados pela camada $\tanh$.

Figura 2 – Arquitetura LSTM.

Fonte: Elaborado pela autora.

As camadas simbolizadas pelos blocos laranja na Figura 2 representam as seguintes funções:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (2.4)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (2.5)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C), \quad (2.6)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o), \quad (2.7)$$

em que W são os pesos e b são os bias calibrados pela rede, σ é a função sigmoide, com valores de saída entre 0 e 1, e $\tanh$ é a função tangente hiperbólica, com valores de saída entre -1 e 1. Das Equações (2.4-2.7) C_t e h_t são, respectivamente,

$$C_t = C_{t-1} * f_t + i_t * \tilde{C}_t, \quad (2.8)$$

e

$$h_t = o_t * \tanh(C_t). \quad (2.9)$$

A partir da arquitetura e das equações apresentadas, observa-se que o grande diferencial da LSTM está no estado variável C_t que representa a memória a longo prazo da rede neural.

Primeiramente, é decidido quais informações são descartadas ou não do estado variável anterior C_{t-1} a partir da multiplicação pela função f_t , resultando em valores entre 0 e 1 a partir das variáveis x_t e h_{t-1} . O próximo passo é decidir quais novas informações são adicionadas e isso é feito por meio de i_t e de $\tilde{C}_t$, em que o primeiro tem um resultado entre 0 e 1 a partir das entradas x_t e h_{t-1} e multiplica o segundo deixando passar somente os novos valores candidatos relevantes que serão somados ao C_t .

O estado h_t , que representa a saída, é baseado em uma versão filtrada de C_t ao passar pela função $\tanh$ que retorna um valor entre -1 e 1, sendo multiplicada por o_t , com resultado entre 0 e 1 a partir das entradas x_t e h_{t-1} . Isso irá decidir qual parte dessa versão filtrada irá passar.

A LSTM já vem sendo utilizada para predição de propagação em ambientes externos (SA-SAKI *et al.*, 2021; JIANG; SCHOTTEN, 2020), mas em ambientes internos tem sido explorada somente na localização (FAN *et al.*, 2020; XU; ZHU; ZHU, 2019).

2.4 Métricas de Validação

Para validar e comparar um modelo é preciso a utilização de métricas. Frequentemente são utilizadas as seguintes medidas na avaliação dos modelos de predição: erro médio quadrá-

tico (RMSE), erro absoluto médio (MAE) e erro percentual absoluto médio (MAPE)(NAGAO; HAYASHI, 2020; SOTIROUDIS; SIAKAVARA, 2015; HAYASHI; NAGAO; ITO, 2020; BAKIRTZIS *et al.*, 2022a).

O MAE é a média da diferença entre o valor real e o predito, como mostrado a seguir (LENDAVE, 2021)

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (2.10)$$

em que y representa o valor real e $\hat{y}$ o valor predito. O valor de saída da Equação (2.10) tem a mesma escala dos dados utilizados para predição, por exemplo, se o resultado do MAE for 5 dB, significa que o modelo pode estar errando em média 5 dB para mais ou menos.

O MAPE mostra a porcentagem do valores preditos em relação aos valores reais, ou seja, se o valor de saída for 0,3 (30%), significa que o modelo faz previsões que em média a diferença entre o valor previsto e o real equivale a 30% do valor real tanto para mais como para menos. O MAPE é dado por (LENDAVE, 2021)

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|, \quad (2.11)$$

em que novamente y representa o valor real e $\hat{y}$ o valor predito.

O RMSE é a raiz quadrada da média dos quadrados dos erros, entre o valor previsto pelo modelo e o valor real e é calculado como (2.12) (LENDAVE, 2021),

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (2.12)$$

São usados os mesmos parâmetros das equações anteriores e seu resultado pode ser interpretado da mesma forma como o MAE.

Cada métrica contribui individualmente para a validação do modelo, mas juntas trazem uma visão mais ampla da avaliação.

2.5 Revisão Bibliográfica

Como exposto neste capítulo, primeiramente foram desenvolvidos modelos de predição empíricos e determinísticos. Apesar de eles trazerem, relativamente, bons resultados, tais modelos foram substituídos pelos baseados em aprendizado de máquina, cada vez mais aprimorados.

Com o passar dos anos vários modelos de predição de propagação de ondas, baseados em ML, foram desenvolvidos e tiveram sua eficácia comprovada. Porém, em sua maioria, voltados para ambientes *outdoor* (SOTIROUDIS; SIAKAVARA, 2015; JO *et al.*, 2020; NAGAO; HAYASHI, 2020), sendo os ambientes *indoor* pouco explorados.

Em sua maioria, os trabalhos voltados para ambientes internos são para fins de localização (FAN *et al.*, 2020; XU; ZHU; ZHU, 2019; XU; ZHANG; PENG, 2023; RAJ; S., 2023; SULAIMAN *et al.*, 2023; YANG *et al.*, 2023; WANG *et al.*, 2023; ZHAO *et al.*, 2023; KUMAR; SINGH; CHAURASIYA, 2023; JEANNICK; WANG; MA, 2023). Grande parte das pesquisas é voltada para a predição do mapa do Indicador de Intensidade do Sinal recebido (RSSI) para uso em localização como em Raj e S. (2023) que utiliza de técnicas de *Deep Learning* ou são usadas outras técnicas com a finalidade de aplicação em localização como em Jeannick, Wang e MA (2023) em que é proposto um sistema baseado em *edge computing*.

