



UNIVERSIDADE FEDERAL FLUMINENSE
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
TELECOMUNICAÇÕES - PPGEET

NIVEA PORTUGAL DE CARVALHO

**REDE NEURAL ARTIFICIAL APLICADA À
PREDIÇÃO DE
COBERTURA DE SINAL RÁDIO
MÓVEL EM VEGETAÇÃO**

NITERÓI

2020

UNIVERSIDADE FEDERAL FLUMINENSE
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
TELECOMUNICAÇÕES

NIVEA PORTUGAL DE CARVALHO

**REDE NEURAL ARTIFICIAL APLICADA À PREDIÇÃO DE
COBERTURA DE SINAL RÁDIO MÓVEL EM
VEGETAÇÃO**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense como requisito parcial para a Obtenção do Grau de Mestre em Engenharia Elétrica e de Telecomunicações.

Área de concentração: Sinais e Sistemas de Comunicações Móveis.

Orientador:

Prof Dr. Edson Luiz Cataldo Ferreira

Coorientadora:

Prof^a Dra. Leni Joaquim de Matos

NITERÓI

2020

Ficha catalográfica automática - SDC/BEE
Gerada com informações fornecidas pelo autor

C331r Carvalho, Nivea Portugal de
Rede Neural Artificial Aplicada à Predição de Cobertura de Sinal Rádio Móvel em Vegetação / Nivea Portugal de Carvalho ; Edson Luiz Cataldo Ferreira, orientador ; Leni Joaquim de Matos, coorientadora. Niterói, 2020.
80 f. : il.

Dissertação (mestrado)-Universidade Federal Fluminense, Niterói, 2020.

DOI: <http://dx.doi.org/10.22409/PPGEET.2020.m.14329401711>

1. Redes Neurais Artificiais. 2. Cobertura de Sinal Rádio Móvel. 3. Predição de Cobertura de Sinal Rádio Móvel em Vegetação. 4. Produção intelectual. I. Ferreira, Edson Luiz Cataldo, orientador. II. Matos, Leni Joaquim de, coorientadora. III. Universidade Federal Fluminense. Escola de Engenharia. IV. Título.

CDD -

NIVEA PORTUGAL DE CARVALHO

REDE NEURAL ARTIFICIAL APLICADA À PREDIÇÃO DE COBERTURA DE SINAL
RÁDIO MÓVEL EM VEGETAÇÃO

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense como requisito parcial para a Obtenção do Grau de Mestre em Engenharia Elétrica e de Telecomunicações.

Área de concentração: Sinais e Sistemas de Comunicações Móveis.

BANCA EXAMINADORA

Prof Dr. Edson Luiz Cataldo Ferreira - Orientador
Universidade Federal Fluminense - UFF

Profª Dra. Leni Joaquim de Matos – Coorientadora
Universidade Federal Fluminense – UFF

Prof. Dr. Pedro Vladimir Gonçalves Castellanos
Universidade Federal Fluminense – UFF

Prof. Dr. Carlos Vinício Rodríguez Ron
Instituto Nacional de Metrologia – INMETRO

Niterói

Dezembro de 2020

Dedico este trabalho à minha família.

Agradecimentos

Agradeço a Deus, meu maior amor, pelo fôlego de vida e pela força e sabedoria que me concedeu, para todo o desenvolvimento deste trabalho.

Agradeço a minha família pelo apoio emocional e financeiro que foram dados com muito carinho e esforço. Espero fazer jus a tudo o que me foi oferecido.

Agradeço aos meus orientadores, Prof Dr. Edson Luiz Cataldo Ferreira e Prof^a Dra. Leni Joaquim de Matos, por acreditarem em mim, por todos os ensinamentos ao longo dos anos, todas as correções que me ajudaram e por me impulsionarem durante a dissertação.

Aproveito para agradecer aos professores do curso de Mestrado, por todo o conhecimento dispensado tão necessário à implementação deste trabalho.

