



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA



Análise de Perda de Percurso para Sistemas Multiportadoras na Faixa de 700 MHz

Grazielle de Lima

DISSERTAÇÃO DE MESTRADO
Juiz de Fora, MG
2023



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA



Análise de Perda de Percurso para Sistemas Multiportadoras na Faixa de 700 MHz

Grazielle de Lima

Dissertação a apresentada ao Departamento de Engenharia Elétrica da Universidade Federal de Juiz de Fora como parte dos requisitos exigidos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de Concentração: Sistemas Eletrônicos

Orientador: Prof. Dr. Álvaro Augusto Machado de Medeiros

Juiz de Fora, MG

2023

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

de Lima, Grazielle.

Análise de Perda de Percurso para Sistemas Multiportadoras na Faixa de 700 MHz / Grazielle de Lima. -- 2023.
72 f.

Orientador: Álvaro Augusto Machado de Medeiros
Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2023.

1. Sistemas Celulares Multiportadora. 2. Cobertura. 3. Perda de Percurso. 4. Modelos Empírico. 5. Rede Neural Artificial. I. Augusto Machado de Medeiros, Álvaro, orient. II. Título.

Grazielle de Lima

Análise de Perda de Percurso para Sistemas Celulares Multiportadoras na faixa de 700MHz

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas Eletrônicos

Aprovada em 24 de abril de 2023.

BANCA EXAMINADORA

Prof. Dr. Álvaro Augusto Machado de Medeiros - Orientador

Universidade Federal de Juiz de Fora

Dr. Alexandre Campos Moraes

Agência Nacional de Telecomunicações

Prof. Dr. Ulysses Roberto Chaves Vitor

Universidade Federal de Juiz de Fora

Juiz de Fora, 14/04/2023.



Documento assinado eletronicamente por **Ulysses Roberto Chaves Vitor, Professor(a)**, em 24/04/2023, às 15:43, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alexandre Campos Moraes, Usuário Externo**, em 24/04/2023, às 15:43, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alvaro Augusto Machado de Medeiros, Professor(a)**, em 29/04/2023, às 07:52, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Uffj (www2.uffj.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **1236178** e o código CRC **AB31F18D**.

Agradecimentos

À Deus, primeiramente, pois sem ele não teria conseguido vencer todas as etapas do curso.

Aos meus pais Milton Teixeira de Lima e Joana D'Arc de Lima por todo o apoio, incentivo, carinho e paciência durante meu mestrado, sem eles nada disto teria sido possível. Ao meu irmão Wayne de Lima pela parceria, carinho e ajuda durante todo tempo. A minha vó Maria e minha Tia Marcilene por todo amor e apoio.

À Universidade Federal de Juiz de Fora, pelo apoio concedido durante meu mestrado. E ao PPEE pela possibilidade de aprendizado.

Em especial ao Professor Dr. Álvaro de Medeiros, pela dedicação incondicional durante as pesquisas, pela competência e também pelos ensinamentos de vida.

De forma especial também ao Me. Marcelo Nunes da Anatel, pela total dedicação durante as pesquisas e pela indispensável contribuição no trabalho.

Aos demais membros da banca, Professor Dr. Ulysses Vitor e Dr. Alexandre Moraes.

Aos Professores que de alguma forma contribuíram durante meu mestrado.

Aos colegas de sala que apoiaram e compartilharam a luta diária.

A Agência Nacional de Telecomunicações por fornecer as campanha de medição que possibilitou a realização desse trabalho.

A todos aqueles que de alguma forma contribuíram com o meu progresso como aluna e como pessoa, deixo aqui meu muito obrigado.

Resumo

O crescente aumento da demanda por serviços de banda larga sem fio exige maior confiabilidade, melhor conectividade e um maior alcance do sinal. Visando uma melhor ocupação do espectro de 700 MHz, antes utilizado pela TV Digital, o Brasil destinou o uso desta faixa a implantação de celulares multiportadoras. Essa faixa de frequências apresenta a vantagem de melhor propagação do sinal, proporcionando uma maior cobertura da estação rádio-base. Neste sentido, o presente trabalho tem como objetivo avaliar, comparar e analisar modelos empíricos de perda de percurso, bem como propor um modelo simples baseado em inteligência artificial. Pela análise de métricas de desempenho, os modelos de predição de cobertura são avaliados em comparação com valores obtidos através de campanha de medição na região da Lagoa da Pampulha em Belo Horizonte. Resultados indicam que os modelos de perda de percurso tradicionais apresentam significativa melhoria após correção de *offset*, e que o modelo baseado em rede neural artificial apresenta melhor adequação aos dados de medição.

Palavras-chaves: Sistemas Celulares Multiportadora, Cobertura, Perda de Percurso, Modelos Empíricos, Rede Neural Artificial.

Abstract

The ever-increasing demand for wireless broadband services requires higher reliability, better connectivity and higher signal range. Aiming at a more efficient occupation of the 700 MHz spectrum, formerly used by Digital TV, Brazil allocated this band to the deployment of multicarrier cellular systems. This frequency band presents the advantage of better signal propagation, providing higher coverage for each base station. In this sense, the present work aims to evaluate, compare and analyze empirical models of path loss, as well as propose a simple model based on artificial intelligence. By analyzing performance metrics, the coverage prediction models are evaluated in comparison with values obtained through a measurement campaign in the region of Pampulha's Lagoon in Belo Horizonte. Results indicate that the traditional path loss models show significant improvement after *offset* correction, and that the model based on an artificial neural network presents a better fit to the measurement data.

Keywords: Multicarrier Cellular Systems, Coverage, Path Loss, Empirical Models, Artificial Neural Network.

Lista de ilustrações

Figura 1 – Comunicação de Radio ponto a ponto, visada direta. Fonte: Adaptada de (PARSONS, 2002)	5
Figura 2 – Comunicação de Radio ponto a ponto, sem visada direta. Fonte: Adaptada de (CASTRO, 2017)	6
Figura 3 – Modelo da reflexão da onda eletromagnética. Fonte: Adaptada de (CASTRO, 2010)	7
Figura 4 – Modelo da difração da onda eletromagnética. Fonte: Adaptada de (CASTRO, 2010)	8
Figura 5 – Variáveis da Equação (2.20). Fonte: Adaptado de (CASTRO, 2017) . . .	17
Figura 6 – Rede Neural com as sinapses. Fonte: (HSU, 2015)	20
Figura 7 – Esquema de uma rede neural artificial com três camadas. Fonte: (NUNES, 2003)	21
Figura 8 – Modelo TSMW. Fonte: (SHWARZ, R. &, Rhode & Shwarz, 2017) . . .	28
Figura 9 – Setup da coleta de dados realizada pelo drive test. Fonte: (SHWARZ, R. &, Rhode & Shwarz, 2017)	29
Figura 10 – Localização das Antenas da operadora de telefonia móvel em 700 MHz. Fonte: Google Earth.	29
Figura 11 – Estação n° 1003002592 – Rua Maria Amélia Maia, 300 - São Tomaz – Belo Horizonte/MG. Fonte: Google Earth.	30
Figura 12 – Característica sub-urbana na proximidade da Estação n° 1003002592 – Rua Maria Amélia Maia, 300 - São Tomaz – Belo Horizonte/MG. Fonte: Google Earth.	30
Figura 13 – Estação n° 379988976 – Avenida Deputado Último Carvalho, 30 - Planalto – Belo Horizonte/MG. Fonte: Google Earth.	31
Figura 14 – Característica sub-urbana na proximidade da Estação n° 379988976 – Avenida Deputado Último Carvalho, 30 - Planalto – Belo Horizonte/MG. Fonte: Google Earth.	31
Figura 15 – Resultados do comportamento da predição para PCI136 dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	35
Figura 16 – Resultados do comportamento da predição para PCI137 dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	36
Figura 17 – Resultados do comportamento da predição para PCI138 dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	36
Figura 18 – Resultados do comportamento da predição para PCI136 após correção de <i>offset</i> dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	37

Figura 19 – Resultados do comportamento da predição para PCI137 após correção de <i>offset</i> dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	38
Figura 20 – Resultados do comportamento da predição para PCI138 após correção de <i>offset</i> dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	38
Figura 21 – Resultados do comportamento da predição para PCI156 dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	39
Figura 22 – Resultados do comportamento da predição para PCI157 dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	40
Figura 23 – Resultados do comportamento da predição para PCI158 dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	41
Figura 24 – Resultados do comportamento da predição para PCI156 após correção de <i>offset</i> dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	42
Figura 25 – Resultados do comportamento da predição para PCI157 após correção de <i>offset</i> dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	43
Figura 26 – Resultados do comportamento da predição para PCI158 após correção de <i>offset</i> dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.	44
Figura 27 – Rede neural artificial extraída do ambiente MatLab.	47
Figura 28 – Análise de desempenho da rede neural artificial extraída do ambiente MatLab.	48
Figura 29 – Diagrama da rede neural artificial extraída do ambiente MatLab.	49
Figura 30 – Resultados da predição para PCI 136 pela RNA em comparação com os valores medidos.	50
Figura 31 – Resultados da predição para PCI 137 pela RNA em comparação com os valores medidos.	50
Figura 32 – Resultados da predição para PCI 138 pela RNA em comparação com os valores medidos.	51
Figura 33 – Resultados da predição para PCI 156 pela RNA em comparação com os valores medidos.	51
Figura 34 – Resultados da predição para PCI 157 pela RNA em comparação com os valores medidos.	52
Figura 35 – Resultados da predição para PCI 158 pela RNA em comparação com os valores medidos.	52

Lista de tabelas

Tabela 1 – Parâmetros de entrada	15
Tabela 2 – Parâmetros para análise de perfil de percurso.	16
Tabela 3 – Resultados da avaliação para Setor de PCI 136 localizado na Estação Planato.	40
Tabela 4 – Resultados da avaliação para Setor de PCI 137 localizado na Estação Planato.	41
Tabela 5 – Resultados da avaliação para Setor de PCI 138 localizado na Estação Planato.	42
Tabela 6 – Resultados da avaliação para Setor de PCI 156 localizado na Estação São Thomaz.	43
Tabela 7 – Resultados da avaliação para Setor de PCI 157 localizado na Estação São Thomaz.	44
Tabela 8 – Resultados da avaliação para Setor de PCI 158 localizado na Estação São Thomaz.	45
Tabela 9 – Análise dos Resultados da Estação Planalto	45
Tabela 10 – Análise dos Resultados da Estação São Tomaz	46
Tabela 11 – Resultados da predição através da RNA para todos os setores.	53
Tabela 12 – Comparação de desempenho entre os modelos de propagação após correção de <i>offset</i> e RNA para todos os setores.	54

Lista de Abreviaturas

3GPP–*Third Generation Partnership Project*

ANATEL–*Agência Nacional de Telecomunicações*

IA–*Inteligência Artificial*

LOS–*Line of Sight*

LTE–*Long-Term Evolution*

MS–*Mobile Station*

MSE–*Mean Square Error*

NLOS–*Non Line of Sight*

NR–*New Radio*

OFDM–*Orthogonal Frequency Division Multiplexing*

RNA–*Rede Neural Artificial*

PCI–*Physical layer Cell Identifiers*

RMSE–*Root Mean Square Error*

RSRP–*Reference Signal Receive Power*

RSRQ–*Reference Signal Received Quality*

RSSI–*Received Signal Strength Indicator*

VHF –*Very High Frequency*

|

UHF –*Ultra High Frequency*

Sumário

	Agradecimentos	vii
	Resumo	viii
	Abstract	ix
1	INTRODUÇÃO	1
1.1	Trabalhos Relacionados	2
1.2	Objetivos	3
1.2.1	Objetivo Geral	3
1.2.2	Objetivos específicos	3
1.3	Contribuições	3
1.4	Metodologia	4
1.5	Estrutura da Dissertação	4
2	MODELOS DE PERDA DE PERCURSO	5
2.1	Propagação de Ondas de Rádio	5
2.1.1	Propagação no Espaço Livre	5
2.1.2	Reflexão	6
2.1.3	Difração	7
2.1.4	Dispersão	8
2.2	Modelos Empíricos de Perda de Percurso	8
2.2.1	Okumura	9
2.2.2	Okumura–Hata	9
2.3	3GPP	11
2.4	Modelo ITU-Advanced	11
2.5	Recomendação ITU-R 1812-6	13
2.5.1	Elementos do método para predição da propagação	14
2.5.2	Parâmetros de entrada	14
2.5.3	Perfil do enlace	14
2.5.4	Processo de Predição	16
2.5.4.1	Propagação em Visada Direta	16
2.5.4.2	Propagação com Difração	17
2.6	Considerações finais	18
3	REDE NEURAL ARTIFICIAL	20
3.1	Características Gerais das Redes Neurais	20
3.2	Modelagem de um RNA	22
3.3	Função de Ativação	22

3.4	Arquitetura	23
3.4.1	RNA com uma camada	23
3.4.2	RNA com multicamadas	23
3.4.3	RNA recorrentes	24
3.4.4	RNA reticuladas	24
3.5	Processos de Aprendizagem	24
3.5.1	Regras de Aprendizagem por Retropropagação (<i>Backpropagation</i>)	25
3.6	Treinamento da RNA	25
3.6.1	Treinamento supervisionado	25
3.6.2	Treinamento não supervisionado	25
3.6.3	Algoritmo de treinamento Levenberg–Maquardt	26
3.6.4	Algoritmo de treinamento regularização bayesiana	26
3.7	Considerações finais	26
4	CAMPANHA DE MEDIÇÃO	27
4.1	Redes celulares na faixa de 700 MHz	27
4.1.1	Tecnologia LTE	27
4.2	Coleta de dados da Rede de Telefonia Móvel	28
4.3	Considerações finais	32
5	ANÁLISE DE MODELOS DE PROPAGAÇÃO	33
5.1	Raiz do Erro Quadrático Médio	33
5.2	Distância Média	33
5.3	Coefficiente de Correlação	34
5.4	Resultados	34
5.4.1	Estação Planalto	35
5.5	Estação São Thomaz	37
5.6	Análise dos resultados	39
5.7	Considerações finais	46
6	ANÁLISE DE REDE NEURAL ARTIFICIAL	47
6.1	Modelo de RNA utilizado	47
6.2	Estação Planalto	48
6.3	Estação São Thomaz	49
6.4	Análise dos resultados	51
6.5	Considerações finais	53
7	CONCLUSÕES	55
	REFERÊNCIAS	56

1 Introdução

Atualmente com as constantes evoluções, os sistemas de comunicação estão em aperfeiçoamento constante no quesito de capacidade de trafegar maiores volumes de dados com maior confiabilidade (SAUTER, 2021). Diversos fatores referentes à propagação dos sinais de comunicação tornam tal evolução desafiadora.

Sabe-se que vários fatores podem influenciar na propagação de ondas de rádio. O nível de potência do sinal recebido decai exponencialmente no percurso da onda eletromagnética no canal de comunicação do transmissor até o receptor (RAPAPPORT, 1996). Também tem influência no sinal as transições de diferentes tipos de ambientes, como a altura dos edifícios, tipo de vegetação, ou presença de áreas cobertas de água.

Os modelos de propagação para a perda de potência com o percurso são importantes para o planejamento de sistemas de telecomunicações por possibilitarem uma predição do nível de sinal em função da distância. Tais modelos têm evoluído historicamente através de adequações do modelo para as diferentes regiões analisadas. Essa adequação utiliza parâmetros geométricos do próprio ambiente e que contemplem áreas urbanas e rios, assim como as áreas de transição entre esses ambientes (PARSONS, 2002).

A principal motivação desse trabalho de caracterização de canais de rádio-móvel é encontrar o melhor modelo para a predição de sistemas celulares multiportadoras na faixa de 700 MHz. Sendo o Brasil um dos países pioneiros na implantação de sistemas celulares multiportadoras nesta faixa de frequência, é importante avaliar o desempenho de modelos de propagação em sinais transmitidos por estes sistemas.

Para isso, o estudo baseia-se em medições de nível de sinal de estações rádio-base de uma operadora de telefonia móvel na região próxima à Pampulha em Belo Horizonte. Essa região apresenta um ambiente urbano composto de diferentes fatores de propagação, tais como:

- Grandes variações de relevo.
- Diferentes tipos de edificações como prédios, casas, supermercados, shopping centers, etc.
- Áreas de espelho d'água como a Lagoa da Pampulha e Lagoa do Nado.
- Áreas de edificações esparsas como a Universidade Federal de Minas Gerais (UFMG), Estádio Governador Magalhães Pinto (Mineirão), Aeroporto da Pampulha.
- Áreas de Vegetação como o Jardim Zoológico e Botânico, Parque Ecológico Francisco Lins do Rego.

1.1 Trabalhos Relacionados

Alguns trabalhos apresentam novos modelos para perda de percurso nas faixas de VHF e UHF, como em (ESCUADERO, 2004), que apresenta um modelo teórico para a estimativa da perda média nessas faixas, no percurso entre as antenas de transmissão e recepção em áreas residenciais, para sistemas de comunicação fixos. No artigo (JUNIOR E. M. J.; VEIGA; N., 2022), os autores propõem um modelo baseado em RNA que apresentou melhores resultados quando comparado aos modelos teóricos já existentes na literatura. Em (SÁ, 2020), são apresentados resultados de campanhas de medições coletadas por uma unidade móvel viajando em baixa velocidade ao longo do túnel da Grota funda no Rio de Janeiro. Sendo observado que a perda de percurso dentro do túnel na frequência de 700MHz é semelhante a perda de percurso no espaço livre.

Já em (LEITE, 2021), apresenta-se a aplicação do Modelo do Traçado de Raios Inteligente na caracterização da perda de percurso e o perfil de atraso de potências numa região de densa vegetação. Através das simulações feitas no trabalho foi possível verificar a influência da vegetação no canal de rádio móvel dessa região. A caracterização do canal de propagação rádio móvel em ambiente com vegetação também é avaliada em (MAGALHÃES, 2020), que analisa os efeitos da vegetação na propagação do sinal na faixa de 700 a 4000 MHz, desenvolvendo modelos para predição do sinal de cobertura em ambientes com vegetação.