Também se destacam pesquisas que não são voltadas para o desenvolvimento de um modelo de predição com a finalidade de planejamento de redes sem fio, mas trazem contribuições relevantes para a comunicação sem fio em ambientes *indoor* (MALLIK *et al.*, 2022; BAKIRTZIS *et al.*, 2022b; DUBEY *et al.*, 2022; XIAO; LI, 2023). Em Mallik *et al.* (2022) e Bakirtzis *et al.* (2022b) são usadas técnicas de ML, no primeiro para criar um mapa de intensidade com o objetivo de medir a exposição e alocar melhor os recursos de rádio, e no segundo para prever a intensidade do sinal recebido em um determinado ambiente interno. Já em Dubey *et al.* (2022) e Xiao e Li (2023) não são usadas técnicas de aprendizado de máquina e são voltados para predição de características de propagação como o RSS, em que o primeiro utiliza da aproximação Rytov de alta frequência e o segundo é baseado em um algoritmo de diferenças finitas no domínio do tempo.

Alguns modelos mais recentes trazem técnicas computacionais para desenvolver um modelo de predição eficiente para ambientes *indoor* (BAKIRTZIS *et al.*, 2022a; SANTANA *et al.*, 2022). Entretanto, em Santana *et al.* (2022) são usadas uma quantidade de parâmetros de entrada um pouco maior, o que pode tornar a aquisição e posteriormente a predição mais custosas, já em Bakirtzis *et al.* (2022a) foram utilizados a permissividade e a condutividade dos materiais do prédio, o que nem sempre é fácil de se obter.

Os modelos anteriormente citados, embora sejam eficientes e com generalidade comprovada, não são necessariamente modelos simples de se replicar, muito menos de serem utilizados para predição.

Buscando um modelo com uma implementação, e posteriormente uma aplicação mais simples e eficiente, foi verificado a efetividade de modelos de predição utilizando LSTM e suas variações, porém voltados para ambientes externos (SASAKI *et al.*, 2021; JIANG; SCHOTTEN, 2020) e para localização em ambientes internos (FAN *et al.*, 2020; XU; ZHU; ZHU, 2019; YANG *et al.*, 2023; WANG *et al.*, 2023; ZHAO *et al.*, 2023; KUMAR; SINGH; CHAURASIYA, 2023).

2.5.1 Discussão

Na Tabela 2 é feita a comparação entre os trabalhos mais recentes relacionados ao presente projeto indicando a aplicação, predição, uso de ML e ambiente de cada um dos artigos.

Tabela 2 – Trabalhos mais recentes relacionados ao presente projeto.

Artigo	Aplicação			Predição		
	Localização	Modelo de Predição de Propagação	Planejamento de Rede	<i>Path Loss</i>	RSS	Outros
Sotiroudis e Siakavara (2015)		x		x		
Jo <i>et al.</i> (2020)		x		x		
Nagao e Hayashi (2020)		x				x
Sasaki <i>et al.</i> (2021)		x		x		
Jiang e Schotten (2020)		x				x
Fan <i>et al.</i> (2020)	x					x
Xu, Zhu e Zhu (2019)	x					x
Xu, Zhang e Peng (2023)	x				x	
Raj e S. (2023)	x					x
Sulaiman <i>et al.</i> (2023)	x					x
Yang <i>et al.</i> (2023)	x				x	x
Wang <i>et al.</i> (2023)	x					x
Zhao <i>et al.</i> (2023)	x					x
Kumar, Singh e Chaurasiya (2023)	x					x
Jeannick, Wang e MA (2023)	x					x
Mallik <i>et al.</i> (2022)		x				x
Bakirtzis <i>et al.</i> (2022b)		x				
Dubey <i>et al.</i> (2022)		x			x	
Xiao e Li (2023)		x				x
Bakirtzis <i>et al.</i> (2022a)		x		x		
Santana <i>et al.</i> (2022)		x	x	x		

Fonte: Elaborado pela autora.

Tabela 2 – Trabalhos mais recentes relacionados ao presente projeto (cont).

Artigo	Utiliza ML		Ambiente	
	Sim	Não	Indoor	Outdoor
Sotiroudis e Siakavara (2015)	x			x
Jo <i>et al.</i> (2020)	x			x
Nagao e Hayashi (2020)	x			x
Sasaki <i>et al.</i> (2021)	x			x
Jiang e Schotten (2020)	x			x
Fan <i>et al.</i> (2020)	x		x	
Xu, Zhu e Zhu (2019)	x		x	
Xu, Zhang e Peng (2023)	x		x	
Raj e S. (2023)	x		x	
Sulaiman <i>et al.</i> (2023)	x		x	
Yang <i>et al.</i> (2023)	x		x	
Wang <i>et al.</i> (2023)	x		x	
Zhao <i>et al.</i> (2023)	x		x	
Kumar, Singh e Chaurasiya (2023)	x		x	
Jeannick, Wang e MA (2023)		x	x	
Mallik <i>et al.</i> (2022)	x		x	
Bakirtzis <i>et al.</i> (2022b)	x		x	
Dubey <i>et al.</i> (2022)		x	x	
Xiao e Li (2023)		x	x	
Bakirtzis <i>et al.</i> (2022a)	x		x	
Santana <i>et al.</i> (2022)	x		x	

Fonte: Elaborado pela autora.

Com base nos estudos realizados, pode-se confirmar a viabilidade de modelos voltados para predição de propagação de ondas em redes sem fio. Os mais recentes se provando eficientes e com baixas taxas de erro, porém, podem nem sempre ser viáveis para todos os ambientes.

Assim, um diferencial para qualquer modelo de predição seria buscar não apenas um modelo com baixa taxa de erros, mas também um que tenha uma implementação e aplicação simplificadas, podendo ser aplicado a diferentes realidades e ambientes.

Além de trazer uma quantidade de parâmetros mínima, também espera-se uma maior facilidade de coleta dos dados, a fim de tornar a futura aplicação mais acessível e factível para diferentes ambientes internos, podendo, assim, ser utilizado no planejamento de redes sem fio de forma mais prática.