Aos meus amigos pela paciência em ouvir e pela prontidão em oferecer ânimo.

Ao meu gestor e colegas da área profissional pela ajuda e estímulo na conclusão do mestrado.

Resumo

Uma rede neural artificial (RNA) é empregada buscando melhorar a predição de sinal rádio móvel em um ambiente com vegetação. A quantidade de dados coletados nas medições é uma dificuldade apresentada em alguns estudos pois, para que seja analisado cada parâmetro, é necessário um número considerável de elementos. Então, uma campanha de medições foi realizada em Niterói, Rio de Janeiro, gerando dados para treinamento e teste da RNA com variação nas frequências de um sinal CW em 705 MHz, 1790 MHz, 2,4 GHz, 3,5 GHz e 4 GHz e, também, nas alturas da antena transmissora em 1,7 m e 4,2 m, em duas rotas. Com isso, garantiu-se uma boa base de dados para treinamento e teste da RNA e uma análise mais profunda do comportamento do sinal de saída, isto é, da potência obtida do sinal, de acordo com os conjuntos de entrada. Diferentes configurações de RNAs foram testadas e, para fins comparativos, foi identificado o modelo de predição de perda que melhor se ajustou ao ambiente e aos fatores das medições. No estudo desse trabalho, o modelo de predição usado foi o log-distância (*log-distance*). Os valores de erro médio quadrático (RMSE-*Root Mean Square Error*) do modelo e das RNAs, com relação às medições médias, foram calculados para todos os percursos e feitas as comparações, mostrando que a RNA escolhida apresentou valores RMSE inferiores em comparação com os obtidos pelo modelo. Assim, conclui-se a eficácia do emprego das RNAs para melhoria da predição de cobertura em vegetação.

Palavras – chave: Rede neural artificial, modelos de predição de cobertura de sinal, propagação através de vegetação.

Abstract

An artificial neural network (RNA) is applied in order to improve the prediction of mobile radio signals in an environment with vegetation. The amount of data collected in the measurements is a difficulty presented in some studies because, for each parameter to be analyzed, a considerable number of elements is necessary. Then, a measurement campaign was carried out in Niterói, Rio de Janeiro, generating data for training and testing ANN with variation in the frequencies of a CW signal at 705 MHz, 1790 MHz, 2.4 GHz, 3.5 GHz and 4 GHz and, also, at the height of the transmitting antenna at 1.7 m and 4.2 m, in two routes. This ensured a good database for ANN training and testing and a deeper analysis of the behavior of the output signal, that is, of the power obtained from the signal, according to the input sets. Different configurations of RNAs were tested and, for comparative purposes, the loss prediction model that best suited the environment and the measurement factors was identified. In the study of this work, the prediction model used was the log-distance. The values of mean square error (RMSE-Root Mean Square Error) of the model and of the ANNs, in relation to the average measurements, were calculated for all paths and comparisons were made, showing that the ANN chosen presented lower RMSE values compared to obtained by the model. Thus, we conclude the effectiveness of using RNAs to improve the prediction of vegetation cover.

Keywords: Artificial neural network, signal coverage prediction models, propagation through vegetation.