Em (CARVALHO, 2020), o modelo de predição utilizado foi o log-distância, sendo avaliados os valores de RMSE do modelo e das Redes Neurais Artificiais, com relação os dados da medição. Concluindo assim que a RNA escolhida apresentou menores valores de RMSE em comparação com o log-distância, e esse trabalho contribui para o avanço das técnicas de modelagem de propagação de sinal de redes de comunicação móvel em áreas com densa vegetação. A modelagem inteligente da cobertura também é abordada em (ROCHA L.; FERREIRA; BATALHA, 2022), em que é proposto *framework* para o planejamento de redes *outdoor* e *indoor*. Através de otimização computacional e campanha de medição, este estudo abrange a coleta de dados, modelagem e estruturação de uma rede garantindo uma cobertura eficiente para comunicação .

Alguns artigos também utilizam medidas obtidas em rede LTE. Os resultados experimentais de (ALEXANDRE; SODRÉ, 2020) demonstram um compartilhamento de espectro eficiente em lagura de banda de 10 MHz para um 5G NR, um LTE-A Pro e três operadoras de dowlink NB-IoT, com o intuito de aproveitar os aspectos de propagação de 700 MHz para o atual 4G e o futuro 5G. A dissertação (ROLIN, 2014) analisa a qualidade e o desempenho da cobertura celular LTE em uma região densa de Curitiba, na faixa de frequência de 2600 MHz com largura de banda de 20MHz, concluindo que o desempenho da cobertura celular LTE nesta localidade não atingia as especificações padronizadas no Release 8 pelo grupo 3GPP. Já em (MELGAREJO D. C. ; FILHO; RODRIGUEZ, 2022), medidas de uma rede LTE experimental na faixa de 250 MHz são utilizadas para modelagem do modelo de propagação utilizado na análise de algoritmos de mitigação de

interferência entre células.

É possível observar nos trabalhos relacionados uma ausência de análise de perda de percurso a partir de parâmetros do padrão LTE para a faixa de frequências de 700 MHz em um ambiente urbano variado como aquele avaliado nesta Dissertação.

1.2 Objetivos

1.2.1 Objetivo Geral

Esta dissertação tem por objetivo analisar e comparar modelos de predição de perda de percurso entre a estação rádio-base de operadora de telefonia móvel e uma estação móvel, ambas operando na faixa de 700 MHz, bem como propor um modelo de perda de percurso baseado em redes neurais artificiais para este cenário.

1.2.2 Objetivos específicos

- Avaliar modelos de predição de perda de percurso para a faixa de 700 MHz existentes na literatura.
- Ajustar esses modelos de forma a obter o menor erro quadrático médio entre as curvas de dados medidos e preditos para diversos modelos de perda de percurso.
- Avaliar qual modelo representa melhor o comportamento da região onde encontram as estações rádio-base e móvel.
- Propor modelo de perda de percurso baseado em redes neurais artificiais de desempenho igual ou superior aos modelos avaliados.
- Comparar modelo proposto com os modelos da literatura avaliados.

1.3 Contribuições

Dentre as contribuições desta dissertação, destacam-se:

- Análise de modelos de propagação para predição de perda de percurso em redes celulares operando na faixa de 700 MHz considerando a posição em relação ao lóbulo de propagação da antena transmissora.
- Ajuste de modelos de perda de percurso para o ambientes urbanos compostos de morfologia variada.
- Modelo de perda de percurso baseado em redes neurais artificiais para ambientes urbanos de morfologia variada.

Vale ressaltar que os dados de medição utilizados nesta Dissertação, bem como as rotinas utilizadas para processamentos deles e para geração dos resultados apresentados encontra-se disponível em (LIMA; NUNES, 2023).

1.4 Metodologia

Este trabalho parte de um conjunto de medições realizados pela equipe de campo da Agência Nacional de Telecomunicações (ANATEL) Belo Horizonte. Estes dados são processados e comparados com alguns modelos de propagação encontrados na literatura através da ferramenta computacional MATLAB. Essa ferramenta também foi utilizada para implementação, treinamento e teste da rede neural artificial proposta para predição de perda de percurso. Parâmetros de desempenho são utilizados para comparar as curvas de potência recebida em função da distância.

1.5 Estrutura da Dissertação

Os Capítulos restantes da dissertação seguem a seguinte configuração:

- Capítulo 2 - Apresenta uma breve descrição sobre os modelos de perda de percurso utilizados no trabalho.
- Capítulo 3 - Mostra uma introdução sobre redes neurais artificiais e as configurações utilizadas no trabalho.
- Capítulo 4 - Descreve a campanha de medições.
- Capítulo 5 - Apresenta os resultados dos modelos e a comparação com os dados medidos.
- Capítulo 6 - Descreve os detalhes da implementação do modelo de predição em redes neurais artificiais, bem como a comparação entre os dados medidos e os preditos.
- Capítulo 7 - Conclui o trabalho e indica sugestão de trabalhos futuros.

2 Modelos de Perda de Percurso

As diferentes condições impostas pelo canal de propagação são as principais limitações de sistemas de telecomunicações sem fio. Diante disso é necessário a compreensão das influências sofridas pelo sinal no trajeto percorrido entre a estação base de transmissão e a estação base de recepção. As perdas no sinal durante a transmissão são influenciadas por vários fatores, que estão relacionados às condições impostas pelo ambiente no qual as ondas de rádio se propagam (CASTRO, 2010).

2.1 Propagação de Ondas de Rádio

Sabe-se que o canal de rádio móvel impõe limitações importantes para o desempenho dos sistemas de telecomunicações sem fio. Pois o caminho do sinal entre a antena transmissora e a antena receptora pode variar de visada direta (*Line of Sight* - LOS) como mostra a Figura 1 para sem visada direta (*Non Line of Sight* - NLOS) quando o caminho é obstruído por prédios, relevo, árvores, etc como mostra a Figura 2. Os canais de rádio são aleatórios e não proporcionam uma análise fácil, já que fatores como a velocidade da estação móvel influenciam o tempo com que o nível de sinal enfraquece enquanto a ela se desloca no espaço (RAPAPPORT, 1996).



Figura 1 – Comunicação de Rádio ponto a ponto, visada direta. Fonte: Adaptada de (PARSONS, 2002)

Com relação à propagação em um canal de frequência ultra alta (*Ultra High Frequency* - UHF), isto é, de 300 MHz a 3 GHz, os principais fenômenos físicos que caracterizam a perda de propagação estão relacionados à propagação no espaço livre juntamente com efeitos de reflexão, difração e espalhamento (RAPAPPORT, 1996).

2.1.1 Propagação no Espaço Livre

Quando uma onda eletromagnética se propaga no espaço livre o percurso entre a antena transmissora e a receptora é caracterizado por uma linha de visada direta sem obstrução como o observado na Figura 1. O termo espaço livre indica o vácuo, porém em



Figura 2 – Comunicação de Rádio ponto a ponto, sem visada direta. Fonte: Adaptada de (CASTRO, 2017)

nível de projeto este termo pode ser aplicado na caracterização de propagação de ondas de rádio em meios desobstruídos. Em projetos de redes sem fio, pode-se considerar a propagação em espaço livre para a realização de uma estimativa inicial de cobertura do sinal propagado (RAPAPPORT, 1996).

Em termos de potência recebida, o cálculo pode ser obtido pela Equação (2.1) de Friis para o espaço livre, em que $P_R(d)$ é a potência recebida em função da distância d , P_T é a potência de transmissão, G_T é o ganho da antena de transmissão, G_R é o ganho da antena de recepção, λ é o comprimento de onda em metros, d é a distância entre a antena transmissora e a antena receptora, em quilômetros. Já o L é o fator de perda do sistema (RAPAPPORT, 1996).

$$P_R(d) = \frac{P_T \cdot G_T \cdot G_R \cdot \lambda^2}{(4 \cdot \pi)^2 \cdot d^2 \cdot L} \quad (2.1)$$

Manipulando (2.1), passando para escala logarítmica pode-se obter a Equação (2.2) da perda L_{EL} em dB para o espaço livre (PARSONS, 2002).

$$L_{EL}(dB) = 32,44 - 10 \cdot \log(G_T) - 10 \cdot \log(G_R) + 20 \cdot \log(f) + 20 \cdot \log(d) \quad (2.2)$$

Este seria o modelo para um caminho ideal de propagação. Porém, para um caminho real, tem-se a reflexão, difração e o espalhamento que são mecanismos que influenciam na propagação da onda eletromagnética.

2.1.2 Reflexão

Este fenômeno ocorre quando uma onda eletromagnética, durante a propagação, entra em colisão com um obstáculo que possui dimensões muito superiores, quando comparado com o comprimento de onda da onda propagante. As reflexões da onda eletromagnética ocorre no solo, nos prédios e paredes (RAPAPPORT, 1996).

Durante a propagação de uma onda eletromagnética, pode-se observar que quando a onda colide em um meio com propriedades elétricas diferentes, parte da onda é transmitida, porém parte é refletida como pode-se observar na Figura 3. Em um dielétrico perfeito, parte da energia é transmitida para o segundo meio e parte é refletida para o primeiro meio sem perdas. Já em um condutor perfeito a onda transmitida é completamente refletida para o primeiro meio sem perdas (RAPAPPORT, 1996).

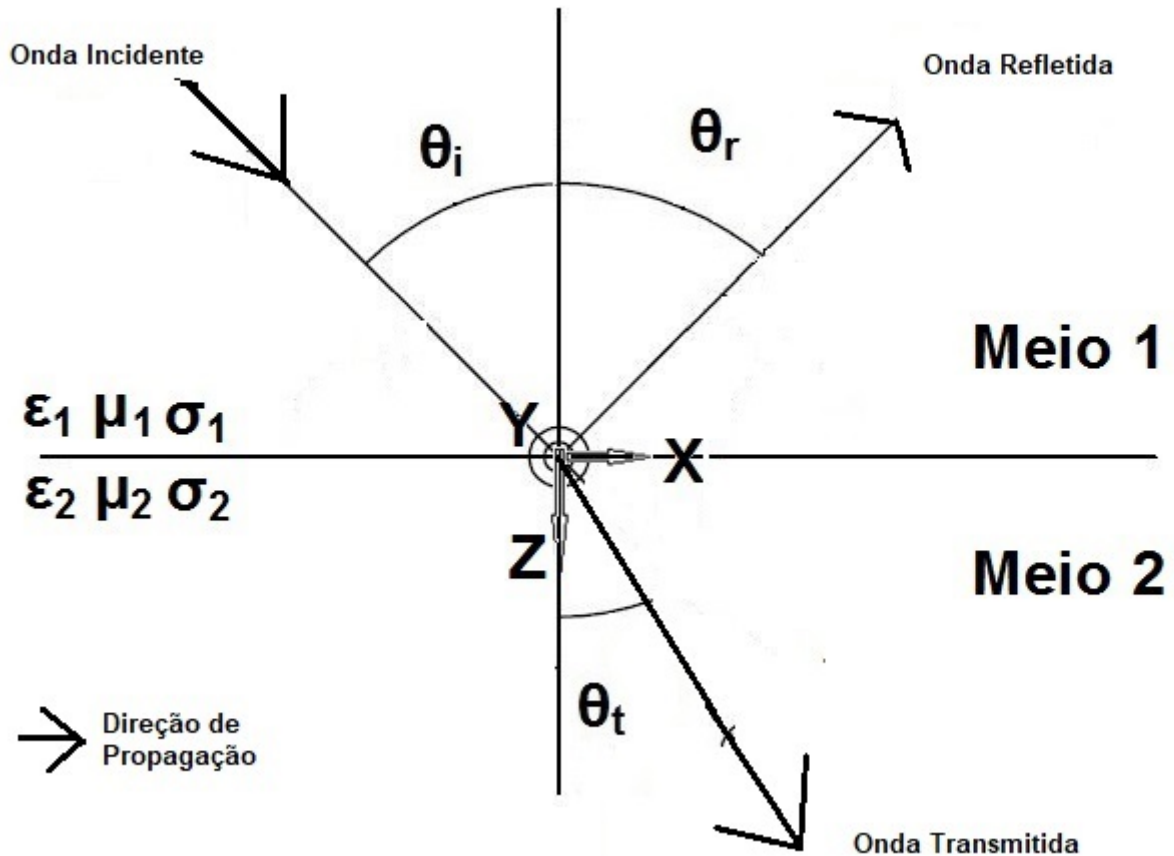


Figura 3 – Modelo da reflexão da onda eletromagnética. Fonte: Adaptada de (CASTRO, 2010)

2.1.3 Difração

A difração acontece quando o caminho de rádio entre o transmissor e o receptor está obstruído por uma superfície irregular pontiaguda, cujas ondas resultantes da superfície de obstrução estão presentes no espaço como mostrado na Figura 4. Fazendo aparecer uma curvatura de ondas em torno do obstáculo até mesmo quando não existe caminho em visada direta entre o transmissor e o receptor. Para altas frequências, a difração depende da geometria do objeto, amplitude, fase e polarização da onda incidente (RAPAPPORT, 1996).




Figura 4 – Modelo da difração da onda eletromagnética. Fonte: Adaptada de (CASTRO, 2010)

2.1.4 Dispersão

Caracteriza-se como dispersão ou espalhamento quando o meio pelo qual a onda eletromagnética tráfega consiste de objetos com dimensões muito próximas ao comprimento de onda da onda propagante. Sendo pois a densidade volumétrica dos obstáculos suficientemente grande, quando uma onda eletromagnética se colide com uma superfície áspera desses objetos, a energia refletida é dispersa em todas as direções. Exemplo de dispersão são os obstáculos como árvores e postes tendem a dispersar a energia em todas as direções, fornecendo assim energia de rádio adicional em um receptor (PARSONS, 2002).

2.2 Modelos Empíricos de Perda de Percurso

Na propagação de ondas eletromagnéticas em ambientes urbanos há inúmeras ocorrências dos fenômenos físicos descritos anteriormente. A modelagem da perda de percurso torna-se então uma tarefa complexa. Uma forma de abordagem do problema é através de modelos empíricos, elaborados a partir de extensivas campanhas de medidas.

De maneira geral, os modelos de perda de percurso visam obter a estimativa de rádio propagação com base nas características nominais. Sendo o valor médio para perda de percurso desses modelos é dado pela Equação (2.3), em que L é o valor médio da perda de percurso em dB, d é o comprimento do percurso geralmente em km, f é a frequência geralmente em MHz, h_r altura da antena receptora em metros, e h_t altura da antena receptora em metros (RAPAPPORT, 1996).

$$L(\text{dB}) = L(f, d, h_r, h_t) \quad (2.3)$$

A seguir, são descritos alguns modelos de perda de percurso que são utilizados neste trabalho.

2.2.1 Okumura

Este modelo é usado para encontrar a perda de percurso na faixa de frequência de 150 MHz a 1920 MHz (normalmente é estendido até 3 GHz) para distâncias de 1 a 100km e alturas de antena da estação base variando de 30 a 100m. As aproximações foram tiradas deste modelo para altura da antena do transmissor de 3m e distância abaixo de 1km. Este modelo foi totalmente baseado em diversos dados e medições na cidade de Tóquio nas faixas de 150MHz e 1500MHz, e ele é definido pela Equação 2.4, em que a atenuação L_O é dada em dB, e é calculada a partir da L_{EL} em dB que é a atenuação no espaço livre acrescentados aos ganhos das antenas (RAPAPPORT, 1996).

Já a atenuação mediana A que está em função da frequência em mega-hertz e distância entre as antenas em quilômetros podendo variar entre 10dB e 70dB. O ganho $G(Area)$ é definido em 33dB para área aberta, 27 dB para área semiaberta, 13 dB para área suburbana (RAPAPPORT, 1996).

$$L_O(dB) = (L_{EL}(dB) + 10 \cdot \log(G_T) + 10 \cdot \log(G_R)) + A(f, d) - G(h_t) - G(h_r) - G(Area) \quad (2.4)$$

O ganho referente à altura da antena transmissora $G(h_t)$ é dado por (2.5), quando h_t está entre 30 e 1000m.

$$G(h_t) = 20 \log \left(\frac{h_t}{200} \right) \quad (2.5)$$

Quando h_r é menor que 10 m e maior que 3 m, o ganho $G(h_r)$ é dado por (2.6)

$$G(h_r) = 10 \log \left(\frac{h_r}{3} \right) \quad (2.6)$$

O ganho referente à altura da antena receptora $G(h_r)$ é dado por (2.7), quando h_r é menor que 3m.

$$G(h_r) = 20 \log \left(\frac{h_r}{3} \right) \quad (2.7)$$

2.2.2 Okumura–Hata

Esse método de cálculo tem como base a introdução de correções obtidas graficamente sobre o valor da atenuação no espaço livre. Sendo assim a formulação construída de forma empírica dos dados de perda de percurso, e é válido para as frequências entre 150 MHz e 1500 MHz. A atenuação para áreas urbanas L_{OHU} pode ser calculada por (2.8) (RAPAPPORT, 1996).

$$L_{OHU}(dB) = 69,55 + 26,16 \cdot \log(f) - 13,82 \cdot \log(h_t) - a(h_r) + (44,9 - 6,55 \cdot \log(h_t)) \cdot \log(d) \quad (2.8)$$

A atenuação L_{OHU} é dada em dB, calculada a partir da frequência f em MHz variando de 150 MHz a 1500 MHz, a distância d em quilômetros, a altura do transmissor h_t e do receptor h_r ambas em metros variando de 30 metros a 200 metros. Já o fator de correção a_{h_r} faz o modelo variar, pois dependem da frequência e do tamanho da cidade (RAPAPPORT, 1996).