3 IMPLEMENTAÇÃO DO MODELO DE PREDIÇÃO

Neste capítulo são apresentados os principais conceitos utilizados no desenvolvimento do modelo de predição. Inicialmente são apresentados os equipamentos utilizados, os locais de medição e como são extraídos os parâmetros de entrada e saída da rede. Por fim é mostrada a metodologia utilizada na geração de dados sintéticos para aumentar a precisão da rede e a configuração das camadas da rede neural do modelo de predição.

3.1 Equipamentos

A topologia para realizar o experimento é ilustrada na Figura 3. No diagrama tem-se o roteador (1) conectado ao rádio (2) que opera em uma frequência de 2,4GHz e é conectado a antena de transmissão (3) omnidirecional de 10dBi. A medição (receptor) é feita por meio de uma antena (4) parabólica de 20dBi conectada ao analisador de espectro (5) Tektronix, este tendo sua saída mostrada na tela do *notebook* (6) em que está conectado.

Figura 3 – Topologia dos equipamentos utilizados nas medições.




Fonte: Elaborado pela autora.

3.2 Locais de Medição

No total foram realizadas medições em quatro locais, aqui chamados de Locais 1,2,3 e 4, em que os dois primeiros foram usados para treinamento e os dois últimos para teste.

Na Figura 4 é mostrada a planta o Local 1 com seus respectivos pontos de medição (Rx) numerados, destacando a quantidade de medições em cada um, e a posição da antena de transmissão (Tx). Para indicação do ângulo de azimute, uma direção de referência é adotada como o ângulo 0° da antena Tx, sendo indicado pela linha tracejada nos diagramas.


Figura 4 – Planta baixa do Local 1 em que dados de treinamento foram adquiridos, com indicação da antena de transmissão (Tx ■), pontos de medição (Rx ●), e 0° direção de referência (d_x - -).



Fonte: Elaborado pela autora.

A planta do Local 2 com seus respectivos pontos de medição (Rx) numerados, posição da antena de transmissão (Tx) e direção de referência é ilustrada na Figura 5. Os conjuntos de dados dos Locais 1 e 2 foram utilizados para treinamento da rede.


Figura 5 – Planta baixa do Local 2 em que dados de treinamento foram adquiridos, com indicação da antena de transmissão (Tx ■), pontos de medição (Rx ●), e 0° direção de referência (d_x - -).



Fonte: Elaborado pela autora.

Os dados coletados no Local 3 foram utilizados para teste da rede e os pontos de medição (Rx) e transmissão (Tx) podem ser observados na Figura 6.


Figura 6 – Planta baixa do Local 3 em que dados de teste foram adquiridos, com indicação da antena de transmissão (Tx ■), pontos de medição (Rx ●), e 0° direção de referência ($\mathbf{d_x}$ - -).



Fonte: Elaborado pela autora.

As medições no último Local também foram utilizadas na etapa de teste e sua respectiva planta com os pontos de Rx, Tx e a direção de referência são ilustrados na Figura 7.

Figura 7 – Planta baixa do Local 4 em que dados de teste foram adquiridos, com indicação da antena de transmissão (Tx ■), pontos de medição (Rx ●), e 0° direção de referência ($\mathbf{d_x}$ - -).



Fonte: Elaborado pela autora.

3.3 Parâmetros


Neste trabalho são adotados seis parâmetros, sendo cinco de entrada e um de saída. A potência do sinal, parâmetro de saída, é medida nos pontos Rx. Com base no sistema de transmissão e nas informações espaciais da planta baixa, os outros cinco parâmetros são calculados: distância; número de paredes; ângulos de azimute e vertical; *Free Space Path Loss* (FSPL).

A Figura 8 mostra uma visão superior da posição das antenas Tx e Rx, em que $\mathbf{d}_x$ é a direção de referência, d é a distância entre as antenas Tx e Rx e ϕ é o ângulo de azimuth. O ângulo vertical na Figura 9 é calculado com base na altura das antenas e na distância entre elas:

$$\theta = \arctg\left(\frac{H-h}{d}\right), \quad (3.1)$$


em que H e h são, respectivamente, as alturas das antenas transmissora e receptora e d a distância entre elas.

Figura 8 – Ângulo de Azimute.



Fonte: Elaborado pela autora.

Figura 9 – Ângulo Vertical.



Fonte: Elaborado pela autora.

O FSPL é a perda de potência do sinal, levando em consideração o espaço livre, ou seja, não considerando nenhum obstáculo. Este parâmetro é calculado como (MATHWORKS, 2011)

$$FSPL(dB) = 20 \log_{10}\left(\frac{4\pi d}{\lambda}\right), \quad (3.2)$$

em que λ é o comprimento de onda do sinal e d é a distância entre as antenas.

É importante destacar o uso de uma quantidade simplificada de parâmetros de entrada e que não são utilizadas características mais detalhadas dos materiais dos obstáculos como ocorre na maioria dos modelos de predição relacionados a propagação de ondas em ambientes internos. Isso torna a implementação e a futura aplicação do modelo mais simples e eficaz.

O Anexo A apresenta, passo a passo, como os parâmetros descritos nesta seção foram computados a partir da planta baixa e dos dados de altura das antenas.

3.4 Dados Sintéticos

Para aumentar a base de treinamento sem a necessidade de mais amostras in loco, é proposta a geração de dados sintéticos de treinamento com base em amostras de potência real dos Locais de medição 1 e 2.


A Figura 10 mostra posições de amostras sintéticas geradas a partir de dados reais obtidos conforme explicado na Figura 4. Para o Local 2 coletou-se outro conjunto de amostras, estas foram utilizadas para geração de dados sintéticos (Figura 11).

Para gerar dados sintéticos, escolhemos 12 amostras in loco do Local 1, e 16 do Local 2 (•). Do Local 1 inicialmente foram selecionados os pontos com ângulos em 0° e 90° , posteriormente foram selecionados pontos que tivessem valores diferentes entre si dos outros parâmetros utilizados, a fim de obter uma variedade maior de dados. Já no Local 2 a coleta de dados foi voltada para a geração de dados sintéticos, na qual as medições foram executadas em visada direta e com o espaçamento de 1 em 1 metro, obtendo, assim, uma maior quantidade de dados em várias distâncias. Foram escolhidos dois locais para treinar a rede com ambientes diferentes.