Lista de Figuras

Figura 1 - Comportamento do sinal e seus multipercursos [4].....	5
Figura 2 - Função densidade de probabilidade log-normal com média e desvio padrão do logaritmo da variável aleatória iguais à 0,5 [1].	9
Figura 3 - Função densidade de probabilidade da distribuição Rayleigh [1].	10
Figura 4 - Densidade de probabilidade para a distribuição de Rice [1].	12
Figura 5 - Componentes do sinal: Raio incidente, raio refratado e raio refletido.	13
Figura 6 - Comportamento do sinal ao passar por uma fenda.	14
Figura 7 - Zonas de Fresnel [10].	14
Figura 8 - Modelo de dois raios [11].	17
Figura 9 - Modelo Gume de faca (a) com obstrução da visada direta (b) sem obstrução [5]. .	18
Figura 10 - Esquema da representação matemática de um neurônio.	21
Figura 11 - Função Degrau.	22
Figura 12 - Função Linear.	23
Figura 13 - Função Sigmoidal Logarítmica.	23
Figura 14 - Função Tangente Hiperbólica.	24
Figura 15 - Redes feed-forward com camada única [13].	25
Figura 16 - Rede feed-forward com múltiplas camadas.	25
Figura 17 - Rede Recorrente [13].	26
Figura 18 - Ambiente de medição e rotas medidas [18].	29
Figura 19 - <i>Setup</i> de Transmissão.	31
Figura 20 - Antena transmissora na altura de 1,7 m.	31
Figura 21 - Antena transmissora na altura de 4,2 m.	32
Figura 22 - Gerador de sinais Anritsu MG3700A.	33
Figura 23 - Amplificador de Potência: Mini-circuits ZHL-16W-43+.	34
Figura 24 - <i>Setup</i> de Recepção.	35
Figura 25 - Analisador de Espectro Anritsu MS2692A.	37
Figura 26 - Comparação entre os modelos de predição de perda de sinal e o ajuste dos dados medidos para o conjunto: altura Tx de 1,7 m, frequência de 2.4 GHz e rota 1.	40
Figura 27 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 4 GHz e rota 1 treinada com divisão 60%, 20%, 20% dos dados da rota 1 e 12 neurônios na camada escondida.	42

Figura 28 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 4 GHz e rota 2 treinada com divisão 60%, 20%, 20% dos dados da rota 1 e 12 neurônios na camada escondida.	42
Figura 29 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 1,7 m, frequência de 4 GHz e rota 1 treinada com divisão 80%, 10%, 10% dos dados da rota 1 e 20 neurônios na camada escondida.	43
Figura 30 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 1,7 m, frequência de 4 GHz e rota 2 treinada com divisão 80%, 10%, 10% dos dados da rota 1 e 20 neurônios na camada escondida.	44
Figura 31 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 1790 MHz e rota 1 treinada com divisão 60%, 20%, 20% dos dados da rota 2 e 12 neurônios na camada escondida.....	45
Figura 32 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 1790 MHz e rota 2 treinada com divisão 60%, 20%, 20% dos dados da rota 2 e 12 neurônios na camada escondida.....	45
Figura 33 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 705 MHz e rota 1 treinada com divisão 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida.....	47
Figura 34 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 705 MHz e rota 2 treinada com divisão 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida.....	47
Figura 35 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 1,7 m, frequência de 2,4 GHz e rota 1 treinada com divisão 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida.....	48
Figura 36 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 1,7 m, frequência de 2,4 GHz e rota 2 treinada com divisão 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida.....	49

Lista de Tabelas

Tabela 1 - Expoente de perda de percurso [3].	6
Tabela 2 – Perdas dos cabos usados na transmissão de acordo com as frequências utilizadas.	33
Tabela 3 – Ganho para cada frequência do amplificador de potência.	34
Tabela 4 – Perdas e ganhos da antena transmissora.	35
Tabela 5 - Ganho real da antena de Recepção para A1 de 1.7 metros.	36
Tabela 6 - Ganho real da antena de Recepção para A2 de 4.2 metros.	36
Tabela 7 - Perdas no Cabo para as portadoras empregadas.	37
Tabela 8 – Organização dos dados medidos.	38
Tabela 9 – Valores RMSE do modelo Log-distância.	41
Tabela 10 - Valores RMSE da rede treinada com divisão 60%, 20%, 20% dos dados da rota 1 e 12 neurônios na camada escondida.	43
Tabela 11 - Valores RMSE da rede treinada com divisão 80%, 10%, 10% dos dados da rota 1 e 20 neurônios na camada escondida.	44
Tabela 12 - Valores RMSE da rede treinada com divisão 60%, 20%, 20% dos dados da rota 2 e 12 neurônios na camada escondida.	46
Tabela 13 - Percentual de melhoria na predição de sinal da rede treinada com divisão 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida em comparação com o modelo log-distância.	48
Tabela 14 - Percentual de melhoria na predição de sinal da rede treinada com 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida em comparação com o modelo log-distância.	49