Para cidades grandes com a frequência de propagação acima de 300 MHz, o fator de correção é dado por (2.9).

$$a(h_r) = 3,2 \cdot (\log(11,75 \cdot h_r))^2 - 4,97 \quad (2.9)$$

Para cidades grandes com a frequência abaixo de 300 MHz o fator de correção é dado pela Equação (2.10).

$$a(h_r) = 8,29 \cdot (\log(1,54 \cdot h_r))^2 - 1,1 \quad (2.10)$$

Para cidades pequenas ou médias, o fator de correção é dado pela Equação (2.11).

$$a(h_r) = 0,8 + (1,1 \cdot \log(f) - 0,7) \cdot h_r - 1,56 \cdot \log(f) \quad (2.11)$$

Para uma área suburbana, a perda L_{OHSU} é calculada a partir da perda urbana L_{OHU} e é dada por (2.12).

$$L_{OHSU}(dB) = L_{OHU} - 2 \cdot [\log(f/28)]^2 - 5,4 \quad (2.12)$$

A perda de percurso para uma área rural L_{OHSR} é dada por (2.13).

$$L_{OHS} = L_{OHU} - 4,78 \cdot (\log(f))^2 + 18,33 \cdot \log(f) - 40,94 \quad (2.13)$$

As Equações do modelo Okumura–Hata são de simples implementação e através de sua implementação obtém-se uma boa predição. Neste trabalho para o cenário pratico utilizou-se as Equações de perdas L_{OHSU} com o fator de correção da Equação (2.9).

2.3 3GPP

O *Third Generation Partnership Project* (3GPP) é o órgão que regulamenta os padrões celulares *Long-Term Evolution* (LTE) e *New Radio* (NR), mais conhecidos como 4G e 5G, respectivamente.

Durante o desenvolvimento do padrão LTE, o 3GPP desenvolveu um conjunto de modelos de canal que devem ser utilizados em avaliações de sistemas celulares com múltiplos elementos de antena, com largura de banda inferior a 5MHz (MOLISCH, 2011).

Estes modelos são definidos para três ambientes: microcélulas urbanas, macrocélulas urbanas e suburbanas. O 3GPP é um modelo misto geométrico-estocástico que pode simular um *layout* de celular incluindo interferência (MOLISCH, 2011).

Para as macrocélulas suburbanas e urbanas, a perda de percurso L_{macro} é determinada por (2.14), em que C é igual a 0dB para áreas suburbanas e 3dB para áreas urbanas. Para microcélulas sem visada direta, a perda de percurso L_{micro} é descrita em (2.15).

$$\begin{aligned} L_{macro} = & (44,9 - 6,55 \cdot \log(h_t)) \cdot \log\left(\frac{d}{1000}\right) \\ & + 45,5 + (35,46 - 1,1 \cdot h_r) \cdot \log(f) \\ & - 13,82 \cdot \log(h_r) + 0,7 \cdot h_r + C \end{aligned} \quad (2.14)$$

$$L_{micro} = -55,9 + 38 \cdot \log(d) + \left(24,5 + \frac{f}{616,67}\right) \cdot \log(f) \quad (2.15)$$

Neste trabalho foi implementado a Equação (2.15), pois para esse cenário foi a melhor predição do modelo.

2.4 Modelo ITU-Advanced

A União Internacional de Telecomunicações (*International Telecommunications Union* - ITU) definiu um conjunto de modelos de canal para avaliação dos sistemas ITU-Advanced. O ITU-R (Setor de Normatização da Radiocomunicações) é formado por mais de 700 organizações públicas e privadas de 191 países.

O ITU-R é um dos três setores do ITU agência intergovernamental da organização das Nações Unidas (ONU) para os TICs (Tecnologia de Informação e Comunicação), que surgiu em 1865 como um comitê especializado da ONU e recentemente passou a ser designado como ITU-R. Essa organização cria recomendações que, após aprovadas pelos membros, se tornam referência para o desenvolvimento de soluções tecnológicas.

O método de modelagem é semelhante ao modelo do 3GPP. Os modelos ITU são baseados em campanhas de medição mais extensas (principalmente feitas no âmbito dos projetos da União Européia WINNER e WINNER 2) e cobrir uma gama maior de cenários (MOLISCH, 2011).

As seguintes etapas devem ser executadas para obter o canal em um ambiente específico:

- Os modelos ITU são baseados no conceito “drop”, e em uma primeira etapa, são selecionadas as localizações das estações base. Para as estações móveis, selecionamos localizações, orientações e vetores de velocidade, de acordo com as funções de densidade de probabilidade.
- Atribuir se uma MS (Estação móvel) está em situação de LOS ou NLOS, para os modelos de perda de percurso do modelo ITU-Advanced (M2135, 2008).
- Calcular a perda de percurso de acordo com as Equações de perda de percurso para os diferentes tipos de ambientes: *Indoor Hotspot*, *Urban Micro*, *Urban Macro*, *Suburban Macro* ou *Rural Macro* (M2135, 2008).

As Equações desse modelo utilizadas neste trabalho estão baseadas nas Equações com visada direta (2.16) e sem visada direta (2.17) para o ambiente *Urban Macro*, em que h_{med} é a altura média dos prédios e W é a largura das ruas, ambos com valores-padrão de 20 m. Para estas Equações, d é dada em metros e f em GHz. Os intervalos de aplicação do modelo são: $5 \text{ m} < h_{med} < 50 \text{ m}$, $5 \text{ m} < W < 50 \text{ m}$, $10 \text{ m} < h_t < 150 \text{ m}$, $1 \text{ m} < h_r < 10 \text{ m}$, e $10 \text{ m} < d < 5000 \text{ m}$.

$$L_{LOS} = 40 \cdot \log_{10}(d) + 7,8 - 18 \cdot \log_{10}(h_t) - 18 \cdot \log_{10}(h_r) + 2 \cdot \log_{10}(f) \quad (2.16)$$

$$\begin{aligned} L_{NLOS} = & 161,04 - 7,1 \cdot \log_{10}(W) + 7,5 \cdot \log_{10}(h) - (24,37 - \\ & 3,7 \cdot (h_{med}/h_t)^2) \cdot \log_{10}(h_t) + (43,42 - 3,1 \cdot \log_{10}(h_t)) \cdot (\log_{10}(d) \\ & - 3) + 20 \cdot \log_{10}(f) - (3,2 \cdot (\log_{10}(11,75 \cdot h_r)))^2 - 4,97 \end{aligned} \quad (2.17)$$

Para esse modelo, implementaram-se as duas Equações, pois alguns pontos de análise tinham visada direta e outros pontos não tinham visada direta. Apesar de ser um pouco mais complexa a implementação pois o modelo envolve mais variáveis teve uma boa predição através desse modelo ITU-Advanced.

2.5 Recomendação ITU-R 1812-6

O modelo ITU-R 1812-6 é um método de previsão de propagação específico para transmissão de sinais terrestres na faixa de frequência de 30 MHz a 6 GHz. Esta recomendação prevê níveis de sinal adequados para distribuição de multicaminhos excedidos por uma determinada porcentagem de tempo (ITU-R1812-6, 2011).

Este modelo do ITU-R fornece uma análise detalhada dos níveis de sinal com base no perfil do terreno, sendo adequado para previsões em sistemas de radiocomunicação que utilizam circuitos terrestres de comprimento de enlace entre 0,25km a 3000km de distância.

Portanto, este método pode ser utilizado para prever tanto a área de cobertura de um sinal, quanto as reduções nesta área de serviço e disponibilidade devido a sinais indesejados, cocanais e/ou adjacentes (interferência). O modelo de propagação deste método é simétrico no sentido de que trata ambos os terminais de rádio da mesma maneira. Não importa qual terminal é o transmissor e qual é o receptor. No entanto, por conveniência na descrição do modelo, os termos “transmissor” e “receptor” são usados para denotar os terminais no início e no final do caminho de rádio, respectivamente. O elemento de variabilidade de localização é então caracterizado estatisticamente em relação às localizações do receptor, além do elemento de perda de entrada do edifício da Recomendação ITU-R 2040-2 (ITU-R2040-2, 2021).

Assume-se que os usuários dessa Recomendação são capazes de especificar perfis detalhados do terreno (ou seja, elevações acima do nível médio do mar) em função da distância ao longo dos grandes caminhos circulares (curvatura da Terra) entre os terminais, para muitas localizações de terminais diferentes (pontos-receptores). Para a maioria das aplicações práticas deste método como a análise da cobertura do ponto de área e previsões de interferência, esta suposição implica a disponibilidade de um banco de dados digital de elevação do terreno, referenciado à latitude e longitude em relação a um dado geodésico (geometria das superfícies curvas) consistente, a partir do qual os perfis do terreno podem ser extraídos por meios automatizados disponível em (ITU-R1812-6, 2011).

Se esses perfis de terreno detalhados não estiverem disponíveis, a Recomendação ITU-R P.1546 (ITU-R1546-6, 2019) deve ser usada para previsões. Em vista do exposto, o elemento de variabilidade de localização desta Recomendação e o elemento de modelo de perda por penetração em edifício são caracterizados através das estatísticas de distribuições lognormais em relação às localizações do receptor.

Embora esta caracterização estatística do problema de propagação ponto-área pareça tornar o modelo geral assimétrico (não recíproco), os usuários dessa Recomendação devem observar que a variabilidade de localização pode, em princípio, ser aplicada em qualquer extremidade do enlace, ou mesmo ambos no transmissor ou no receptor. No entanto, a correção da variabilidade de localização só é significativa em situações em que a localização exata de um determinado terminal é desconhecida e é necessária uma representação

estatística sobre as possíveis localizações desse terminal (ITU-R1812-6, 2011).

Na extremidade do transmissor, os usuários também devem adicionar a perda de transmissão na entrada do prédio, caso o transmissor estiver dentro de um prédio. Porém, os usuários também devem estar cientes de que o uso de valores de perda mediana pode ser enganoso, caso o transmissor não estiver em uma localização mediana (ITU-R1812-6, 2011).

2.5.1 Elementos do método para predição da propagação

Este método de predição de propagação de ondas eletromagnéticas leva em consideração os seguintes elementos do modelo: as perdas em visada direta, as perdas por difração (abrangendo terrenos lisos, terrenos irregulares e casos de subcaminho), perdas por dispersão troposférica, perdas por propagação anômala (reflexão/refração de dutos e camadas), perdas por variabilidade de localização, perdas por propagação com variação de ganho pela altura da camada morfológica e as perdas por penetração em edifícios (ITU-R2040-2, 2021).

2.5.2 Parâmetros de entrada

Na Tabela 1, têm-se todos dados básicos de entrada, que definem os terminais de rádio, a frequência f , a porcentagem de tempo P e porcentagem da media de sinal p no local para os quais uma previsão é necessária. As latitudes ϕ_t e ϕ_r e as longitudes ψ_t e ψ_r das duas estações são declaradas como entradas básicas pois são necessárias para obter o perfil do enlace. Os parâmetros radiometeorológicos devem ser obtidos para um único local associado ao enlace de rádio e, para um caminho longo, o centro do caminho deve ser selecionado. É apropriado obter os parâmetros radiometeorológicos para a localização do transmissor ao fazer sua predição na área de cobertura (ITU-R1812-6, 2011).

Para a predição em uma área esse método realiza várias predições ponto a ponto distribuído uniformemente dentro da área, o número de pontes deve ser a quantidade ideal para garantir que os valores de perdas de transmissão sejam o suficiente para estimar o valor médio.

2.5.3 Perfil do enlace

Os perfis de enlace utilizados no método requerem dados específicos de enlace para terreno ao longo do percurso, incluindo a construção de um perfil de terreno usando as alturas reais. É importante observar que a perda de difração pode ser superestimada se o perfil do terreno não possui perdas por difração. Este método ITU-R foi desenvolvido e validado em relação a dados digitais de terreno e combinado com representações aleatórias de categorias de morfologia (*clutter*). Se os dados precisos de altura de superfície estivessem disponíveis, outras técnicas como traçado de raios, que inclui o efeito de

Tabela 1 – Parâmetros de entrada

Parâmetro	Unidade	Mínimo	Máximo	Descrição
f_{req}	GHz	0,03	3,0	Frequência em GHz
ρ	%	1,0	50,0	Percentual anual médio em que o nível de sinal calculado é excedido
ρ	%	1,0	99	Percentual de locais onde o cálculo nível de sinal é excedido
ϕ_t, ϕ_r	graus	-80,0	+80,0	Latitude da transmissão e recepção
ψ_t, ψ_r	graus	-180,0	+180,0	Longitude da transmissão e recepção
h_{tg}, h_{rg}	m	1	3000	Altura da antena acima do nível do solo
Polarização				Tipo de Polarização
w_s	m	1	100	Largura da Rua (da estação móvel) deve se admitir 27 caso não tenha disponível o valor

Fonte: ITU-R 1812-6 (ITU-R1812-6, 2011).

difração em torno de edifícios, poderiam ser exploradas para chegar a um resultado mais preciso de perdas na propagação (ITU-R1812-6, 2011).

Um perfil para o enlace de rádio é necessário para a aplicação do método de previsão de propagação. Inicialmente, consiste em três matrizes, cada uma com o número de pontos de perfil n , sendo d_i a distância do transmissor do i -ésimo ponto de perfil em quilômetros, h_i é a altura do terreno do i -ésimo ponto de perfil acima do nível do mar em metros e G_i é a altura h_i mais altura da camada morfológica do i -ésimo termo do ponto do perfil em metros, em que i é o índice do perfil de enlace. Deve haver pelo menos um ponto de perfil intermediário entre o transmissor e o receptor, assim n deve satisfazer a condição

de $n \geq 3$, pois um número tão pequeno de pontos é apropriado apenas para laços curtos, menor que 1km (ITU-R1812-6, 2011).

A adição de outras alturas não é fisicamente necessária, como as alturas dos telhados no caso de edifícios, onde existem lacunas entre morfologias. Como é visto pela onda de rádio, a energia pode viajar entre os objetos ao invés de sobre eles. Isso se aplica particularmente a áreas urbanas de arranha-céus em categorias como “urbano denso” ou “arranha-céus urbano”, que tendem a estar associados a alturas de construção de 30 metros ou mais. Mas algumas áreas de arranha-céus têm grandes espaços entre os edifícios altos, e é possível que existam caminhos de baixa perda passando em torno deles, em vez de sobre os telhados. Valores menores de alturas representativas em vez dos alturas de morfologia podem ser apropriadas em nesses casos(ITU-R1812-6, 2011).

2.5.4 Processo de Predição

O passo a passo do processo de predição é descrito a seguir. Primeiramente, temos a Tabela 2 com todas as variáveis que influenciam na predição ITU-R, em seguida analisa-se a perda básica de transmissão $L_R(dB)$, as perdas básicas de transmissão devido à propagação de visada direta LoS e as perdas de propagação por difração (ITU-R1812-6, 2011).

Tabela 2 – Parâmetros para análise de perfil de percurso.

Parâmetro	Unidade	Descrição
a_e	km	Raio efetivo da Terra
λ	m	Comprimento de onda
$d - d_i$	m	Distancia do enlace ponto a ponto
d	km	Distância do enlace da área
C_e	km^{-1}	Curvatura da Terra $1/a_e$
d_i	m	Distância do enlace do ponto
h_{ts}, h_{rs}	m	Altura do centro da antena em relação ao nível do mar
h_{tc}, h_{rc}	m	Altura máxima (Altura do centro da antena em relação ao nível do mar, g_1 e g_n respectivamente)

Fonte: ITU-R 1812-6 (ITU-R1812-6, 2011).

2.5.4.1 Propagação em Visada Direta

Todos os parâmetros a seguir devem ser avaliados para percursos com visada direta, a perda básica de transmissão devido à propagação no espaço livre é dada por L_{bfs} na




Figura 5 – Variáveis da Equação (2.20). Fonte: Adaptado de (CASTRO, 2017)

Equação (2.18) em função da distância d_{fs} entre as antenas de transmissão e recepção (km) que é dada por (2.19), em que d é a distância do percurso em km (ITU-R1812-6, 2011).

$$L_{bfs} = 92,4 + 20 \cdot \log(f) + 20 \cdot \log(d_{fs}) \quad (2.18)$$

$$d_{fs} = \sqrt{d^2 + \left(\frac{h_{ts} - h_{rs}}{1000} \right)^2} \quad (2.19)$$

2.5.4.2 Propagação com Difração

A perda por difração é calculada pela combinação de um método baseado na construção de Bullington e da difração esférica da Terra. A parte de Bullington do método é uma expansão do básico da construção de Bullington para controlar a transição entre o espaço livre e as condições obstruídas. Neste método do cálculo de difração é sempre usado o raio médio efetivo da Terra, através de uma aproximação para a perda de difração de Gume de faca simples com uma função da parâmetro adimensional v que é o parâmetro da difração que pode ser calculado como mostra a Equação (2.20) (ITU-R1812-6, 2011), em que as variáveis mostradas na Figura 5, h e λ estão em metros e d_1 e d_2 estão em quilômetros.

$$v = 0,0316 \cdot h \cdot \left[\frac{2 \cdot (d_1 + d_2)}{\lambda \cdot d_1 \cdot d_2} \right] \quad (2.20)$$

Já a perda por difração $J(v)$ é dada por (2.21). É possível notar que $J(-0,78) \approx 0$, e isso define que o limite inferior no qual essa aproximação deve ser usada. $J(v)$ é zero para $v \leq -0,78$.

$$J(v) = 6,9 + 20 \cdot \log(\sqrt{((v - 0,1)^2 + 1)} + v - 0,1) \quad (2.21)$$

O método de difração de Bullington é usado duas vezes para cada cálculo de difração de determinado o raio efetivo da Terra. E em seguida as alturas das antenas são modificadas e todas as alturas dos perfis são zeradas. Nas Equações (2.22), (2.23), as inclinações são calculadas em m/km em relação à linha de base que une o nível do mar no transmissor ao nível do mar no receptor. Os valores a serem usados para a curvatura da Terra $C_e = 1/(63371 \cdot 4/3)$. Encontra-se o ponto de perfil intermediário com a maior inclinação da linha do transmissor ao ponto através de (2.22) (ITU-R1812-6, 2011), em que onde o índice de perfil i assume valores de 2 a $n - 1$.

$$S_{tim} = \max\left(\frac{g_i + 500 \cdot C_e \cdot d_i \cdot (d - d_i) - h_{tc}}{d_i}\right) \quad (2.22)$$

Calcula-se então, em (2.23) a inclinação da linha do transmissor ao receptor assumindo um caminho LoS, com S_{tr} é dado em m/km (ITU-R1812-6, 2011).

$$S_{tr} = \left(\frac{h_{rc} - h_{tc}}{d}\right) \quad (2.23)$$

Caso $S_{tim} < S_{tr}$, o caminho de difração é LoS. Encontra-se em (2.24), o ponto de perfil intermediário com o parâmetro de difração para o máximo valor de v (ITU-R1812-6, 2011), em que o índice de perfil i assume valores de 2 a $n - 1$.

$$v_{max} = \max\left(g_i + 500 \cdot C_e \cdot d_i \cdot (d - d_i) - \frac{h_{tc} \cdot (d - d_i) + h_{rc} \cdot d_i}{d} \cdot \sqrt{\frac{0,002 \cdot d}{\lambda \cdot d_i \cdot (d - d_i)}}\right) \quad (2.24)$$

Calcula-se através de (2.25) a perda no gume da faca Bullington para cada ponto (ITU-R1812-6, 2011).

$$L_{(uc)}(dB) = J(v_{max}) \quad (2.25)$$

As perdas totais calculadas pelo espaço livre e pela difração nesse trabalho foram as definidas por (2.26) (ITU-R1812-6, 2011).

$$L_{(uc)}(dB) = J(v_{max}) + L_{(bfs)} \quad (2.26)$$

2.6 Considerações finais

Neste Capítulo, discutiram-se as principais características da propagação eletromagnética, os modelos de propagação existentes na literatura, as recomendações

da UIT que são utilizados neste trabalho. Neste Capítulo 3, será descrito sobre RNA que é uma rede neural artificial, que também pode ser utilizada para o problema da modelagem de perda de percurso.