Cada amostra sintética (•) foi gerada com passo de 20 graus e raio igual à distância das amostras reais. A potência do sinal de amostras sintéticas é estimada a partir do padrão de radiação da antena (Figura 12) e a potência real do sinal com igual distância Tx-Rx.


Na metodologia proposta, todos os dados do Local 1 e Local 2 são utilizados para o treinamento do LSTM. Outros dois ambientes, aqui nomeados, Local 3 e Local 4 são usados apenas para teste da rede, conforme será apresentado no próximo capítulo.

Figura 10 – Distribuição espacial (distância x ângulo de azimuth) de amostras de treino reais (•) e sintéticas (*) do Local 1.




Fonte: Elaborado pela autora.

Figura 11 – Distribuição espacial (distância x ângulo de azimuth) de amostras de treino reais (•) e sintéticas (*) do Local 2.



Fonte: Elaborado pela autora.

Figura 12 – Diagrama de radiação da antena transmissora.

Fonte: Adaptada de (NETWORKS,).

3.5 PL versus RSS

Na literatura, a maioria dos autores prefere a predição do *Path Loss* (PL). Este caracteriza-se pela densidade de potência de uma onda eletromagnética à medida que ela se propaga pelo espaço. Entretanto, para encontrarmos o PL é necessário o RSS, sendo este a medida da intensidade do sinal recebido, logo, essas duas medidas estão diretamente relacionadas.

Com o objetivo de simplificar o modelo proposto, utiliza-se como parâmetro de saída o RSS uma vez que o cálculo do PL é obtido a partir da intensidade do sinal recebido como pode ser visto a seguir

$$PL(dB) = Eirp(dBm) - RSS(dBm), \quad (3.3)$$

em que *Eirp* é a potência irradiada isotrópica efetiva da antena transmissora, que por sua vez é dado a partir do valor da potência do transmissor (dBm) somado ao ganho da antena (dBi) e subtraído qualquer perda ocasionada pelos cabos e conectores (dB). Assim, podemos comparar tanto os resultados do RSS como do PL.

3.6 Configuração da Rede Neural do Modelo


A fim de desenvolver o modelo proposto, leva-se em consideração as camadas utilizadas em Sasaki *et al.* (2021) para aplicação em área externa. Tomando como base, configurou-se os tipos de camadas da rede neural, sendo estas: uma Camada de Entrada, uma Camada LSTM com 300 unidades ocultas, uma Camada Totalmente Conectada com 30 unidades, uma camada totalmente conectada com 20 unidades, uma camada totalmente conectada com 10 unidades e uma camada totalmente conectada com 1 unidade.

A Camada de Entrada é a entrada do modelo em que são inseridos os dados dos parâmetros de entrada. Já as Camadas Totalmente Conectadas vão multiplicar as informações por uma matriz de pesos e, em seguida, adicionar um vetor de *bias*, calibrados pela própria rede para nivelar as informações e mapear a saída da camada LSTM para um tamanho de saída desejado.

Nas opções de treinamento foi utilizado o otimizador Adam, o mesmo escolhido por Sasaki *et al.* (2021), um gradiente descendente estocástico, e 300 *epoch*, em que uma *epoch* no aprendizado de máquina significa uma passagem completa do conjunto de dados de treinamento pelo algoritmo. Os dados foram ordenados de acordo com a distância entre o ponto de medição e a antena transmissora.

Na Figura 13 ilustra-se a rede treinada inserindo os parâmetros de entrada na Camada de Entrada e obtendo o valor predito de RSS após a última Camada Totalmente Conectada.

Todo o desenvolvimento da rede foi feito na linguagem e ferramenta MATLAB, a partir de um notebook com processador CORE i5, obtendo, assim, um tempo de treinamento da rede neural igual a 30 segundos.

Figura 13 – Representação das camadas da rede neural do modelo

Fonte: Elaborado pela autora.

4 RESULTADOS E COMPARAÇÃO COM OUTROS MODELOS

Para avaliar a metodologia proposta, utiliza-se três métricas: o erro quadrático médio (RMSE), o erro absoluto médio (MAE) e o erro percentual absoluto médio (MAPE).

O sinal foi transmitido na frequência de 2,4GHz por uma antena omnidirecional de 10dBi, com $H = 1,9\text{m}$, e medido através de uma antena parabólica de 10dBi com $h = 1,0\text{m}$. Todos os locais do experimento são salas e corredores de escritórios, com paredes de alvenaria. A distância e o número de paredes foram calculados automaticamente a partir da planta baixa dos locais.

4.1 Avaliação dos dados sintéticos

Inicialmente é apresentado na Tabela 3 um comparativo para demonstrar a melhora do LSTM com aplicação de dados sintéticos, utilizando como referência o Local 3. Todas as medidas de avaliação apresentaram resultados superiores quando aumentada a base de dados de treinamento.

Tabela 3 – Influência dos dados de treinamento no desempenho do método, usando o Local 3 como referência.

	Usando somente dados reais 36 pontos	Usando dados reais e sintéticos 298 pontos
RMSE (dB)	8,65	4,87
MAE (dB)	6,85	3,71
MAPE	0,09	0,05

Fonte: Elaborado pela autora.

4.2 Comparação com outros modelos

Resultados de predição foram obtidos para uma distância de até 15 metros do local da antena transmissora, e foram comparados com os modelos ITU, Cost-321 e Log-Distance, modelos empíricos de predição (RATH *et al.*, 2017; HOSSEINZADEH *et al.*, 2017).