Lista de Abreviaturas e Siglas

Tx	Transmissor
Rx	Receptor
RNA	Rede Neural Artificial
MLP	<i>Multi Layer Perceptron</i>
RBF	<i>Radial Basis Function</i>
RNBE	Rede Neural Baseada no Erro
RNBT	Rede Neural Baseada no Terreno
f.d.p	Função Densidade de Probabilidade
LM	<i>Levenberg-Marquardt</i>
CW	<i>Continuous Wave</i>
PA	<i>Power Amplifier</i>
RMSE	Erro Médio Quadrático

Sumário

Capítulo 1 - Introdução	1
1.1 Objetivos	2
1.2 Organização da Dissertação	2
1.3 Revisão Bibliográfica	3
Capítulo 2 - O Canal Rádio Móvel	4
2.1. Caracterização do Canal Rádio Móvel	4
2.1.1. Desvanecimento em Grande Escala	4
2.1.1. Desvanecimento em Pequena Escala	5
2.1.2. Path Loss	5
2.2. Distribuições Usuais Aplicadas ao Desvanecimento	6
2.2.1. Log-Normal	7
2.2.2. Rayleigh	9
2.2.3. Rice	11
2.3. Mecanismos de Propagação	12
2.3.1. Reflexão	12
2.3.2. Difração	13
2.4. Zonas de Fresnel	14
2.5. Modelos de Predição de Perda de Sinal	15
2.5.1. Espaço Livre	16
2.5.2. Modelo Log-Distância	16
2.5.3. Modelo de Dois Raios	17
2.5.4. Gume de Faca	17
2.6. Modelos Aplicados em Canal com Vegetação	19
2.6.1. Modelo Itu-R	19
2.6.2. Modelo Chen e Kuo	19
2.6.3. Modelo Weissberg	20
Capítulo 3 - Redes Neurais Artificiais	21
3.1. Modelo de um Neurônio	21

3.1.1. Funções de Ativação	22
3.2. Arquitetura de Redes Neurais Artificiais	24
3.2.1. Redes Alimentadas Adiante (Feed-Forward) com Camada Única	24
3.2.2. Rede Feed-Forward com Múltiplas Camadas	25
3.2.3. Redes Recorrentes	26
3.3. Treinamento de Uma Rede Neural	26
3.3.1. Supervisionado	27
3.3.2. Não-Supervisionado	28
Capítulo 4 - Aquisição e Processamento dos Dados	29
4.1. Setup de Medições	30
4.1.1. Setup de Transmissão	30
4.1.2. Setup de Recepção	35
4.2. Ajuste dos Dados	37
Capítulo 5 - Aplicação da Rede Neural Artificial	39
5.1. Comparação dos Modelos de Predição	40
5.2. Processo de Criação da RNA	41
Capítulo 6 - Conclusões e Trabalhos Futuros	51
Bibliografia	52
Anexo A – Ajustes dos Dados	55
Anexo B – Gráficos Comparativos dos Modelos de Predição	58
Anexo C – Código da Rede Neural Artificial	65

Capítulo 1 - Introdução

Com o aumento da conscientização das pessoas de que é necessário ter uma vida mais saudável, é crescente a busca por ambientes onde elas se sintam mais próximas da natureza. Ao mesmo tempo, a tecnologia vem avançando de maneira a facilitar a maneira como são feitas as tarefas do dia a dia, tornando muitos adeptos às aplicações que simplificam seus processos para facilitar o uso em dispositivos portáteis. Com um aparelho celular é possível fazer uma jornada inteira de trabalho enquanto se ouve música e trocam-se mensagens. Para que todas as ações sejam feitas sem perda de dados valiosos ou redução do desempenho, é imprescindível que o sinal rádio seja entregue com nível adequado, sofrendo pouca atenuação durante a propagação no ambiente. Para isso, são feitos muitos estudos teóricos, a partir de parâmetros concernentes ao ambiente obtidos a partir de dados experimentais.