3 Rede Neural Artificial

O uso da Inteligência Artificial (IA) tem permeado em diversas áreas da sociedade nos dias atuais. Dentre as várias técnicas de IA, uma técnica bastante utilizada é a Rede Neural Artificial. As RNAs são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. O cérebro de um mamífero pode ter muitos bilhões de neurônios como observa-se na Figura 6, e uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento (SHERPHERD; KOCH, 1990).




Figura 6 – Rede Neural com as sinapses. Fonte: (HSU, 2015)

O cérebro humano é complexo, não linear e paralelo, ou seja, tem a capacidade de organizar os neurônios para realizar cálculos específicos como por exemplo, reconhecimento de padrões, percepções e controle motor, executando tudo isso de forma mais rápida que o computador digital mais rápido atualmente (HAYKIN, 1999). As RNAs modelam sistemas usando conexões sinápticas que simulam o sistema nervoso humano, processam informações e consistem em um grande número de unidades computacionais simples, chamadas neurônios artificiais. Matematicamente, as RNAs são representadas por vetores ou matrizes de pesos sinápticos artificiais, que tendem a reproduzir características humanas (SILVA; H.; FLAUZINO, 2010).

3.1 Características Gerais das Redes Neurais

Uma rede neural artificial é composta por várias unidades de processamento, cujo funcionamento é bastante simples, e essas unidades geralmente são conectadas por canais de comunicação que estão associados a determinado peso, conforme mostrado na Figura 7.

O comportamento inteligente de uma RNA vem das interações entre as unidades de processamento da rede e as unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões.




Figura 7 – Esquema de uma rede neural artificial com três camadas. Fonte: (NUNES, 2003)

Essa RNA da Figura 7 é do tipo de multicamadas e suas arquiteturas neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior. Usualmente as camadas são classificadas em três grupos:

- Camada de Entrada: onde os padrões são apresentados à rede;
- Camadas Intermediárias ou Escondidas: onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- Camada de Saída: onde o resultado final é concluído e apresentado.

O modelo de McCulloch e Pitts de 1943 enxergou o cérebro como um sistema computacional (MCCULLOCH W. S., 1943). Sendo as principais suposições é que a atividade de um neurônio é um processo binário, em que se acerta ou erra, e um único atraso significativo é o atraso sináptico. Já a atividade de qualquer sinapse inibitória previne absolutamente a excitação do neurônio e as estruturas das interconexões não muda com o tempo. Uma RNA é especificada, principalmente pela sua topologia, pelas características dos nós e pelas regras de treinamento.

3.2 Modelagem de um RNA

Primeiramente, tem-se um neurônio com n terminais de entrada: $x_1, x_2, x_3, \dots, x_n$ e apenas um terminal de saída y . O comportamento das sinapses é emulado através de pesos $x_1, x_2, x_3, \dots, x_n$, que são acoplados às entradas dos neurônios, cujo valor pode ser excitatório ou inibitório. Já o efeito de uma sinapse i no neurônio pós-sináptico é obtido pela multiplicação da entrada x_i pelo peso w_i .

Os principais elementos de um RNA são as entradas, os pesos, o viés (*bias*), o somador, a função de ativação e a saída.

- Entradas - são as informações externas que é fornecida pelo usuário.
- Pesos - são componentes centrais do Neurônio Artificial que representam as conexões da rede e, através da sua atualização, é feito o aprendizado fornecendo conhecimento para o Neurônio.
- Viés - serve para aumentar as possibilidades do ajuste dos pesos.
- Função de Ativação - é responsável por definir se o Neurônio vai ser ativado ou não.
- Saída - é a informação gerada pelo Neurônio Artificial, a partir da entrada fornecida.

3.3 Função de Ativação

A função de ativação tem o objetivo de transformar a entrada recebida por um neurônio em um sinal de ativação ou estado. É um sinal de estímulo que entra na extremidade de entrada da rede, propaga-se neurônio por neurônio através da rede e sai na extremidade de saída da rede como um sinal de saída. A função de ativação limita o intervalo permissível de amplitude do sinal de saída em um valor finito. (HAYKIN, 1999).

O sinal da função de ativação define o valor da ativação de um neurônio de acordo com o nível de atividade de entrada esse sinal. As funções de ativação típicas trabalham com adição, comparação ou transformações matemáticas:

- Função Sigmoidal - produz saída de valores contínuos entre 0 e 1, e é dada por (3.1).

$$\Phi(v) = \frac{1}{1 + e^{-v}} \quad (3.1)$$

- Função Tangente Hiperbólica - produz saída de valores contínuos entre -1 e 1, expressa por (3.2).

$$\Phi(v) = \frac{e^v - e^{-v}}{e^v + e^{-v}} \quad (3.2)$$

- Função Gaussiana - produz saída de valores contínuos entre 0 e 1, definida por (3.3), em que μ é o centro da função de ativação e σ é o desvio padrão de v em relação a μ .

$$\Phi(v) = e^{\frac{-(v-\mu)^2}{2\cdot\sigma^2}} \quad (3.3)$$

- Função linear - produz qualquer saída, conforme a expressão(3.4), em que α pertence ao conjunto dos números reais.

$$\Phi(v) = \alpha \cdot v \quad (3.4)$$

3.4 Arquitetura

A maneira como os neurônios artificiais estão organizados dentro de uma RNA depende do algoritmo utilizado para o seu treinamento. Porém, o tipo de arquitetura é essencial para definir o algoritmo de aprendizagem adequado. As arquiteturas são classificadas de acordo com a organização das camadas (HAYKIN, 1999).

A topologia de uma RNA é definida em função dos tipos de conexões, que podem ser excitatórias, inibitórias ou inexistentes. Quanto as conexões de um nó que podem existir conexões de entrada e saída, o arranjo da conexão pode ser do tipo *feedforward* ou recorrente.

3.4.1 RNA com uma camada

Essa RNA tem uma arquitetura simples, é definida por uma camada de sinais de entrada e por um conjunto de neurônios de saída. A direção do fluxo de sinais na rede ocorre apenas em um sentido, a camada de sinais de entrada não é considerada uma camada de neurônios (sem processamento) (HAYKIN, 1999).

3.4.2 RNA com multicamadas

Esta RNA é definida pelas camadas ocultas que podem ser uma ou mais, nessas camadas existem neurônios ocultos, que são responsáveis pelos cálculos dos sinais. As redes multicamadas podem ser utilizadas como classificadoras, seja por combinação de retas ou através de regiões convexas. As camadas intermediárias facilitam o processo de treinamento da rede, cuja função é interferir entre o sinal externo e a saída (HAYKIN, 1999). Tipos de conexões dessa RNA:

- Conexão total: onde todos neurônios de uma camada se interligam a todos da próxima camada, podendo ser a camada de saída.
- Conexão parcial: nem todos os neurônios de camadas diferentes se conectam.

- Conexão local: todos os neurônios da camada oculta se interligam a camada de saída.

3.4.3 RNA recorrentes

Possuem no mínimo uma retroalimentação, que pode ocorrer sem *self-feedback*, quando os nós não geram realimentação para si mesmos, ou com *self-feedback*, quando os nós geram realimentação para si mesmos. A retroalimentação gera um comportamento dinâmico não linear, que funciona como armazenamento desta rede (HAYKIN, 1999).

3.4.4 RNA reticuladas

É construída por uma estrutura de matrizes ($n \times m$), em que a dimensão n é a quantidade de neurônios existentes que determina a entrada, e a dimensão m é o número de níveis que a rede pode estar projetada. Os neurônios dessa rede se organizam em linhas e colunas (HAYKIN, 1999).

3.5 Processos de Aprendizagem

A habilidade de aprendizagem é a propriedade mais importante da RNA que busca melhorar o desempenho da rede, através de um processo iterativo de ajustes aplicado a seus pesos e o treinamento. O aprendizado ocorre quando a RNA atinge uma solução generalizada para uma determinada classe de problemas. Um conjunto de regras bem definidas para a solução de um problema de aprendizado é descrito como algoritmo de aprendizado. Existem diversos tipos de algoritmos de aprendizado específicos para determinados modelos de RNA, diferenciando de acordo com as modificações dos parâmetros (HAYKIN, 1999).

A maneira que uma RNA se relaciona com o ambiente define o processo de aprendizagem, a cada nova iteração esta rede sabe ainda mais sobre si mesma. Existem os seguintes paradigmas de aprendizagem:

- Aprendizado Supervisionado: quando é utilizado um agente externo que indica à rede a resposta desejada para o padrão de entrada, podendo ser estático ou dinâmico, porém sem este agente esta rede não é capaz de aprender;
- Aprendizado Não Supervisionado: é a auto organização, ou seja, quando não existe uma agente externo indicando a resposta desejada para os padrões de entrada;
- Reforço: quando um crítico externo avalia a resposta fornecida pela rede, podendo ter um reforço positivo significa recompensa, um reforço negativo significa punição, ou também pode não existir reforço.

O ciclo de aprendizagem é uma apresentação de todos os N pares de entrada e saída do conjunto de treinamento no processo de aprendizado. A correção dos pesos em um ciclo pode ser verificada de duas maneiras:

- Modo Padrão: A correção dos pesos acontece a cada apresentação à rede de um exemplo do conjunto de treinamento e cada correção de pesos é referente somente ao erro do exemplo apresentado naquela iteração, ou seja em cada ciclo ocorrem N correções.
- Modo Vários: Apenas uma correção é feita por ciclo e todos os exemplos do conjunto de treinamento são apresentados à rede, o erro médio é calculado e a partir deste erro faz as correções dos pesos.

3.5.1 Regras de Aprendizagem por Retropropagação (*Backpropagation*)

Esse algoritmo busca encontrar iterativamente a diferença mínima entre as saídas desejadas e as saídas obtidas pela rede neural, com o mínimo de erro possível, ajustando assim os pesos entre as camadas através da retropropagação do erro encontrado a cada iteração (RUMERLHART D. E.; HINTON G. E.; WILLIAMS, 1986)

3.6 Treinamento da RNA

Pode-se realizar o treinamento supervisionado e o não supervisionado.

3.6.1 Treinamento supervisionado

Consiste em fornecer um conjunto de resultados esperados a RNA, o erro é a diferença entre a saída atual e a saída desejada. O cálculo do erro permite que a matriz de pesos seja ajustada. A cada sequência de treinamento a RNA é melhorada.

Neste treinamento o erro pode ser calculado para cada elemento do conjunto de entrada. Após calcular os erros individualmente, calcula a raiz da média dos quadrados (RMS) que atua como uma taxa de erro global em toda RNA.

3.6.2 Treinamento não supervisionado

No treinamento não supervisionado nenhuma saída é antecipada ou a resposta desejada é fornecida a RNA. Este tipo de treinamento é utilizado apenas para a classificação dos padrões de entrada, um único neurônio na camada de saída dispara uma resposta.

O cálculo do erro em treinamento não supervisionado não é simples, pois as regras de aprendizagem permitem que a rede ajuste o seu erro sozinha. O ideal é que um neurônio dispare em um nível elevado para uma entrada específica, se não for possível, os pesos entre os neurônios são ajustados para que as conexões sejam fortalecidas.

3.6.3 Algoritmo de treinamento Levenberg–Maquardt

Esse algoritmo é caracterizado por ter uma quantidade significativa de pesos sinápticos, que são determinados através da derivada de segunda ordem do erro quadrático nos pesos. Ele apresenta a convergência com a realização de menos iterações, porém requer mais cálculos por iterações devido aos cálculos de matrizes inversas, o que exige maior esforço computacional. O método foi desenvolvido especialmente para uma convergência mais rápida em algoritmos de retropropagação (*backpropagation*), e realiza uma série de cálculos baseados em palpites para determinar a melhor solução, conforme mostrado em (3.5) (BARROS, 2018), em que $g'(\cdot, \theta)$ denota um modelo de aproximação de um número finito de dados, N o número de amostras, l o número de camadas dos neurônios, r é o erro residual, M é o número de saídas, e $J(\theta)$ é o Jacobiana a ser encontrada.

$$J(\theta) = \sum_{i=l}^N \sum_{j=l}^M (g_{ij}(x) - g'_{ij}(x, \theta))^2 = \sum_{k=l}^M r_k^2 \quad (3.5)$$

3.6.4 Algoritmo de treinamento regularização bayesiana

A regularização bayesiana minimiza a combinação linear de erros quadráticos e pesos, modifica a combinação linear para que ao final do treinamento a rede tenha boas qualidades de generalização. Essa regulação acontece dentro do algoritmo Levenberg–Maquardt, a retro-propagação é usada para calcular o jacobiano J de desempenho e performance em relação as variáveis de pesos e *bias* (BARROS, 2018).

As RNA que utilizam esse método são mais robustas e o seu processo de validação reduz ou elimina a necessidade de uma longa validação cruzada. É um processo matemático que converte uma regressão linear em um problema estatístico. O método dificulta que ocorra mais treinamento que o necessário, não prejudicando o aprendizado (BARROS, 2018).

Nesse trabalho o algoritmo para treinamento e aprendizado utilizado foi a regulação bayesiana.

3.7 Considerações finais

Neste Capítulo foi feita uma introdução sobre as redes neurais artificiais, principais características, modelagem, função ativação, arquitetura, treinamento e processos de aprendizagem. Essas características e particularidades serão necessárias para implementar modelos de predição utilizando a inteligência artificial. No Capítulo 4 é descrita a campanha de aquisição dos dados amostrais que são utilizados para a implementação da RNA e avaliação desta e dos modelos empíricos.

4 Campanha de Medição

Neste Capítulo é detalhada a campanha de aquisição de dados em uma rede LTE em Belo Horizonte, com descrição sobre parâmetros medidos, equipamentos utilizados e região onde os dados foram coletados.

4.1 Redes celulares na faixa de 700 MHz

De acordo com a Anatel (ANATEL, 2018), no Brasil a faixa de de frequência entre 698 MHz e 806 MHz, chamada de faixa de 700 MHz, era destinada a TV analógica. Com a migração para a TV digital essa faixa ficou disponível e foi distribuída entre as operadoras de telefonia móvel para implementação da tecnologia *Long Term Evolution* (LTE). Segundo a Anatel, uma das principais vantagens do LTE na faixa de 700 MHz é a melhoria do sinal em ambientes internos, visto que, quanto mais baixa é a frequência menor é a dificuldade do sinal em penetrar em barreiras físicas.

4.1.1 Tecnologia LTE

A tecnologia LTE é baseada no uso da multiplexação por divisão de frequência ortogonal (*Orthogonal Frequency Division Multiplexing* - OFDM). A técnica OFDM é um esquema de modulação especialmente adequado para transmissão de alta taxa de dados em ambientes dispersivos de atraso. Ela converte um fluxo de dados de alta taxa em vários fluxos de baixa taxa que são transmitidos por N canais paralelos de banda estreita, chamados de subportadoras, que podem ser facilmente equalizados. A duração do símbolo em cada subportadora torna-se assim maior por um fator de N , para que o receptor possa separar os sinais transportados por diferentes subportadoras, eles devem ser ortogonais. (RAPAPPORT, 1996)

Para avaliação do sinal recebido, as redes LTE utilizam os parâmetros Indicador de Intensidade do Sinal Recebido (*Received Signal Strength Indicator* - RSSI), Potência Recebida do Sinal de Referência (*Reference Signal Receive Power* - RSRP) e Qualidade Recebida do Sinal de Referência (*Reference Signal Received Quality* - RSRQ). Nas redes celulares, quando uma estação móvel se move de uma célula para outra, realiza-se o *handover* ou troca de células, o que necessita também da medição da qualidade do sinal das células vizinhas (MOLISCH, 2011).

O parâmetro RSSI mede a potência média total recebida incluindo o sinal desejado e a interferência cocanal gerada por outras células. O parâmetro RSRP é a potência média recebida dos sinais de referência LTE espalhados por toda a largura de banda e é considerado banda estreita. O cálculo do RSRP é baseado na energia recebida dentro da parte útil do símbolo OFDM. RSRQ é a qualidade do sinal recebido, na referência

LTE, e seu valor deve ser positivo para a conexão ser estável. O número de blocos ocupados N é utilizado para quantificação da qualidade do sinal através da equação: $RSRQ = (N * RSRP) / RSSI$, que é medido na mesma largura de banda. RSRQ é um tipo de medição de relação entre o sinal desejado e interferência e indica a qualidade do sinal de referência recebido. A medição RSRQ fornece informações adicionais quando RSRP não é suficiente para fazer um *handover* confiável ou decisão de nova seleção de célula.

4.2 Coleta de dados da Rede de Telefonia Móvel

A coleta de dados foi realizada pela equipe de campo da Anatel da Gerência Regional em Belo Horizonte nos dias 14, 18 e 19 de dezembro de 2018 através de um analisador de redes de rádio com a função de varredura para incursões de *test-drive*. Utilizou-se o equipamento do modelo TSMW fabricado pela empresa Rhode & Schwarz, como mostrado na Figura 8. O equipamento possui GPS integrado, opera na faixa de 30 MHz a 6 GHz, possui receptores de RF, Rádio Frequência independentes com largura de banda de 20 MHz. Esse equipamento é capaz de medir simultaneamente até 12 portadoras com uma taxa de até 100 amostras por segundo com sensibilidade de até -123 dBm como mostrado na Figura 9 (SHWARZ, R. &, Rhode & Shwarz, 2017).