Os valores dos parâmetros N , n e σ , mostrados na Tabela 4, foram ajustados experimentalmente como em Rath *et al.* (2017), Chrysikos, Georgopoulos e Kotsopoulos (2009) e Hosseinzadeh *et al.* (2017), visando assim minimizar os valores de MSE, MAPE e RSME.

A Tabela 5 apresenta as métricas de avaliação dos modelos aplicadas ao conjunto de dados que foram utilizados para teste (Locais 3 e 4).

Tabela 4 – Parâmetros dos modelos ITU, Cost-321 e Log-Distance.

Modelo	Parâmetros	Valor
ITU	N	20,0
Cost-321	L_{wi}	2
Log-Distance	n	1,7
	σ	1,5

Fonte: Elaborado pela autora.

Tabela 5 – Performance dos modelos de predição.

Modelo	Local	RMSE (dBm)	MAE (dBm)	MAPE (%)
ITU	3	11,17	9,14	14,54
	4	7,02	5,47	8,01
Cost-321	3	11,24	8,96	13,58
	4	9,19	8,25	11,09
Log-Distance	3	10,65	8,77	14,01
	4	6,82	5,16	7,73
Modelo Proposto	3	4,87	3,71	5,35
	4	5,28	4,10	6,03

Fonte: Elaborado pela autora.

A partir dos resultados obtidos é verificado que o modelo proposto apresenta um menor percentual de erro quando comparado com os modelos empíricos (Tabela 5). Mesmo que para o Local 4, a diferença entre os métodos seja menor que no Local 3, ela ainda é significativa, uma vez que estamos trabalhando em dBm (escala logarítmica).

É possível entender melhor a qualidade do modelo apresentado por meio de gráficos, a fim de comparação. Observa-se os valores preditos em comparação com os valores reais e como cada modelo se comporta.

A Figura 14 mostra os gráficos do modelo ITU, estes apresentam sempre uma curva, sendo decrescente no RSS e crescente no PL. Compreende-se que quanto maior for a distância menor será a potência do sinal e, portanto, maior será o *Path Loss*. Esse resultado é coerente, porém como o modelo não leva em conta outras características dos locais de medição não é possível obter uma predição mais precisa.

Os gráficos do modelo Cost-321 são ilustrados na Figura 15 onde não nota-se um padrão no seu comportamento. Porém, o fato de usar o material que é feito os obstáculos entre o transmissor e receptor como parâmetro é possível obter até mesmo resultados iguais aos reais, mas de uma forma geral somente esse aspecto não é suficiente para obter uma predição precisa.


A performance na predição realizada através do modelo Log-distance é mostrada na Figura 16 que apresenta um comportamento similar ao do modelo ITU, mas nesse caso não resulta em uma curva, decrescente ou crescente. Este modelo apresenta uma predição mais ajustada e com variações que, relativamente, tentam seguir os valores medidos. Entretanto, também por não

levar em conta as características dos locais, acaba não trazendo resultados satisfatórios, mesmo no caso do Local 4, o qual apresenta uma menor diferença nas métricas, comparativamente ao nosso modelo.


Os gráficos de comparação dos valores reais e preditos para o modelo proposto estão presentes na Figura 17, onde é possível observar que as curvas se ajustam. Não é observado apenas um padrão decrescente ou crescente, mostrando que no aprendizado a rede neural foi capaz de modelar as variações do RSS e PL devido aos possíveis fatores que interferem na propagação *indoor*.

Assim, demonstra-se que o modelo apresentado resulta em previsões que melhor se assemelham as medições realizadas, pois leva em conta características do ambiente em que esses dados foram coletados.


Figura 14 – Predição do RSS e PL utilizando o modelo de predição ITU.




Fonte: Elaborado pela autora.

Figura 15 – Predição do RSS e PL utilizando o modelo de predição Cost-321.


Fonte: Elaborado pela autora.

Figura 16 – Predição do RSS e PL utilizando o modelo de predição Log-Distance.

Fonte: Elaborado pela autora.

Figura 16 – Predição do RSS e PL utilizando o modelo de predição Log-Distance.

Fonte: Elaborado pela autora.

Figura 17 – Predição do RSS e PL utilizando o modelo de predição proposto.

Fonte: Elaborado pela autora.

4.3 Mapa de intensidade RSS


Também é utilizado o modelo apresentado no presente trabalho para gerar um mapa de cores da predição do RSS nos locais usados para teste (Figura 18), obtendo, assim, uma visão mais ampla da aplicação do modelo de predição. É possível visualizar os pontos de maior e menor intensidade de potência em todo o local, possibilitando a aplicação do presente modelo no planejamento da rede sem fio, pois fornece uma estimativa da cobertura da antena.

O *colormap* traz as intensidades de potência em toda a planta, destacando que quanto mais escuro for, maior será o valor do RSS, ou seja, maior será a potência do sinal. Na Figura 10(a), a antena transmissora está posicionada no corredor principal, nas coordenadas (0,0), em metros. Na Figura 10(b), a antena está posicionada quase no centro da imagem, também nas coordenadas (0,0), em metros. Em ambos os casos a antena pode ser vista como um ponto azul escuro isolado, uma vez que ela representa o ponto em que o RSS será máximo.


É visto que não somente a distância influencia no valor do RSS, mas também observa-se que o ângulo azimute, com relação a antena transmissora, e os obstáculos, nesse caso paredes, irão afetar os valores preditos.

É importante observar também a influência do ângulo vertical e, consequentemente, a altura da antena receptora. Este parâmetro foi relevante apenas em pontos próximos a antena transmissora, e menor em pontos distantes. A potência medida próximo da antena transmissora, na altura desta ($h = 1,9\text{m}$), foi de -14dBm , porém na base da antena ($h = 1\text{m}$) essa potência é de -40dBm , como visto nos mapas. Diferenças desta magnitude não foram observadas em pontos mais distantes da antena transmissora. Por essa razão optou-se por manter constante a altura da antena receptora.