Parques são ambientes de lazer e descanso onde, em geral, a população busca entretenimento nos dispositivos celulares. Os modelos mais usuais de predição de sinal não costumam ter bom ajuste nestes ambientes, uma vez que a vegetação entre transmissor (TX) e receptor (RX) tem muita influência no sinal que por ela se propaga, principalmente causando absorção e espalhamento, acarretando não só em atenuação como dispersão do mesmo.

Na literatura, são encontrados, muitos estudos e modelos sobre o comportamento do sinal em áreas urbanas considerando-se efeitos de prédios, veículos e sinalizações [19-21] e de ambientes com densa vegetação como florestas [22-23], mas sobre ambientes urbanos ou residenciais arborizados e parques com árvores de menor porte há poucos modelos [24-26], geralmente muito específicos, havendo necessidade de um maior número de testes em campo para se chegar a modelos mais realistas.

1.1 Objetivos

Com o intuito de melhorar a predição de cobertura de sinal em um parque com vegetação entre o transmissor e o receptor, uma rede neural artificial (RNA), com o estímulo apropriado (os dados de entrada e saída), é aplicada para o cálculo da cobertura do nível de sinal rádio móvel, mostrando bons resultados para a predição. Assim, os objetivos deste trabalho foram:

- Aquisição dos dados em uma campanha de medições para serem aplicadas na criação da RNA;
- Verificação e comparação dos resultados obtidos com modelos de predição que já são empregados para o ambiente de estudo;
- Criação, treinamento e teste de uma rede neural artificial para previsão da atenuação do sinal através do canal rádio móvel considerado;
- Comparação dos resultados obtidos com a RNA criada e outros modelos de predição.

1.1. Organização da Dissertação

Este trabalho foi desenvolvido com embasamentos teóricos colocados em prática e divididos em capítulos. No capítulo 2, é caracterizado o canal rádio móvel, com a sua teoria e modelos desenvolvidos por pesquisadores ao longo dos anos. O capítulo 3 apresenta a base teórica de redes neurais artificiais bem como seus principais parâmetros e funcionamentos. No capítulo 4, é feita a descrição do aparato experimental e, também, da obtenção dos dados experimentais através da campanha de medições. No capítulo 5, é possível ver todo o processo de criação da rede neural artificial, escolha e divisão dos dados, seu treinamento, teste e comparação dos resultados. Finalmente, o capítulo 6 apresenta as conclusões.

1.2. Revisão Bibliográfica

As rede neurais artificiais vêm sendo utilizadas e estudadas com bons resultados, como mecanismo de criação de modelos de predição de cobertura de sinal. São encontrados, na literatura, muitos estudos onde sua aplicação foi bem sucedida, tanto para melhorar algum modelo existente como para gerar o próprio modelo. A seguir, são citadas algumas dessas aplicações.

- M.B Moura (2017) através da criação de uma rede perceptron de multicamadas (MLP) resultados até 86% melhores do que os utilizados pelos modelos de predição já existentes para ambiente *outdoor – indoor*,– outdoor, *Partition-Based Outdoor-to-indoor*, modelo *indoor Multi-Wall Cost 231* [12].
- I Vilovic (2007) provou, através de resultados experimentais, que uma rede RBF (*Radial Basis Function*) apresenta melhores resultados, se comparada com uma MLP e com outros modelos empíricos, na predição de sinal em ambiente indoor [16].
- G.P Ferreira (2015) obteve um bom resultado na criação de uma rede neural e sua aplicação na melhora do melhor modelo de predição para o ambiente urbano de baixa densidade [11].
- B Cavalcanti (2017) criou e comparou dois modelos de redes neurais, uma com entrada baseada no erro (RNBE) e outra com entrada baseada no terreno (RNBT), encontrando o melhor resultado na RNBE, inclusive quando comparados com outros modelos próprios para o ambiente em questão [17].
- S. P. Sotiroudis (2014) gerou resultados via redes neurais artificiais, dando a ela informações detalhadas sobre o perfil do ambiente construído. Informações essas obtidas por meio de uma grade virtual cobrindo a área sob investigação e criando com isso um esquema aproximado do terreno [28].
- U. Masood (2019) propôs um modelo de propagação 3D baseado em aprendizado de máquina. Identificado um novo conjunto de parâmetros de predição inteligentes, que podem caracterizar a complexa estrutura geométrica do ambiente de propagação, obtendo um aumento de 25% na precisão da previsão em comparação com modelos empíricos, bem como diminuição de 12x no tempo de previsão [29].