Figura 8 – Modelo TSMW. Fonte: (SHWARZ, R. &, Rhode & Shwarz, 2017)

A campanha de aquisição de dados foi realizada em um veículo embarcado com o equipamento e uma antena omnidirecional de ganho de 0 dBi, modelo BMLPV-MBLTE-HP do fabricante PCTEL, uma altura da antena de recepção de 1,7 m. A Figura 10 apresenta as seis estações rádio-base que serviram de antenas transmissoras para a coleta de dados. Entre as seis estações foram coletadas diversas amostras, sendo utilizadas para este trabalho as amostras do dia 18 recebidas de duas estações de transmissão, a escolha dessas amostras foi decidida por essa ter o maior volume de amostras. Uma estação localizada na rua Maria Amélia Maia, n° 300 e a outra na rua Deputado Último Carvalho n° 30, com um total 5206 amostras medidas georreferenciadas, como pode-se observar nas Figuras 11 e 13. As medições na sub faixa de radiofrequência de 700 MHz, mais especificamente na faixa entre 773 MHz a 783 MHz.

As medições foram feitas a uma distância máxima de 900 m da estação base, a uma velocidade média de 50 km/h. As seis estações base estão localizadas conforme



Figura 9 – Setup da coleta de dados realizada pelo drive test. Fonte: (SHWARZ, R. &, Rhode & Shwarz, 2017)

a Figura 10. Porém, para esse trabalho utilizou-se as medidas do dia 18 coletadas de duas estações base localizadas no Planalto e São Tomaz, conforme as Figuras 11 e 13. Para todas medições foram considerados a frequência de operação, altura da antena transmissora dentro dos limites suportados pelos modelos de propagação, informações sobre os equipamentos utilizados.

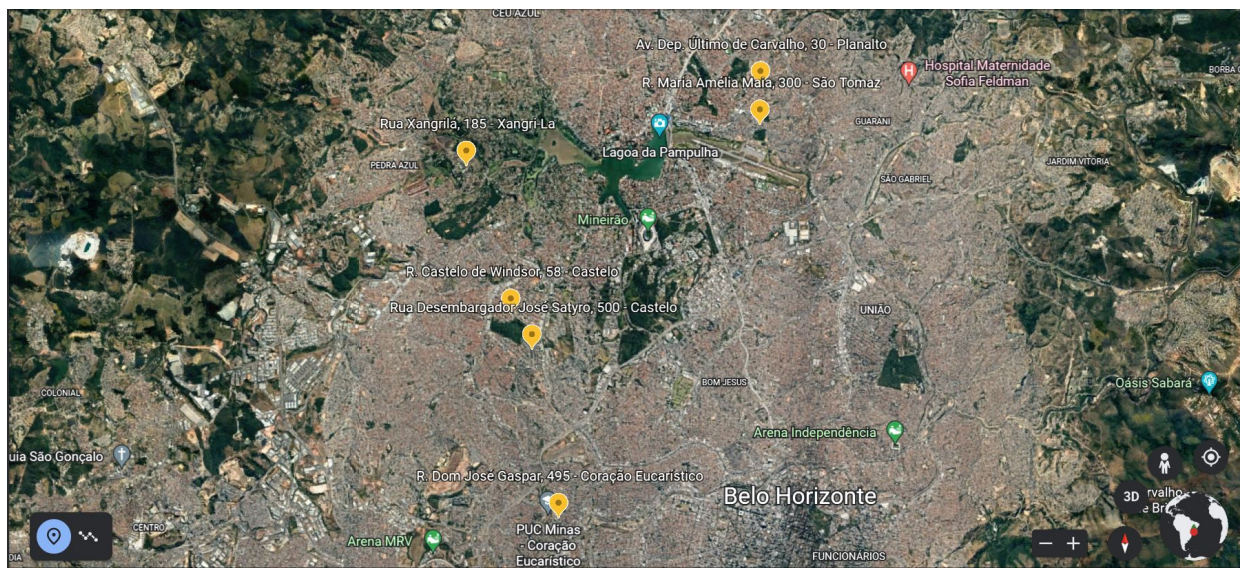


Figura 10 – Localização das Antenas da operadora de telefonia móvel em 700 MHz. Fonte: Google Earth.

As antenas transmissoras e a antena da estação móvel estão a uma diferença média de 30 m de altitude longe uma das outras.

As características de relevo da estação base localizada no São Tomaz 14 e no Planalto 12, podemos dizer que as características da área de coleta de dados é bastante diversa nas proximidades das antenas.

As características técnicas da estação base são dadas pelas:




Figura 11 – Estação n° 1003002592 – Rua Maria Amélia Maia, 300 - São Tomaz – Belo Horizonte/MG. Fonte: Google Earth.




Figura 12 – Característica sub-urbana na proximidade da Estação n° 1003002592 – Rua Maria Amélia Maia, 300 - São Tomaz – Belo Horizonte/MG. Fonte: Google Earth.

- Coordenadas:
Latitude: $1951^{\circ}39,1''S(-19,860861)$,
Longitude: $4357^{\circ}45,9''O(-43,96275)$
- Altitude: Aproximadamente 814 metros.
- Tecnologia: LTE.

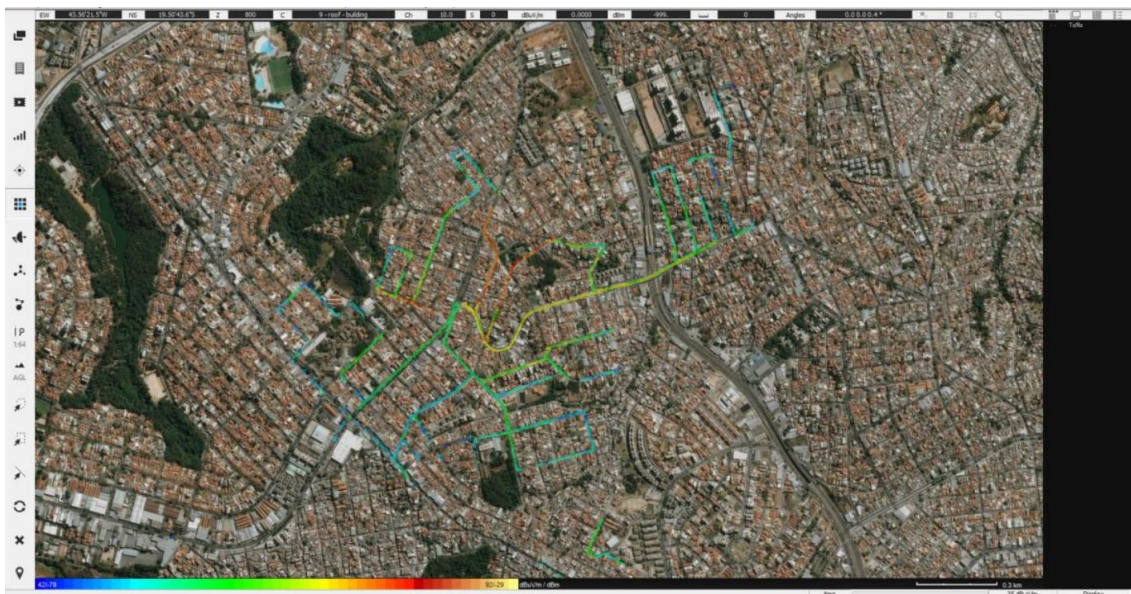


Figura 13 – Estação n° 379988976 – Avenida Deputado Último Carvalho, 30 - Planalto – Belo Horizonte/MG. Fonte: Google Earth.




Figura 14 – Característica sub-urbana na proximidade da Estação n° 379988976 – Avenida Deputado Último Carvalho, 30 - Planalto – Belo Horizonte/MG. Fonte: Google Earth.

- Antenas das estações: 3799888976 (PCI136, PCI137 e PCI138) e 1003002592 (PCI156, PCI157 e PCI158).

Para as Estações Rádio-Bases 3799888976 e 1003002592 adotaram-se as seguintes configurações: Tilt Mecânico de 10,4°, Ganho Máximo de 15,8 dBi, Potência Máxima de 80 W (49 dBm).

O tratamento de dados da campanha de medição foi feito de acordo com (NUNES, 2017).

4.3 Considerações finais

Neste Capítulo descreveu-se a campanha de aquisição de dados de potência medida para a tecnologia LTE na faixa de 700 MHz. No Capítulo 5, é apresentada a comparação dos resultados amostrais medidos e os resultados preditos por diferentes modelos.

5 Análise de modelos de propagação

Neste Capítulo, é apresentada a comparação dos modelos de propagação descritos no Capítulo 2, em relação aos dados medidos. Em todos os modelos descritos, considera-se a variação de intensidade de sinal em função da distância, levando em conta o ganho da antena transmissora (estação radio-base) para cada posição da estação móvel. Nos resultados obtidos, os parâmetros que serão avaliados são a raiz do erro médio quadrático (RMSE), coeficiente de correlação entre as curvas, a distância entre as curvas medida e predita.

5.1 Raiz do Erro Quadrático Médio

O cálculo da raiz do erro quadrático médio (RMSE) fornece a média de diferença quadrática entre a predição do modelo e o valor de destino. Ele pode ser usado como a medida da qualidade de um estimador (WILLMOTT, 1981). O RMSE em sua forma mais simples é representado por (5.1), em que N representa a quantidade de amostras, X_i é o valor da amostra medida e X'_i denota o valor predito.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (X_i - X'_i)^2}{N}} \quad (5.1)$$

A raiz do erro médio quadrático possui uma única dimensão que é igual à dimensão dos valores observados e preditos. Por isso interpreta-se seu valor como uma medida do desvio médio entre observado e predito. Contudo, as diferenças entre X_i e X'_i são elevadas ao quadrado. Essas diferenças podem ser positivas ou negativas dependendo se o valor estimado for inferior ou superior ao valor real observado (TAYLOR, 1997).

5.2 Distância Média

A distância média D_M é a soma das distâncias entre a curva de dados medidos X_i e a curva da dados preditos X'_i dividida pelo número de pontos N , como mostrado em (5.2)

$$D_M = \frac{\sum_{i=1}^N (X_i - X'_i)}{N} \quad (5.2)$$

5.3 Coeficiente de Correlação

O grau de correlação entre duas variáveis, conhecido como coeficiente de correlação de Pearson, busca analisar a correlação linear entre duas variáveis, representadas num plano cartesiano (X, Y) ou gráfico de dispersão, no qual apresentam uma dispersão ao longo de uma reta imaginária. O coeficiente de correlação de Pearson pode ter um intervalo de valores de -1 a +1. Um valor de zero indica que não há associação entre as duas variáveis. Um valor maior que zero indica uma associação positiva, e à medida que o valor de uma variável aumenta, o mesmo acontece com o valor da outra variável. Um valor menor que zero indica uma associação negativa, e à medida que o valor de uma variável aumenta, o valor da outra diminui. O coeficiente de correlação linear de Pearson $R'_{XX'}$ entre a amostra observada X_i e a amostra predita X'_i é definido por (5.3), em que N indica a quantidade de amostras (HOFFMAN, 2006).

$$R_{XX'} = \frac{N \cdot \sum_{i=1}^N X_i \cdot X'_i - \sum_{i=1}^N X_i \cdot \sum_{i=1}^N X'_i}{\sqrt{N \cdot \sum_{i=1}^N X_i^2 - (\sum_{i=1}^N X_i)^2} \cdot \sqrt{N \cdot \sum_{i=1}^N X_i'^2 - (\sum_{i=1}^N X'_i)^2}} \quad (5.3)$$

O coeficiente encontrado na Equação (5.3) é adimensional, logo não é afetado pelas unidades de médias das variáveis X e X' . O sinal positivo indica que as variáveis são diretamente proporcionais, porém o sinal negativo já indica qual a relação entre as variáveis é inversamente proporcional (HOFFMAN, 2006).

5.4 Resultados

Conforme indicado no Capítulo 4, em virtude da maior quantidade de dados válidos para análise, foram utilizados apenas os dados para duas estações rádio-base:

- Estação localizada no bairro Planalto, composta dos setores indicados pelos Identificadores de Célula de Camada Física (*Physical layer Cell Identifiers* - PCIs) 136, 137 e 138.
- Estação localizada no bairro São Thomaz, composta dos setores indicados pelos PCIs 156, 157 e 158.

Para análise dos modelos de predição de cobertura, utilizou-se os valores de RSRP coletados nas campanhas de medição.

A variação de potência recebida em pontos próximos nas curvas de dados medidos e preditos ocorre por ser levado em conta o diagrama de irradiação da antena transmissora (estação rádio-base) para cálculo da potência recebida P_r . Deste modo, o ganho da antena está relacionado com a latitude, longitude, a distância, elevação e o azimute. Como em cada ponto, o ganho deve variar, foi fornecido juntamente com os dados de RSRP medidos,

os valores de ganho para cada posição na área de análise, sendo estes incorporados às curvas de predição.

5.4.1 Estação Planalto

Para a Estação Planalto, foram coletadas amostras para cada setor representado por seu PCI e comparados os resultados dos modelos Okumura-Hata, 3GPP, ITU-Advanced e ITU-R 1812-6. Nas Figuras 15,16,17 são feitas as comparações dos modelos e das medições para os setores identificados pelos PCIs 136, 137 e 138, respectivamente.




Figura 15 – Resultados do comportamento da predição para PCI136 dos modelos Okumura-Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

Nas Figuras 15, 16, pode-se observar quando se compara as curvas de cada modelo e a curva de medição no ponto mais próximo e mais distante a estação base todos apresentam um erro de *offset*, com o ITU-R apresentando maior proximidade à medição. Já quando observa a Figura 17 que tem maior número de pontos medidos o modelo que apresentou maior erro de *offset* foi o ITU-R.

Ao analisar os gráficos da Estação Planato observamos erro de *offset* em todos os setores. E para aproximar as curvas medidas e preditas, precisa-se corrigir esse erro que pode ser causado através da calibração de equipamentos, nível de ruído, entre outros. Para reduzir o RMSE entre a predição e a medição foi feito ajustes no *offset*. Nas Figuras 18,19,20 pode-se observar a melhoria na predição para cada setor após a correção de *offset*.

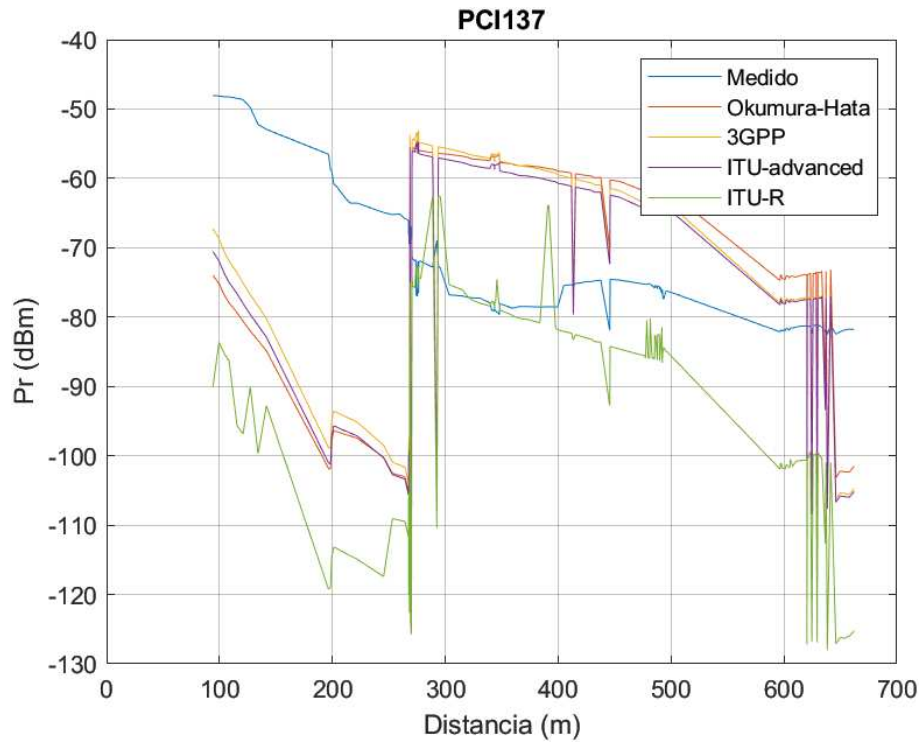


Figura 16 – Resultados do comportamento da predição para PCI137 dos modelos Okumura-Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

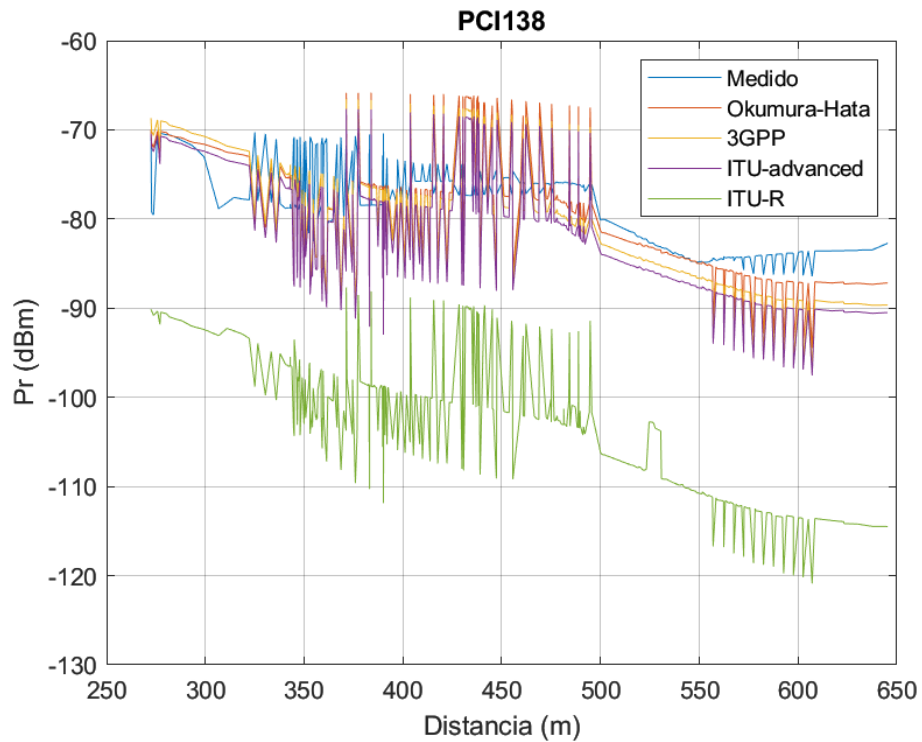


Figura 17 – Resultados do comportamento da predição para PCI138 dos modelos Okumura-Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