Figura 18 – Colormap do RSS predito pelo método proposto em cada local de teste, com indicação da antena de transmissão (Tx ■).



(a) Local 3



(b) Local 4

Fonte: Elaborado pela autora.

5 CONCLUSÕES

Ao longo do estudo e pesquisa foi desenvolvido um modelo de predição baseado em LSTM para cobertura de redes sem fio em ambientes *indoor*, este sendo validado por meio de métricas amplamente utilizadas na literatura e comparado com outros modelos de predição.

O presente modelo também foi desenvolvido não apenas voltado para obtenção de baixas taxas de erro, mas também pensando em uma aplicação futura menos complexa e aplicabilidade em diferentes ambientes internos.

Tendo como parâmetro de saída o RSS, foi possível também realizar aplicações em plantas reais, trazendo como contribuição o uso do modelo no planejamento de redes sem fio.

Para isso foi proposta, paralelamente, um metodologia para extrair informações da planta baixa do ambiente. Utilizou-se métodos de processamento digital de imagens para automatizar a extração e predição dos valores de RSS em todo o ambiente. Esta metodologia tornou possível analisar uma quantidade significativa de pontos, fazendo a predição de RSS em uma resolução de 0,06m/pixel.

Outra importante contribuição é a geração de dados sintéticos para aumentar a base de dados de treinamento. Esta comprovadamente tornou possível uma redução significativa nas métricas utilizadas sem a necessidade de novas medições nos locais.

Ao comparar a abordagem proposta aos modelos ITU, Cost-321 e Log-Distance, observou-se que os modelos baseados em aprendizado de máquina podem fornecer predições mais precisas, como menor erro, desde que seja escolhido o conjunto apropriado de parâmetros de treinamento.

Assim, conclui-se que o objetivo geral e os objetivos específicos do presente trabalho foram alcançados, assim como a contribuição de um novo modelo de predição de redes sem fio para ambientes internos com baixas taxas de erros.

5.1 Trabalhos Futuros

Embora os objetivos apresentados no início desse trabalho tenham sido alcançados, ainda é possível avançar no desenvolvimento e aprimoramento do modelo apresentado, logo, a seguir são sugeridos possíveis trabalhos futuros:

- Treinamento: embora alcançou-se uma quantidade de dados de treinamento em que se obteve um percentual de erro baixo, esse banco de dados de treinamento pode ser aumentado, incluindo novas antenas, frequências de transmissão e outros ambientes internos.
- Validação: ainda que o modelo tenha sido validado em mais de um ambiente, mais valida-

ções podem ser feitas para verificar a aplicação do modelo, testando em outros ambientes, com outros tipos de antena e em outras frequências de transmissão.

- Planejamento de Rede: apesar de apresentar como o modelo proposto pode ser utilizado para o planejamento de redes sem fio, não foi feita a aplicação real, somente a simulação. Logo, cita-se como trabalho futuro a implementação de um projeto de rede sem fio baseado no modelo de predição aqui apresentado.

REFERÊNCIAS

- AKHPASHEV, R. V.; ANDREEV, A. V. Cost 231 hata adaptation model for urban conditions in lte networks. In: **2016 17th International Conference of Young Specialists on Micro/Nanotechnologies and Electron Devices (EDM)**. [S.l.: s.n.], 2016. p. 64–66.
- BAKIRTZIS, S. *et al.* Em deepray: An expedient, generalizable and realistic data-driven indoor propagation model. **IEEE Transactions on Antennas and Propagation**, p. 1–1, 2022.
- BAKIRTZIS, S. *et al.* Deepray: Deep learning meets ray-tracing. In: **2022 16th European Conference on Antennas and Propagation (EuCAP)**. [S.l.: s.n.], 2022. p. 1–5.
- CHRYSIKOS, T.; GEORGOPOULOS, G.; KOTSOPOULOS, S. Site-specific validation of its indoor path loss model at 2.4 ghz. In: **2009 IEEE International Symposium on a World of Wireless, Mobile and Multimedia Networks Workshops**. [S.l.: s.n.], 2009. p. 1–6.
- DUBEY, A. *et al.* Received signal strength estimation in indoor environment using high frequency rytov approximation. **IEEE Microwave and Wireless Components Letters**, v. 32, n. 6, p. 788–791, 2022.
- FAN, S. *et al.* A structured bidirectional lstm deep learning method for 3d terahertz indoor localization. In: **IEEE INFOCOM 2020 - IEEE Conference on Computer Communications**. [S.l.: s.n.], 2020. p. 2381–2390.
- FARHOUD, M.; EL-KEYI, A.; SULTAN, A. Empirical correction of the okumura-hata model for the 900 mhz band in egypt. In: **2013 Third International Conference on Communications and Information Technology (ICCIT)**. [S.l.: s.n.], 2013. p. 386–390.
- GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. Upper Saddle River, N.J.: Prentice Hall, 2008. ISBN 9780131687288 013168728X 9780135052679 013505267X. Disponível em: <http://www.amazon.com/Digital-Image-Processing-3rd-Edition/dp/013168728X>.
- GUPTA, A.; JHA, R. K. A survey of 5g network: Architecture and emerging technologies. **IEEE Access**, v. 3, p. 1206–1232, 2015.
- GUPTA, B.; QUAMARA, M. An overview of internet of things (iot): Architectural aspects, challenges, and protocols. **Concurrency and computation**, Wiley Subscription Services, Inc, Hoboken, v. 32, n. 21, p. n/a, 2020. ISSN 1532-0626.
- HAYASHI, T.; NAGAO, T.; ITO, S. A study on the variety and size of input data for radio propagation prediction using a deep neural network. In: **2020 14th European Conference on Antennas and Propagation (EuCAP)**. [S.l.: s.n.], 2020. p. 1–5.
- HOCHREITER, S.; SCHMIDHUBER, J. Long Short-Term Memory. **Neural Computation**, v. 9, n. 8, p. 1735–1780, 11 1997. ISSN 0899-7667. Disponível em: <https://doi.org/10.1162/neco.1997.9.8.1735>.
- HOSSEINZADEH, S. *et al.* Empirical propagation performance evaluation of lora for indoor environment. In: **2017 IEEE 15th International Conference on Industrial Informatics (INDIN)**. [S.l.: s.n.], 2017. p. 26–31.