Capítulo 2 - O Canal Rádio Móvel

2.1. Caracterização do Canal Rádio Móvel

O canal de comunicação rádio móvel é o meio no qual o sinal de comunicação se propaga desde o transmissor até o receptor. Nesse meio, por vezes, o sinal é distorcido e sofre alterações. Essas mudanças se dão por diversos motivos que vão desde a atenuação com a distância entre o transmissor e o receptor, até variações devido a obstáculos naturais e feitos pelo homem como: montanhas, vegetação, prédios, torres, postes, entre outros.

Este capítulo tem, por objetivo, apresentar as principais características do meio de transmissão bem como do sinal que o atravessa, inclusive como ele é reconhecido no receptor. Para isso, será estudado como ele se comporta diante de alguns fatores que causam desvanecimento e, por fim, serão apresentados alguns modelos que predizem qual será o nível de sinal recebido para certo nível de potência transmitida.

2.1.1. Desvanecimento em Grande Escala

O desvanecimento em grande escala ou variabilidade lenta, é uma flutuação no nível do sinal causado pelo movimento do receptor em relação ao transmissor, considerando grandes distâncias em relação ao comprimento de onda do sinal. Também conhecido como sombreamento, o desvanecimento em grande escala tem em vista que o receptor está em uma região de “sombra”, ou seja, que há um obstáculo entre ele e o transmissor como os citados no item anterior, tendo a visada direta obstruída.

O sombreamento segue uma distribuição Normal com função densidade de probabilidade (f.d.p) de acordo com a equação 1:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[-\frac{1}{2} \left(\frac{x-\mu}{\sigma} \right)^2 \right] , x \in (-\infty, \infty) \quad (1)$$

onde μ é o valor médio da distribuição e σ seu desvio padrão.

2.1.1. Desvanecimento em Pequena Escala

O sinal recebido em uma comunicação rádio é uma composição de sinais que se espalharam e refletiram em superfícies até chegar no receptor. Essas ondas são chamadas de multipercursos. O desvanecimento em pequena escala ou variabilidade rápida, como também é conhecido, é a variação brusca do sinal causada pela soma vetorial dos multipercursos quando há um deslocamento pequeno do móvel em relação ao transmissor, cerca de poucos comprimentos de onda. Na figura 1, é possível ver o raio direto do sinal e seus multipercursos chegando ao receptor.

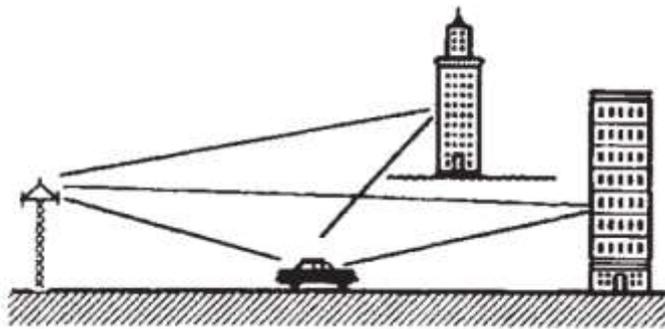


Figura 1 - Comportamento do sinal e seus multipercursos [4].