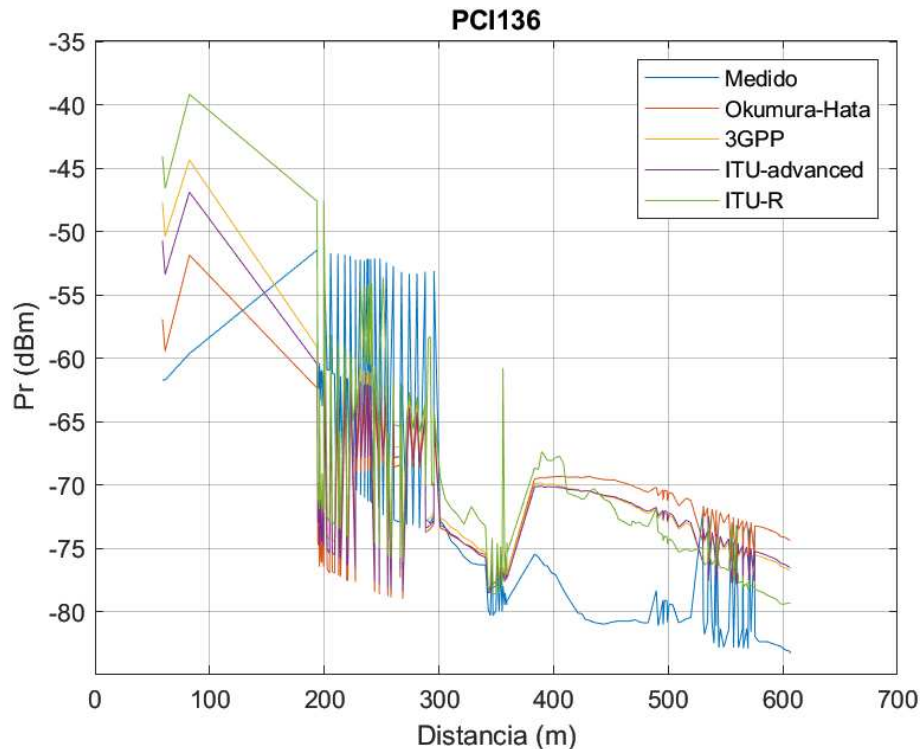


Figura 18 – Resultados do comportamento da predição para PCI136 após correção de *offset* dos modelos Okumura-Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

Nas Figuras 18, 19, 20, ao se comparar as curvas de cada modelo e a curva de medição no ponto mais próximo e mais distante a estação base, todos apresentam uma melhoria significativa após a correção do erro de *offset*. O modelo do ITU-R é o que apresenta maior proximidade à medição. Ao tentar alterar a inclinação das curvas da Estação Planato com o intuito de melhorar e aproximar a inclinação das curvas dos modelos a curva de medidas, não houve melhoria significativa na similaridade das curvas para nenhum dos modelos.

5.5 Estação São Thomaz

Nessa estação rádio-base encontram-se os setores identificados pelos PCIs 156, 157 e 158. As Figuras 21,22,23 apresentam as comparações dos modelos e das medições.

Nas Figuras 21, 22, pode-se observar quando se compara as curvas de cada modelo e a curva de medição no ponto mais próximo e mais distante a estação base todos apresentam um erro de *offset*, porém o ITU-R é o que apresenta maior proximidade à medição. Observa-se na Figura 23 que o modelo que apresenta menor erro de *offset* é o ITU-R quando comparado com os outros modelos.

Ao analisar os gráficos da Estação São Thomaz observamos erro de *offset* em todas os setores. E para aproximar as curvas medidas e preditas, precisa-se corrigir esse erro que pode ser causado através da calibração de equipamentos, nível de ruído, entre outros.




Figura 19 – Resultados do comportamento da predição para PCI137 após correção de *offset* dos modelos Okumura-Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

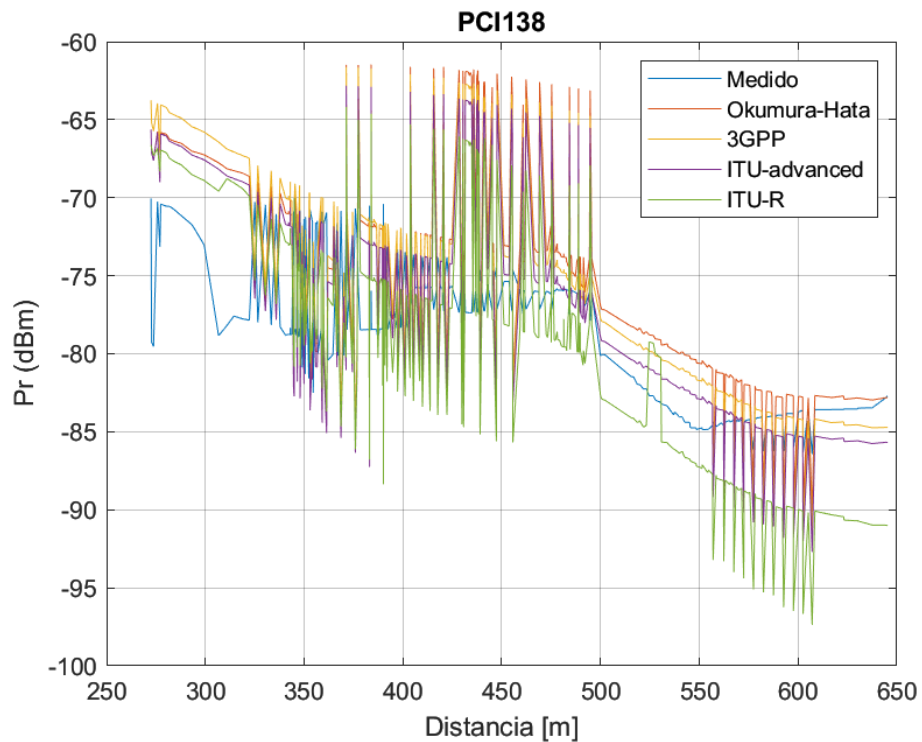


Figura 20 – Resultados do comportamento da predição para PCI138 após correção de *offset* dos modelos Okumura-Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

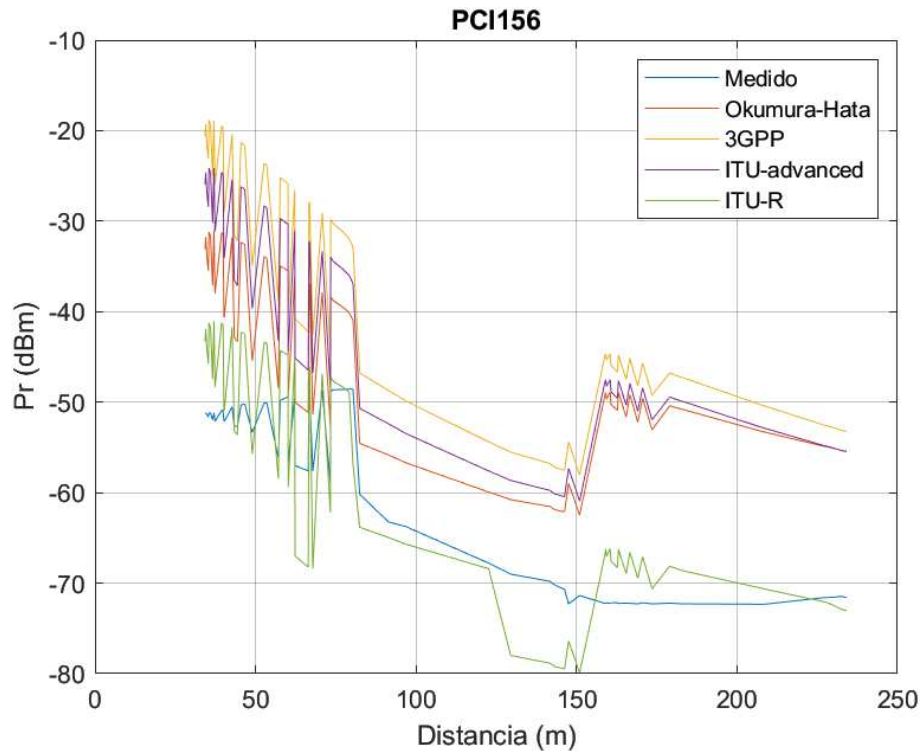


Figura 21 – Resultados do comportamento da previsão para PCI156 dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

Para reduzir o RMSE entre a previsão e a medição realizam-se ajustes no *offset*. Nas Figuras 24,25,26 pode-se observar a melhoria na previsão para cada setor após a correção de *offset*.

Nas Figuras 24, 25, 26, ao comparar as curvas de cada modelo e a curva de medição no ponto mais próximo e mais distante da estação rádio-base, observa-se uma melhoria significativa após a correção do erro de *offset*, com o modelo do ITU-R apresentando maior proximidade a medição. Com o intuito de melhorar e aproximar a inclinação das curvas dos modelos à curva de medidas, fez-se a correção da inclinação com relação à taxa de correlação. Contudo, não houve melhoria significativa na similaridade das curvas para nenhum dos modelos.

5.6 Análise dos resultados

As Tabelas 3, 4, 5, 6, 7 e 8 apresentam os resultados da raiz do erro médio quadrático, a distância média e a correlação antes e após a correção de *offset* para os setores identificados pelos PCIs 136, 137, 138, 156, 157 e 158, respectivamente.

Ao analisar a Tabela 3 de resultados para PCI136 localizada na Estação Planalto, pode-se dizer que a Distancia Média entre a previsão e a medição diminui para aproximadamente 1 dB após a correção de *offset*. Há também diminuição do RMSE,

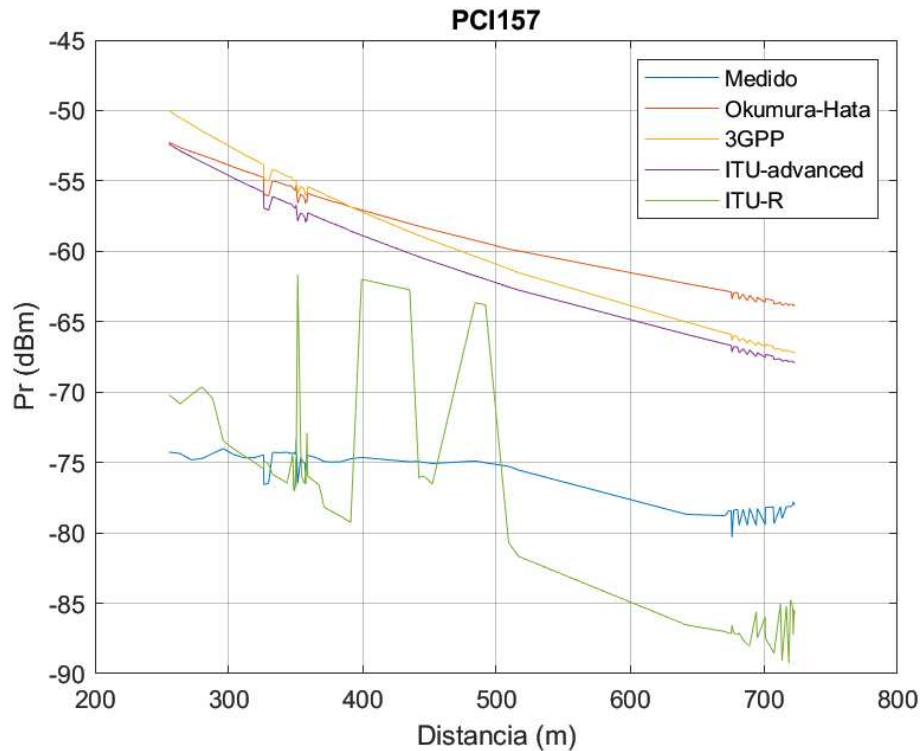


Figura 22 – Resultados do comportamento da previsão para PCI157 dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

mas a Correlação se mantém para todos os modelos, e está entre 54% e 68%.

Tabela 3 – Resultados da avaliação para Setor de PCI 136 localizado na Estação Planato.

Modelo	RMSE	Distância Média	Correlação
Okumura–Hata	10,8768	-9,6990	0,5468
3GPP	11,1076	-10,6057	0,6799
ITU-Advanced	9,9271	-8,8651	0,6524
ITU-R 1812-6	10,2517	9,0044	0,6253
Após correção de <i>offset</i>			
Okumura–Hata	7,6916	1,1778	0,5468
3GPP	6,964	0,5019	0,6799
ITU-Advanced	7,1253	1,0620	0,6524
ITU-R 1812-6	7,4382	-1,2474	0,6253

Fonte: Autoria própria.

Ao analisar a Tabela 4 de resultados para PCI137 localizada na Estação Planalto, nota-se que a Distância Média entre a predição e a medição aumentou para todos os modelos exceto para o ITU-R que foi para aproximadamente 2 dB após a correção de *offset*, e o RMSE diminuiu para todos os modelos. Já a Correlação mantém igual para todos os modelos, e está entre 18% e 38%, a menor entre os setores desta Estação.




Figura 23 – Resultados do comportamento da previsão para PCI158 dos modelos Okumura–Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

Tabela 4 – Resultados da avaliação para Setor de PCI 137 localizado na Estação Planato.

Modelo	RMSE	Distância Média	Correlação
Okumura–Hata	20,4336	-2,8832	-0,3835
3GPP	19,2881	-2,7124	-0,2640
ITU-Advanced	19,0402	-1,4232	-0,3000
ITU-R 1812-6	18,9892	16,6885	-0,1824
Após correção de <i>offset</i>			
Okumura–Hata	18,2136	17,5504	-0,3835
3GPP	17,9784	16,5757	-0,2640
ITU-Advanced	18,397	17,617	-0,3000
ITU-R 1812-6	17,9415	-2,3006	-0,1824

Fonte: Autoria própria.

Ao analisar a Tabela 5 de resultados para PCI138 localizada na Estação Planalto, pode-se observar que a Distância Média entre a previsão e a medição aumentou para todos os modelos exceto para o ITU-R que foi para aproximadamente 0 dB após a correção de *offset*, e o RMSE diminuiu para o ITU-R porém piorou um pouco para os outros modelos. Já a Correlação mantém igual para todos os modelos, e está entre 29% e 48%.

Ao analisar a Tabela 6 de resultados para o Setor de PCI 156 localizada na Estação São Thomaz, pode-se dizer que a Distancia média entre a previsão e a medição melhorou

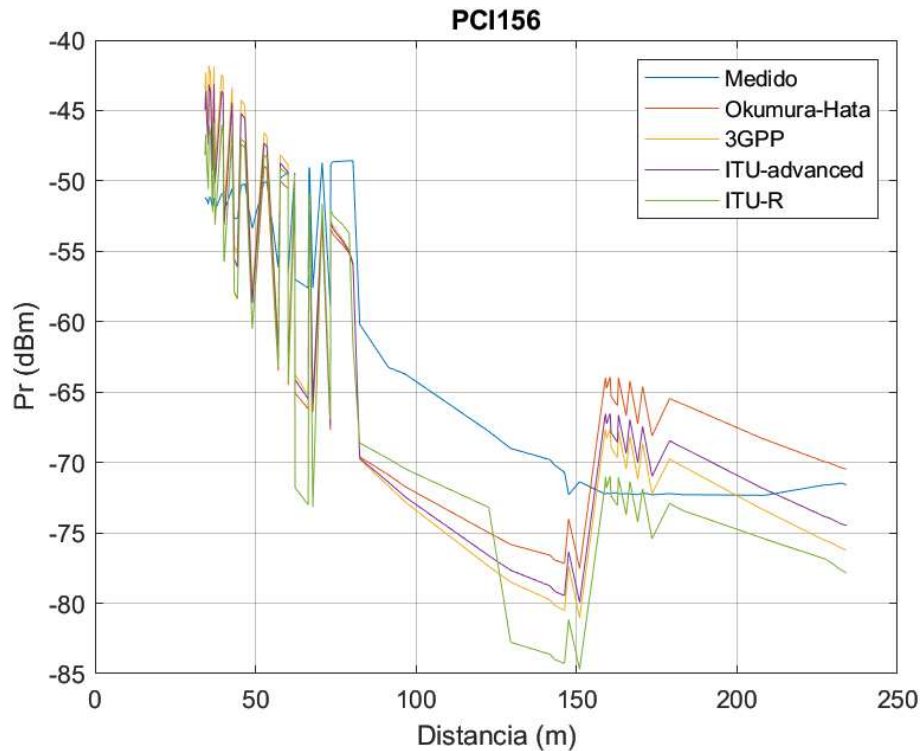


Figura 24 – Resultados do comportamento da predição para PCI156 após correção de *offset* dos modelos Okumura-Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

Tabela 5 – Resultados da avaliação para Setor de PCI 138 localizado na Estação Planato.

Modelo	RMSE	Distância Média	Correlação
Okumura-Hata	4,3688	0,7701	0,2923
3GPP	4,9321	1,4434	0,3399
ITU-Advanced	4,8284	2,7071	0,3330
ITU-R 1812-6	23,4971	23,971	0,4793
Após correção de <i>offset</i>			
Okumura-Hata	5,9842	-3,5987	0,2923
3GPP	5,9529	-3,4887	0,3399
ITU-Advanced	5,2437	-2,1213	0,3330
ITU-R 1812-6	5,2436	-2,3911e-14	0,4793

Fonte: Autoria própria.

para todos os modelos indo para aproximadamente 1 dB após a correção de *offset*, e o RMSE diminuiu para todos os modelos. Já a Correlação mantém igual para todos os modelos, e está entre 85% e 92%.