- JEANNICK, U. I.; WANG, H.; MA, M. Multisource indoor positioning system based on edge computing. In: **2023 IEEE Jordan International Joint Conference on Electrical Engineering and Information Technology (JEEIT)**. [S.l.: s.n.], 2023. p. 154–159.
- JIANG, W.; SCHOTTEN, H. D. Recurrent neural networks with long short-term memory for fading channel prediction. In: **2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring)**. [S.l.: s.n.], 2020. p. 1–5.
- JO, H.-S. *et al.* Path loss prediction based on machine learning techniques: Principal component analysis, artificial neural network, and gaussian process. **Sensors**, v. 20, n. 7, 2020. ISSN 1424-8220. Disponível em: <https://www.mdpi.com/1424-8220/20/7/1927>.
- KUMAR, R.; SINGH, S.; CHAURASIYA, V. K. A low-cost and efficient spatial–temporal model for indoor localization “h-lstmf”. **IEEE Sensors Journal**, v. 23, n. 6, p. 6117–6128, 2023.
- LENDAVE, V. **A Guide to Different Evaluation Metrics for Time Series Forecasting Models**. 2021. Acesso em: 10 Jan. 2023. Disponível em: <https://analyticsindiamag.com/a-guide-to-different-evaluation-metrics-for-time-series-forecasting-models/>.
- LÓPEZ-BARRANTES, A. *et al.* Comparison of empirical models and deterministic models for the analysis of interference in indoor environments. In: **2012 Asia-Pacific Symposium on Electromagnetic Compatibility**. [S.l.: s.n.], 2012. p. 509–512.
- MALLIK, M. *et al.* Eme-net: A u-net-based indoor emf exposure map reconstruction method. In: **2022 16th European Conference on Antennas and Propagation (EuCAP)**. [S.l.: s.n.], 2022. p. 1–5.
- MATHWORKS. **fspl**. 2011. Acesso em: 20 nov. 2022. Disponível em: <https://www.mathworks.com/help/phased/ref/fspl.html>.
- MOURÃO, R. Q. e R. **5G Technology in Brazil: The Biggest Auction in the World and Its Impacts in the Country**. 2021. Acesso em: 25 out. 2022. Disponível em: <https://www.montaury.com.br/en/5g-technology-in-brazil-the-biggest-auction-in-the-world-and-its-impacts-in-the-country>.
- MUKTI, F. S. *et al.* Integrating cost-231 multiwall propagation and adaptive data rate method for access point placement recommendation. **International Journal of Advanced Computer Science and Applications**, v. 12, p. 772–777, 01 2021.
- NAGAO, T.; HAYASHI, T. Study on radio propagation prediction by machine learning using urban structure maps. In: **2020 14th European Conference on Antennas and Propagation (EuCAP)**. [S.l.: s.n.], 2020. p. 1–5.
- NETWORKS, U. **airMAX Omni Antennas Datasheet**. Acesso em: 25 set. 2022. Disponível em: https://dl.ubnt.com/datasheets/airmaxomni/amo_ds_web.pdf.
- OLAH, C. **Understanding LSTM Networks**. 2015. Acesso em: 15 nov. 2022. Disponível em: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- RAJ, N.; S., V. B. Indoorrssinet - deep learning based 2d rssi map prediction for indoor environments with application to wireless localization. In: **2023 15th International Conference on COMMunication Systems NETWORKS (COMSNETS)**. [S.l.: s.n.], 2023. p. 609–616.

- RATH, H. K. *et al.* Realistic indoor path loss modeling for regular wifi operations in india. In: **2017 Twenty-third National Conference on Communications (NCC)**. [S.l.: s.n.], 2017. p. 1–6.
- SANTANA, Y. H. *et al.* Indoor genetic algorithm-based 5g network planning using a machine learning model for path loss estimation. **Applied Sciences**, v. 12, n. 8, 2022. ISSN 2076-3417. Disponível em: <https://www.mdpi.com/2076-3417/12/8/3923>.
- SANTOS, A. F. dos. **Caracterização de Cobertura de Sinais em Ambientes Internos com Mais de Um Pavimento na Faixa de 700 MHz**. 2016. 87 f. Dissertação (Mestrado em Engenharia Elétrica) — Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, Paraíba, 2016.
- SASAKI, M. *et al.* Deep learning based channel prediction at 2–26 ghz band using long short-term memory network. In: **2021 15th European Conference on Antennas and Propagation (EuCAP)**. [S.l.: s.n.], 2021. p. 1–5.
- SCHAUBACH, K.; DAVIS, N.; RAPPAPORT, T. A ray tracing method for predicting path loss and delay spread in microcellular environments. In: **[1992 Proceedings] Vehicular Technology Society 42nd VTS Conference - Frontiers of Technology**. [S.l.: s.n.], 1992. p. 932–935 vol.2.
- SERETIS, A.; SARRIS, C. D. An overview of machine learning techniques for radiowave propagation modeling. **IEEE Transactions on Antennas and Propagation**, v. 70, n. 6, p. 3970–3985, 2022.
- SOTIROUDIS, S. P.; SIAKAVARA, K. Mobile radio propagation path loss prediction using artificial neural networks with optimal input information for urban environments. **AEU - International Journal of Electronics and Communications**, v. 69, n. 10, p. 1453–1463, 2015. ISSN 1434-8411. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1434841115001855>.
- SULAIMAN, B. *et al.* Radio map generation approaches for an rssi-based indoor positioning system. **Systems and Soft Computing**, v. 5, p. 200054, 2023. ISSN 2772-9419. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2772941923000078>.
- THEOFILOGIANNAKOS, G. K.; XENOS, T. D.; YIOULTSIS, T. V. A hybrid parabolic equation—integral equation technique for wave propagation modeling of indoor communications. **IEEE Transactions on Magnetics**, v. 45, n. 3, p. 1112–1115, 2009.
- WANG, X. *et al.* Maploc: Lstm-based location estimation using uncertainty radio maps. **IEEE Internet of Things Journal**, v. 10, n. 15, p. 13474–13488, 2023.
- XIAO, L.; LI, J. Computational analysis of indoor propagation characteristics of 2.4GHz band in office environments. In: BATISTA, P.; PACHORI, R. B. (Ed.). **International Conference on Image, Signal Processing, and Pattern Recognition (ISPP 2023)**. SPIE, 2023. v. 12707, p. 127074Y. Disponível em: <https://doi.org/10.1117/12.2681272>.
- XU, B.; ZHU, X.; ZHU, H. An efficient indoor localization method based on the long short-term memory recurrent neuron network. **IEEE Access**, v. 7, p. 123912–123921, 2019.
- XU, X.; ZHANG, C.; PENG, A. Enhanced propagation model constrained rss fingerprints patching with map assistance for wi-fi positioning. **Computer Communications**, v. 208, p. 200–209, 2023. ISSN 0140-3664. Disponível em: <https://www.sciencedirect.com/science/article/pii/S014036642300186X>.