Ao analisar a Tabela 7 de resultados para PCI157 localizada na Estação São Thomaz, pode-se dizer que a Distância média entre a predição e a medição melhorou para todos os modelos indo para aproximadamente 1 dB após a correção de *offset*, e o RMSE diminuiu para todos os modelos. Já a Correlação mantém igual para todos os modelos, e está entre




Figura 25 – Resultados do comportamento da predição para PCI157 após correção de *offset* dos modelos Okumura-Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

Tabela 6 – Resultados da avaliação para Setor de PCI 156 localizado na Estação São Thomaz.

Modelo	RMSE	Distância Média	Correlação
Okumura-Hata	15,0502	-15,0502	0,8584
3GPP	22,9773	-22,9773	0,9009
ITU-Advanced	19,0146	-19,0146	0,8923
ITU-R 1812-6	4,7824	-2,4098	0,9227
Após correção de <i>offset</i>			
Okumura-Hata	4,636	-4,6573e-15	0,8584
3GPP	4,8013	-7,404e-15	0,9009
ITU-Advanced	4,6372	-1,3614e-14	0,8923
ITU-R 1812-6	4,2378	2,3725	0,9227

Fonte: Autoria própria.

82% e 92%.

Ao analisar a Tabela 8 de resultados para PCI158 localizada na Estação São Thomaz, pode-se dizer que a Distância Média entre a predição e a medição melhorou para todos os modelos indo para aproximadamente 0 dB, exceto para o ITU-R que piorou um pouco após a correção de *offset*, e o RMSE diminuiu para todos os modelos. Já a Correlação mantém igual para todos os modelos, entre 81% e 85%, exceto para o ITU-R que piorou




Figura 26 – Resultados do comportamento da previsão para PCI158 após correção de *offset* dos modelos Okumura-Hata, 3GPP, ITU-Advanced e ITU-R 1812-6 em comparação com as medições.

Tabela 7 – Resultados da avaliação para Setor de PCI 157 localizado na Estação São Thomaz.

Modelo	RMSE	Distância Média	Correlação
Okumura-Hata	17,4914	-17,4914	0,9159
3GPP	16,6665	-16,6665	0,9109
ITU-Advanced	15,2063	-15,2063	0,9122
ITU-R 1812-6	4,8015	2,6916	0,8245
Após correção de <i>offset</i>			
Okumura-Hata	1,9672	6,1321e-15	0,9159
3GPP	3,6273	-8,7601e-16	0,9109
ITU-Advanced	3,1221	3,8934e-15	0,9122
ITU-R 1812-6	4,7036	-2,1098	0,8245

Fonte: Autoria própria.

um pouco após a correção de *offset*.

Os resultados principais da Estação Planalto estão na Tabela 9, em que o modelo que mais teve similaridade com a medição foi o ITU-R 1812-6.

Os resultados principais da Estação São Thomaz estão na Tabela 10, em que o modelo que mais teve similaridade com a medição foi o ITU-R 1812-6.

Tabela 8 – Resultados da avaliação para Setor de PCI 158 localizado na Estação São Thomaz.

Modelo	RMSE	Distância Média	Correlação
Okumura-Hata	19,6294	-19,6294	0,8108
3GPP	20,4748	-20,4748	0,8163
ITU-Advanced	18,5371	-18,5371	0,8186
ITU-R 1812-6	3,8918	0,7880	0,8522
Após correção de <i>offset</i>			
Okumura-Hata	5,5658	2,7961e-14	0,8108
3GPP	4,7384	-2,1612e-14	0,8163
ITU-Advanced	4,966	-1,6119e-15	0,8186
ITU-R 1812-6	4,2092	-3,1038	0,8522

Fonte: Autoria própria.

Tabela 9 – Análise dos Resultados da Estação Planalto

PCI136 Modelo	RMSE	Distância Média	Correlação
<i>Okumura-Hata</i>	7,6916	1,1778	0,5468
<i>3GPP</i>	6,964	0,5019	0,6799
<i>ITU-Advanced</i>	7,1253	1,0620	0,6524
<i>ITU-R 1812-6</i>	7,4382	-1,2474	0,6253
PCI137 Modelo	RMSE	Distância Média	Correlação
<i>Okumura-Hata</i>	18,2136	17,5504	-0,3835
<i>3GPP</i>	17,9784	16,5757	-0,2640
<i>ITU-Advanced</i>	18,397	17,617	-0,3000
<i>ITU-R 1812-6</i>	17,9415	-2,3006	-0,1824
PCI138 Modelo	RMSE	Distância Média	Correlação
<i>Okumura-Hata</i>	5,9842	-3,5987	0,2923
<i>3GPP</i>	5,9529	-3,4887	0,3399
<i>ITU-Advanced</i>	5,2437	-2,1213	0,3330
<i>ITU-R 1812-6</i>	5,2436	-2,3911e-14	0,4793

Fonte: Autoria própria.

Com as melhorias de *offset*, o melhor método de predição para esse setor continua sendo o ITU-R 1812-6. Algumas observações podem ser feitas com relação aos resultados:

- O modelo Okumura-Hata utilizado é aquele para ambientes suburbanos, devido às características da região de análise. Ele apresenta um resultado aceitável, porém exigiu um ajuste maior de *RMSE* quando comparado com os outros modelos. A correlação dessa predição ficou em geral pior para o mesmo setor quando comparado a outros modelos.
- O modelo 3GPP para ambientes suburbano apresenta um bom resultado na

Tabela 10 – Análise dos Resultados da Estação São Tomaz

PCI156 Modelo	RMSE	Distância Média	Correlação
<i>Okumura-Hata</i>	4,636	-4,6573e-15	0,8584
<i>3GPP</i>	4,8013	-7,404e-15	0,9009
<i>ITU-Advanced</i>	4,6372	-1,3614e-14	0,8923
<i>ITU-R 1812-6</i>	4,2378	2,3725	0,9227
PCI157 Modelo	RMSE	Distância Média	Correlação
<i>Okumura-Hata</i>	1,9672	6,1321e-15	0,9159
<i>3GPP</i>	3,6273	-8,7601e-16	0,9109
<i>ITU-Advanced</i>	3,1221	3,8934e-15	0,9122
<i>ITU-R 1812-6</i>	4,7036	-2,1098	0,8245
PCI158 Modelo	RMSE	Distância Média	Correlação
<i>Okumura-Hata</i>	5,5658	2,7961e-14	0,8108
<i>3GPP</i>	4,7384	-2,1612e-14	0,8163
<i>ITU-Advanced</i>	4,966	-1,6119e-15	0,8186
<i>ITU-R 1812-6</i>	4,2092	-3,1038	0,8522

Fonte: Autoria própria.

predição. Porém, assim como no modelo Okumura–Hata é necessário fazer correções de *RMSE*. Ele apresenta baixa correlação entre a medição e a predição. A vantagem desse modelo é a simplicidade de implementação.

- O modelo ITU-Advanced, que apresenta equações mais complexas, também necessita correção de *offset* e apresenta correlação mais baixa na Estação Planalto do que na Estação São Thomaz.
- O modelo ITU-R 1812-6 apresenta melhor concordância com os valores obtidos pela medição, porém foi necessário fazer ajustes de *offset*. A correlação dessa predição é, em geral, mais alta do que as dos outros modelos.

5.7 Considerações finais

Neste Capítulo, foi apresentada uma comparação entre os modelos de propagação e as medições. Após a comparação entre os modelos de propagação e a análise de resultados para todos setores de duas células, verificou-se uma melhor acurácia do modelo de propagação ITU-R 1812-6. O setor que apresentou resultados mais próximos às medições foi o setor identificado pelo PCI 137, localizada na Estação Planalto, após a correção do erro de *offset*. No Capítulo 6, serão analisados os resultados de predição através da RNA.

6 Análise de Rede Neural Artificial

Neste Capítulo é apresentada a comparação entre os resultados a RNA descrita no Capítulo 3 com as medições, sendo primeiramente descrito o modelo de RNA utilizado.

6.1 Modelo de RNA utilizado

O Modelo de RNA utilizado para a predição baseia-se na implementação em MATLAB, utilizando a função *fitnet*, *train* e *perform*. Essas funções criam a RNA e utiliza-se a retroalimentação para a definição dos pesos e *bias*. Para análise de desempenho da rede aplica a análise do erro quadrático médio.

Para armazenar os valores para teste e treinamento, devem-se colocar os valores de entrada em uma matriz X e os valores de saída em uma matriz Y com os destinos dessas matrizes associado.

Em seguida, constrói-se uma rede neural com uma camada de entrada e uma camada de saída. Utilizou-se a função *fitnet* com dez neurônios por camada como pode-se observar na Figura 27.




Figura 27 – Rede neural artificial extraída do ambiente MatLab.

O algoritmo de treinamento padrão para uma rede de ajuste de função Levenberg-Marquardt, usa-se também o algoritmo de treinamento de regularização bayesiana e compara os resultados de desempenho. Ele ajusta os tamanhos de cada camada após o treinamento, considerando as camadas de entrada e saída nulas inicialmente. Após a rede ser treinada, é estimado os alvos utilizando-a, e feito a análise de desempenho da rede como mostrada na Figura 28. A função que avalia o desempenho da rede é o erro quadrático médio MSE , conforme descrito por (6.1).

$$MSE = \frac{\sum_{i=1}^N (X_i - X'_i)^2}{N} \quad (6.1)$$

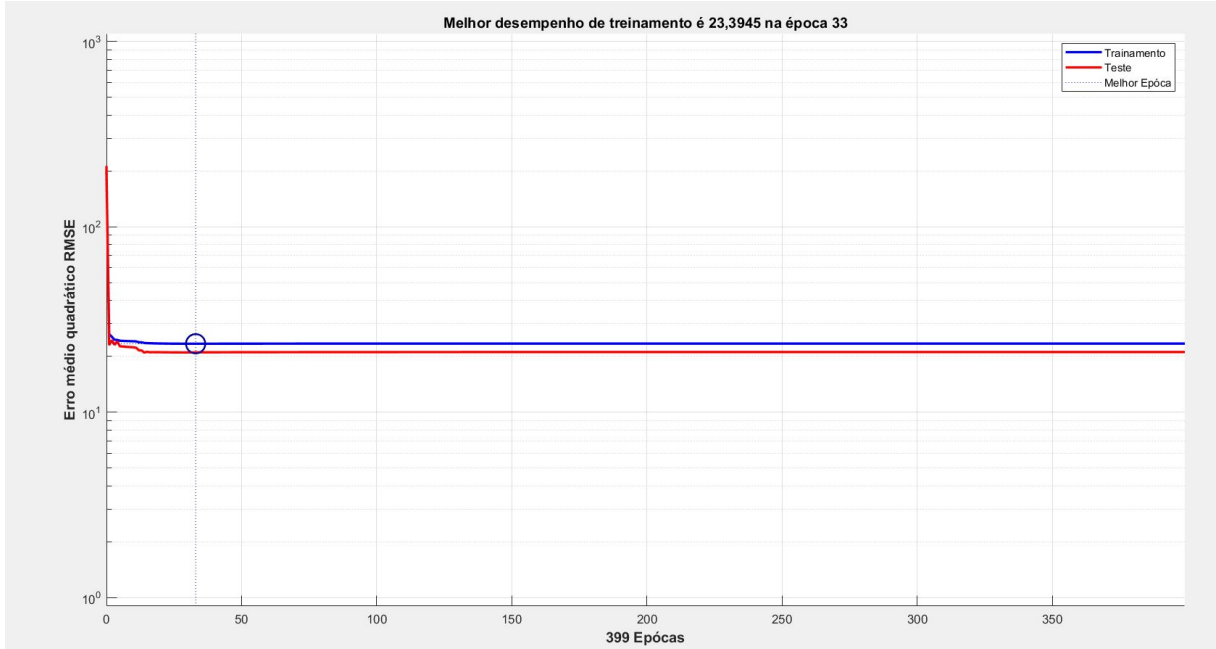


Figura 28 – Análise de desempenho da rede neural artificial extraída do ambiente MatLab.

Na análise de desempenho da RNA observa-se que, quando o teste e o treinamento torna o MSE nulo, então pode-se dizer que alcançou o resultado ótimo da RNA. Como no caso desta que chegou a esse valor após a iteração 33.

A seguir na Figura 29 pode-se observar o diagrama de rede implementada, em que são apresentadas todas informações da rede, da construção da rede e da divisão de aleatória de dados. Ela também mostra que o treinamento da rede foi feito através da regularização Bayesiana, e que a análise de desempenho baseou-se no MSE .

A RNA é treinada e posteriormente utilizada para todos os casos amostrais dos 6 setores, conforme apresentado a seguir.

6.2 Estação Planalto

Nesta estação rádio-base estão as PCIs 136, 137 e 138, cujas medições são comparadas com os resultados da RNA são mostradas nas Figuras 30, 31, 32.

Nas Figuras 30, 31, 32, pode-se observar quando compara-se as curvas obtidas pela rede neural tem maior similaridade com a curva dos valores medidos sem necessitar de ajustes de erro de *offset* ou Correlação. Ao analisar os gráficos do Setor 1 observamos a otimização RNA é muito mais eficiente que os outros modelos simulados.

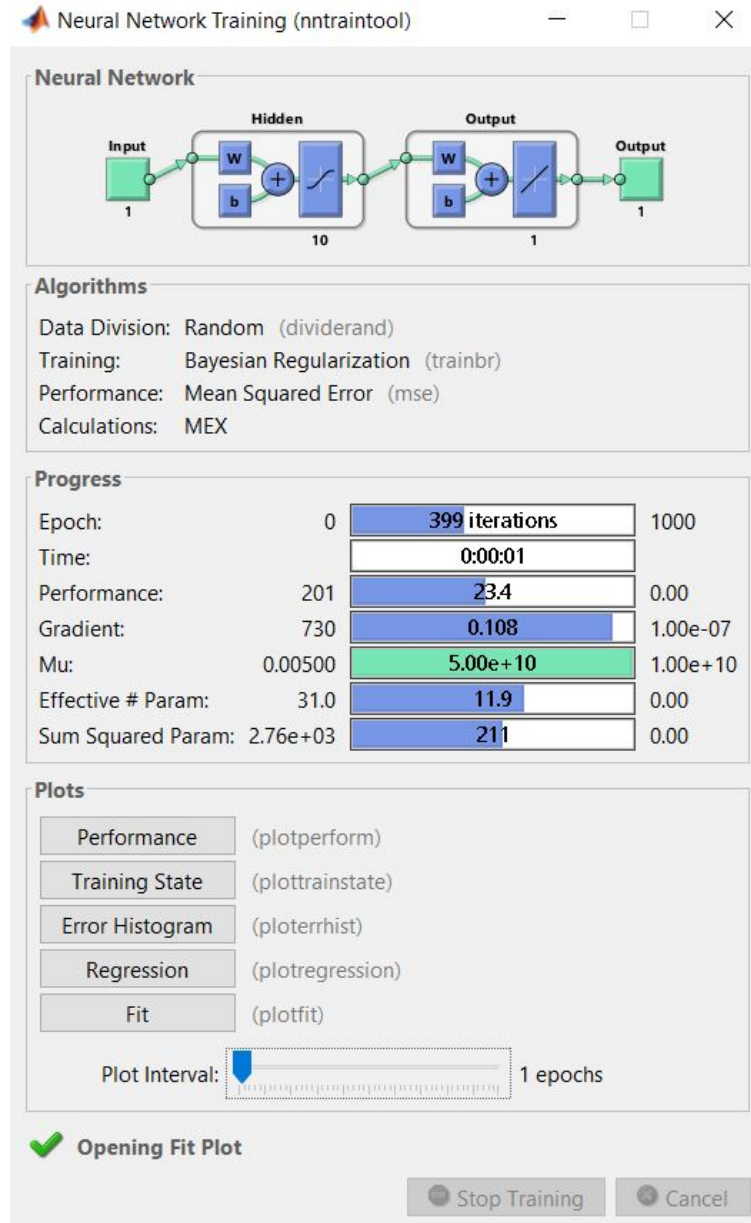


Figura 29 – Diagrama da rede neural artificial extraída do ambiente MatLab.

6.3 Estação São Thomaz

A Estação São Thomaz é formada pelos setores identificados pelos PCIs 156, 157 e 158. As Figuras 33, 34, 35 apresentam as comparações entre os resultados obtidos para a predição através da RNA e os valores obtidos pela medição.

Nas Figuras 33, 34, 35, pode-se observar quando compara-se as curvas de inteligência artificial tem maior similaridade com a curva dos valores medidos sem necessitar de ajustes de erro de *offset* ou Correlação. Ao analisar os gráficos do Setor 2 observamos a otimização RNA é muito mais eficiente que os outros modelos simulados.




Figura 30 – Resultados da predição para PCI 136 pela RNA em comparação com os valores medidos.

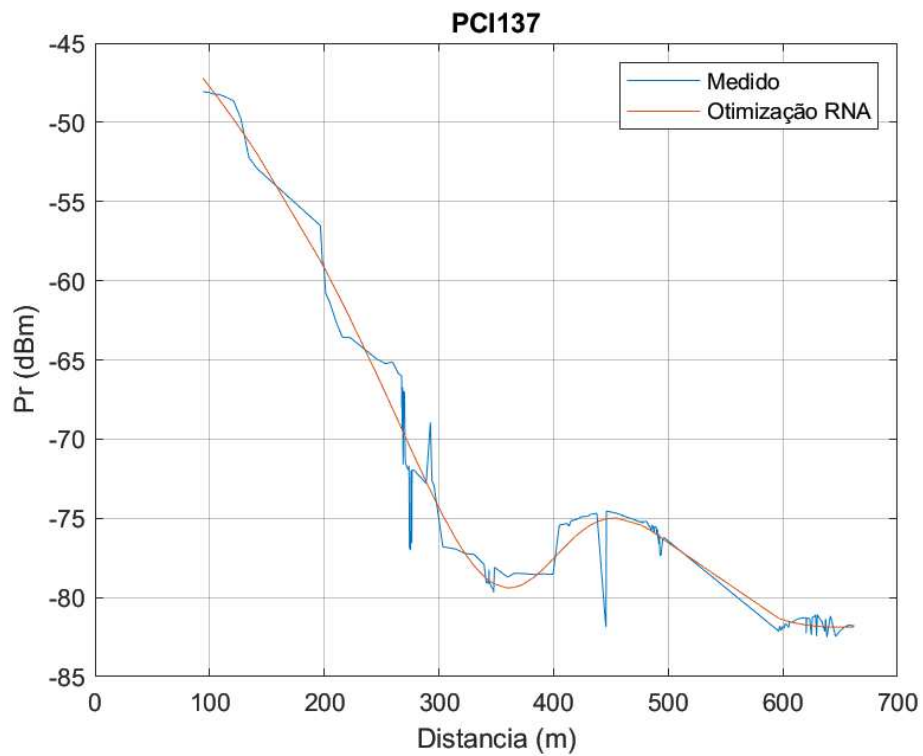


Figura 31 – Resultados da predição para PCI 137 pela RNA em comparação com os valores medidos.

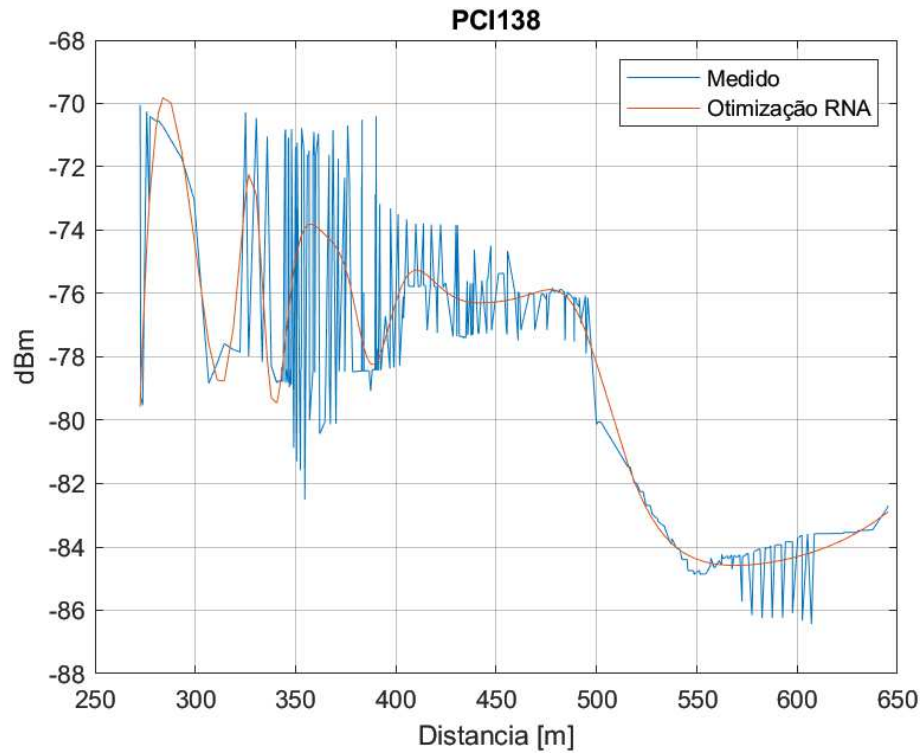


Figura 32 – Resultados da predição para PCI 138 pela RNA em comparação com os valores medidos.




Figura 33 – Resultados da predição para PCI 156 pela RNA em comparação com os valores medidos.

6.4 Análise dos resultados

Ao analisar as Figuras 30 - 35, observa-se uma maior concordância da predição obtida pela RNA com os dados obtidos nas campanhas de medição, sendo o setor identificado




Figura 34 – Resultados da predição para PCI 157 pela RNA em comparação com os valores medidos.

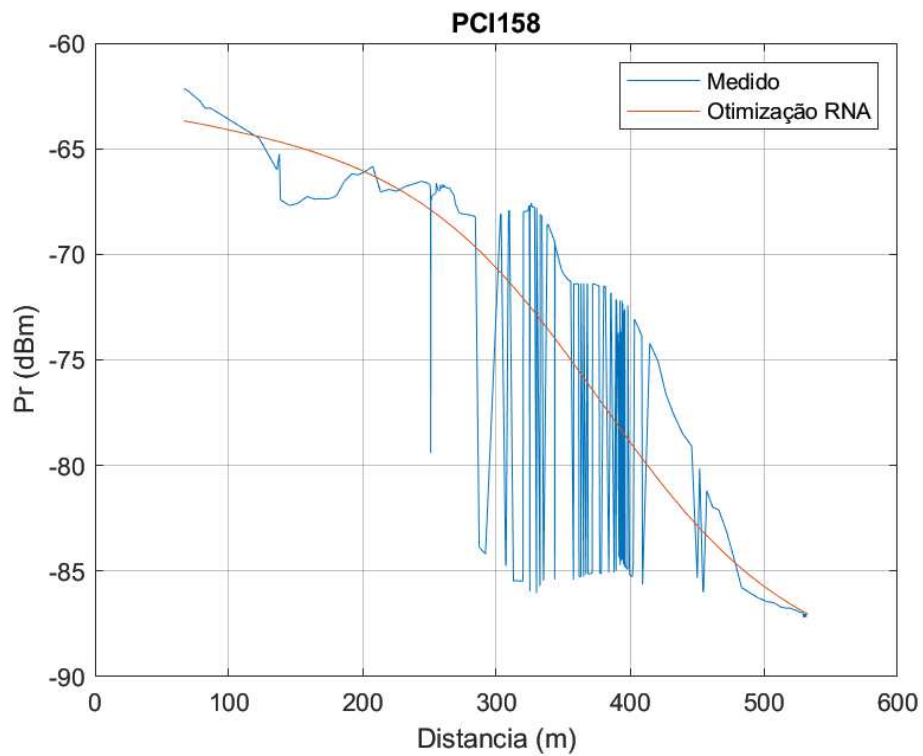


Figura 35 – Resultados da predição para PCI 158 pela RNA em comparação com os valores medidos.

pelo PCI 137 o mais visualmente próximo.

A Tabela 11 apresenta o desempenho da RNA com relação ao erro médio quadrático, a distância média e a correlação para cada setor avaliado. É possível observar que o setor de PCI 157 apresentou a maior proximidade entre a curva obtida pela RNA e a curva de valores medidos. Por apresentar uma maior dispersão de pontos medidos, a curva obtida para a RNA apresentou um valor de *RMSE* maior nos setores de PCI 136 e 158.

Tabela 11 – Resultados da predição através da RNA para todos os setores.

PCI	RMSE	Distância Média	Correlação
PCI136	4,3945	0,0399	0,8378
PCI137	0,8330	0,0179	0,9876
PCI138	1,0897	0,0065	0,8709
PCI156	1,4498	0,1511	0,9731
PCI157	0,3701	-0,0115	0,9586
PCI158	3,6959	-0,0128	0,8066

Fonte: Autoria própria.

Ao analisar os gráficos das Estações Planalto e São Thomaz, observa-se que o erro de *offset* em todas os setores é insignificante. Logo, pode-se dizer que o IA de RNA é muito eficiente e tem uma melhor predição que os modelos tradicionais.

O modelo de RNA de poucas camadas, com 10% das amostras para treinamento e testes que se mostraram eficientes para realizar a predição para todos os setores, sem a necessidade de realizar ajustes.

6.5 Considerações finais

Após a implementação da RNA, bem como do seus treinamentos e testes, a análise de resultados para todos os seis setores apresentou um melhor desempenho com relação aos modelos de propagação. A RNA foi mais acurada e obteve resultados melhores em todas predições. Ao observar e comparar os valores de *RMSE* e correlação de todos os modelos para todas os setores, a RNA provou ser eficaz sem precisar de ajustes e correção de erros. Isso comprova a aplicabilidade da RNA para predições de potência recebida.

Para PCI137 do Setor 1 que apresentou uma péssima Correlação e um RMSE ruim para todos os modelos, quando utilizou a otimização RNA o resultado foi obtido foi ótimo como observa-se na Tabela 12.

Tabela 12 – Comparação de desempenho entre os modelos de propagação após correção de *offset* e RNA para todos os setores.

	RNA		Okumura-Hata		3GPP		ITU-Advanced		ITU-R	
PCI	RMSE Corr		RMSE Corr		RMSE Corr		RMSE Corr		RMSE Corr	
136	4,395	0,838	7,692	0,547	6,964	0,680	7,125	0,652	7,438	0,625
137	0,833	0,988	18,214	-0,384	17,978	-0,264	18,397	-0,300	17,942	-0,182
138	1,090	0,871	5,984	0,292	5,953	0,340	5,2447	0,333	5,244	0,479
156	1,450	0,973	4,636	0,858	4,801	0,901	4,637	0,892	4,238	0,923
157	0,370	0,959	1,967	0,916	3,627	0,911	3,122	0,912	4,704	0,824
158	3,696	0,807	5,566	0,811	4,738	0,816	4,966	0,819	4,209	0,852

Fonte: Autoria própria.

7 Conclusões

A predição da perda de percurso do sinal de potência entre a estação rádio-base e a estação móvel é de relevante importância para o planejamento e otimização das redes celulares. Também é de grande importância o estudo da transmissão em 700 MHz que além do Brasil esta sendo alocado para serviços móveis em vários países da América latina, do Caribe e alguns países da Asia (AMERICAS, 2019)

Nesta dissertação, foi analisado o desempenho de quatro modelos de perda de percurso para redes celulares em relação a medidas de campo obtidas na região da Lagoa da Pampulha em Belo Horizonte. Todos os modelos passaram por ajustes de *offset* e de inclinação, tendo o último apresentada melhoria insignificante com relação ao modelo original. O ajuste de *offset* mostrou-se eficiente na redução do erro quadrático médio.

O trabalho apresentou uma contribuição importante ao verificar a adequação de modelos tradicionais, que são obtidos através de campanhas de medições no exterior, ao ambiente de propagação urbano brasileiro. Além disso, a particularidade brasileira da implantação de sistemas LTE na faixa de 700 MHz torna importante a necessidade de avaliação destes modelos para uso nestas redes. A análise dos modelos de propagação após o ajuste de *offset* indicou o modelo ITU-R 1812-6 como mais adequado ao ambiente de morfologia variada no qual foram obtidas as medições.

Além disso, este trabalho propôs um modelo de predição de perda de percurso baseado em uma rede neural artificial. O trabalho mostrou que, a partir de uma RNA simples de camada única, é possível obter resultados com valores preditos mais próximos aos valores medidos em comparação aos modelos tradicionais. Isso mostra a importância do uso de ferramentas de inteligência artificial em métodos de predição de cobertura.

Para fins de reprodutibilidade e continuidade do trabalho apresentado nesta Dissertação, os dados de medição e as rotinas utilizadas para processamentos destes e para geração dos resultados encontram-se disponíveis em (LIMA; NUNES, 2023).

Este trabalho abre possibilidades para o uso de medições em redes celulares na faixa de 700 MHz não apenas na análise da perda de percurso, mas também em outros aspectos da caracterização do canal rádio-móvel, como o somreamento e o desvanecimento. Outras possibilidades de trabalho futuros incluem a análise de outros fatores da rede celular como a interferência cocanal ou de canal adjacente, que podem ser maiores nesta faixa de frequência. A análise de procedimentos inerentes a redes celulares dependentes dos parâmetros da camada física, tais como *handover*, queda de conexão, *attach* de célula, dentre outros, também são importantes para a operação destas redes. Por fim, a avaliação de novos modelos de perda de percurso, bem como de outras técnicas de inteligência artificial e aprendizado de máquina podem ser explorados em trabalhos futuros.

Referências

- ALEXANDRE, A. L. D. S. F. L. C.; SODRÉ, A. C. Indoor coexistence analysis among 5g new radio, lte-a and nb-iot in the 700 mhz band. *IEEE Access*, 2020.
- AMERICAS, G. *A FAIXA DE 700 MHZ*. 2019. Disponível em: <https://brechazero.com.br/wp-content/uploads/2019/12/BANDA20DEA>Acesso em: 23 de julho de 2023.
- ANATEL. *Pesquisa amostral, coleta de dados*. 2018. Disponível em: <https://www.gov.br/anatel/pt-br/>, Acesso em: 23 de julho de 2023.
- BARROS, V. P. A. *Avaliação do desempenho de algoritmos de retropropagação com redes neurais artificiais para a resolução de problemas não-lineares*. Dissertação (Mestre em ciência da computação) — UTFPR, 2018.
- CARVALHO, N. P. D. *Rede Neural Artificial Aplicada à Predição de Cobertura de Sinal Rádio Móvel em Vegetação*. 2020.
- CASTRO, B. S. L. *Modelo de propagação para redes sem fio fixas na banda de 5,8GHz em cidades típicas da região amazônica*. Dissertação (Mestre em Ciências (M. Sc.) em Engenharia Elétrica) — UFP, 2010.
- CASTRO, M. C. F. 2017. Disponível em: <http://fccdecastro.com.br/download.html>, Acesso em: 07 de abril de 2023.
- ESCUADERO, A. *Análise e Modelagem de Perda de Percurso através de Parede de Alvenaria na Frequência de 10 GHz*. 2004.
- HAYKIN, S. *Neural networks and learning machines*. 3^a. ed. New Jersey: Pearson, 1999.
- HOFFMAN, R. *Análise de regressão: uma introdução à econometria*. Hucitec. DOI: 10.11606/9788592105709: AUTOR, 2006.
- HSU, J. Digital reasoning has trained a record-breaking artificial intelligence neural network that is 14 times larger than google's previous record. <https://spectrum.ieee.org/global-configuration-management>, 2015.
- ITU-R1546-6. *Method for point-to-area predictions for terrestrial services in the frequency range 30 MHz to 4 000 MHz*. Recommendation itu-r p.2040-2. Geneva: Eletronic Publication, 2019.
- ITU-R1812-6. *A path-specific propagation prediction method for point-to-area terrestrial services in the frequency range 30 MHz to 6 000 MHz*. Recommendation itu-r p.1812-6. Geneva: Eletronic Publication, 2011.
- ITU-R2040-2. *Effects of building materials and structures on radiowave propagation above about 100 MHz*. Recommendation itu-r p.2040-2. Geneva: Eletronic Publication, 2021.

- JUNIOR E. M. J.; VEIGA, A. C. P.; N., S. T. Predição de perda de percurso utilizando redes neurais artificiais em um canal de tv uhf em uberlândia/brasil. *Conjecturas*, 2022.
- LEITE, R. R. S. *Estudo da Perda de Percurso e do Perfil de Atraso de Potências na Frequência de 3500 MHz em Regiões Urbanas Densamente Vegetadas*. 2021.
- LIMA, G. d.; NUNES, M. L. *Perda de percuso em sistemas LTE em 700 MHz: Dados de medição e rotinas de processamento*. 2023. Disponível em: https://github.com/Grazielledelima/PathLossLTE__700MHz.
- M2135, I.-R. *Guidelines for evaluation of radio interface technologies for IMT-Advanced*. Recommendation itu-r m.2135. Geneva: Eletronic Publication, 2008.
- MAGALHÃES, D. A. M. *Análise de Cobertura e Modelalagem do Sinal Rádio Móvel em Ambiente com Vegetação na Faixa 700 – 4000 MHz*. 2020.
- MCCULLOCH W. S., P. W. A logical calculus of the ideas immanent in nervous activity. bulletin of mathematical biophysics. *The university of chicago*, 1943.
- MELGAREJO D. C. ; FILHO, L. Q. R. d. C. M. A. A. M. d. F. F. L.; RODRIGUEZ, D. Z. Dynamic algorithm for interference mitigation between cells in networks operating in the 250 mhz band. *IEEE Access*, 2022.
- MOLISCH, A. F. *Wireless Communications*. 2^a. ed. University of southern California: IEEE, 2011.
- NUNES, M. L. *Predição de cobertura radioelétrica em ambiente urbano complexo utilizando base de dados descritiva de alta resolução*. Dissertação (Mestre em Engenharia Elétrica) — UFMG, 2017.
- NUNES, T. V. L. *Método de previsão de defeitos em estradas vicinais de terra com base no uso das redes neurais artificiais: trecho de Aquiraz-CE*. Dissertação (Mestre em Ciências (M. Sc.) em Engenharia de Transportes) — UFC, 2003.
- PARSONS, J. D. *The mobile radio propagation channel*. 2^a. ed. Chichester: JOHN WILEY SONS LTD, 2002.
- RAPAPPORT, T. S. *Comunicações sem fio - principios e praticas*. 2^a. ed. New Jersey: Prentice hall PTR, 1996.
- ROCHA L.; FERREIRA, S. . V. K. C. T. A. J.; BATALHA, I. Ziwi: indoor and outdoor planning network—framework to collection, modeling and network structure based on computational optimization and measurements. *Soft Computing*, 2022.
- ROLIN, E. C. *Análise da Qualidade e do Desempenho da Cobertura Celular Long Term Evolution em Curitiba, Paraná*. 2014.
- RUMERLHART D. E.; HINTON G. E.; WILLIAMS, R. J. “learning representations by back-propagating errors,. *Nature*, 1986.
- SAUTER, M. *From GSM to LTE-Advanced Pro and 5G An Introduction to Mobile Networks and Mobile Broadband*. [S.l.]: Wiley, 2021.
- SHERPHERD, G. M.; KOCH, C. *Introduction to synaptic circuits.in The Synaptic Organization of the Brain*. New York: Oxford University Press, 1990.

SHWARZ, R. &. *TSMW universal radio network analyzer - Data sheet*. [S.l.], Rhode & Shwarz, 2017. Rev. 5.

SILVA, I. N.; H., S. D.; FLAUZINO, R. A. *Artificial Neural Networks for Engineering and Applied Sciences - Practical Course*. [S.l.]: ARTLIBER, 2010.

SÁ, M. J. d. P. *Caracterização de canal rádio móvel em túnel urbano na faixa de 700 MHZ*. 2020.

TAYLOR, J. R. *Introduction To Error Analysis: The Study of Uncertainties in Physical Measurements*. University Science Books: A series of books in physics, 1997.

WILLMOTT, C. J. *On the validation of models*. 2^a. ed. Geodr: Phys., 1981.