YANG, X. *et al.* Deepwipos: A deep learning-based wireless positioning framework to address fingerprint instability. **IEEE Transactions on Vehicular Technology**, v. 72, n. 6, p. 8018–8034, 2023.

ZHAO, Y. *et al.* An efficient and robust fingerprint based localization method for multi floor indoor environment. **IEEE Internet of Things Journal**, p. 1–1, 2023.

Apêndices


APÊNDICE A – USO DE PDI PARA AUTOMAÇÃO DA EXTRAÇÃO DE INFORMAÇÕES DA PLANTA BAIXA DOS AMBIENTES

Uma das dificuldades encontradas dentro do problema da modelagem *indoor* é mapear uma área significativa, com diferentes configurações de obstáculos, e fazer isso de forma rápida e eficiente. Além disso a metodologia proposta deve ser capaz de fornecer resultados para testes em ambientes ainda não trabalhados.

Se supormos um andar com corredores e várias salas. Precisaríamos definir um *gride* de resolução e fazer uma varredura por ambiente, alimentando um banco de dados com informações de distância e número de obstáculos e computar os ângulos vertical e horizontal para cada célula espacial, e somente depois testar a rede treinada.

O diagrama da Figura 19 exhibe as etapas de processamento da imagem da planta baixa de qualquer ambiente, seja para fornecer dados de treinamento, seja para fornecer dados de teste. Ou em nível de aplicação, para fazer a projeção de irradiação completa.

Figura 19 – Fluxograma do método baseado em PDI para análise da planta baixa.



Fonte: Elaborado pela autora.

As variáveis de entrada do algoritmo são: **I** a imagem binária da planta baixa, como mostrada na Figura 20, e indicada no diagrama pelo número ①, e os escalares **H** (altura da antena transmissora), **h** (altura da antena receptora), **r** (resolução em metros/pixel de **I**), e **[Ax,Ay]** (coordenadas da antena transmissora na imagem, considerando que o canto superior esquerdo é o pixel (0,0)).

Figura 20 – Exemplo de uma planta baixa de 534x1103 pixels e resolução de 0,06 m/pixel.




Fonte: Elaborado pela autora.

O passo ② destacado no diagrama, consiste em computar a transformada da distância (GONZALEZ; WOODS, 2008) de um único ponto branco localizado nas coordenadas da antena transmissora, cujo resultado é exibido na Figura 21. Neste exemplo, a antena transmissora encontra-se nas coordenadas: linha 230, coluna 460.


No passo ③ é realizada a operação de afinamento morfológico (GONZALEZ; WOODS, 2008) da planta baixa. Isso fornece uma versão da planta em que cada elemento de resolução das paredes é realmente representado por um único pixel, como mostra a Figura 22. O afinamento é necessário, pois evita que erros de contagem ocorram na última etapa do método, que consiste de detectar quantas paredes existem entre a antena transmissora e um ponto qualquer da imagem. A contagem é realizada em um raio entre a antena de transmissão e a de recepção. Neste exemplo, sete paredes foram detectadas e este valor é armazenado em uma matriz, nas coordenadas da antena receptora. O passo ④ representa o cálculo das variáveis de saída, realizado ponto a ponto para todo pixel pertencente ao ambiente interno.

Figura 21 – Distância de cada ponto do ambiente a antena transmissora localizada na linha 230 e coluna 460 da imagem.




Fonte: Elaborado pela autora.

Figura 22 – Resultado do afinamento da planta baixa e contagem de paredes entre Tx e Rx (pontos amarelos).




Fonte: Elaborado pela autora.


As variáveis de saída do algoritmo são quatro mapas. O mapa de distâncias, previamente apresentado na Figura 21. Dois mapas com os valores dos ângulos de azimuth (5) e vertical (6), calculados com base nas coordenadas de cada ponto, na distâncias TX-RX e na altura das antenas. O quarto mapa (7) apresenta o número de paredes detectadas entre cada ponto da imagem e o ponto em que está localizada a antena transmissora. Estes três últimos mapas são mostrados, respectivamente, nas Figuras 23, 24 e 25.

Figura 23 – Mapa de ângulos horizontais.

Fonte: Elaborado pela autora.

Figura 24 – Mapa de ângulos verticais.

Fonte: Elaborado pela autora.

Figura 25 – Mapa do número de paredes.

Fonte: Elaborado pela autora.