As distribuições estatísticas mais comuns que representam esse desvanecimento são Rayleigh, Rice e Nakagami-m, que serão vistas mais à frente.

2.1.2. Path Loss

A perda de percurso também é uma característica do comportamento do sinal rádio móvel ao longo do seu percurso entre transmissor e receptor, mais especificamente, de quanto ele é atenuado. A potência recebida do sinal é proporcional à distância entre o transmissor e o receptor, acrescentado de um gradiente [4]. Essa relação de potência com a distância, em dB, é dada pela equação 2:

$$10\log_{10} P_r = 10\log_{10} P_0 - 10\alpha 10\log_{10} d \quad (2)$$

onde α é o gradiente ou expoente de perda de percurso, como também é conhecido. Ele varia de acordo com o ambiente e quantidade de obstáculos, classificando o nível de obstrução do

senal. Para ambientes externos, que é o interesse deste trabalho, o expoente de perda de percurso varia de acordo com a tabela 1, que pode ser vista a seguir.

Tabela 1 - Expoente de perda de percurso [3].

Ambiente	Expoente de Perda de Percurso
Espaço Livre	2
Rádio-celular em área urbana	2.7 a 3.5
Rádio-celular urbano com sombreamento	3 a 5
Na linha de visão do prédio	1.6 a 1.8
Obstruído no prédio	4 a 6
Obstruído em fábricas	2 a 3

2.2. Distribuições Usuais Aplicadas ao Desvanecimento

Diversos estudos têm sido feito para prever estatisticamente o comportamento de alguns elementos que compõem um cenário de propagação do sinal RF. Isso se dá por esses elementos apresentarem variações que não são determinísticas, mas aleatórias, onde não se pode prever a exatidão do valor, mas esperar que ele esteja entre certos valores [1]. Os limites dentro dos quais os valores aleatórios se encontram (x_1 e x_2) são encontrados pela equação 3, onde $p(x)$ é a função densidade de probabilidade (f.d.p.), que representa o comportamento estatístico da envoltória do sinal.

$$P(x_1, x_2) = \int_{x_1}^{x_2} p(x) dx \quad (3)$$

A seguir, serão apresentadas as distribuições estatísticas usadas para prever o comportamento do sinal que atravessa um meio.

2.2.1. Log-Normal

Devido às grandes distâncias entre transmissor e receptor e a quantidade de obstáculos e multipercursos que formam o meio de transmissão, considerado em região de sombra, o sinal chega no receptor espalhado. Assim como visto em 2.1.1, o sombreamento segue uma f.d.p. Normal. A amplitude desse sinal é modelada, então, segundo uma distribuição log-normal sendo representada em dB, que é uma função logarítmica. As equações seguintes mostram o cálculo feito para representação dessa distribuição.

Considerando um número de n obstruções com espessura e atenuação Δr e α cada, respectivamente, tem-se na Equação 4 o valor da amplitude do sinal atravessado por elas, E_n .

$$E_n = E_0 \exp(-\sum_{i=1}^n \alpha_i \Delta r_i) \quad (4)$$

Substituindo por r_n , o somatório da atenuação multiplicado pela espessura de todos os obstáculos como na equação 5, tem-se o sinal visto na equação 6.

$$r_n \equiv -\sum_{i=1}^n \alpha_i \Delta r_i \quad (5)$$

$$E_n = E_0 \exp(r_n) \quad (6)$$

Sendo n um número muito grande de obstruções ($n \rightarrow \infty$), então, pelo Teorema do Limite Central, r tem uma distribuição normal, $p(r_n)$, calculada pela equação 7.

$$p(r_n) = \frac{1}{\sqrt{2\pi\sigma_{r_n}}} \exp\left[-\frac{1}{2} \left(\frac{r_n - m_{r_n}}{\sigma_{r_n}}\right)^2\right] \quad (7)$$

onde m_{r_n} e σ_{r_n} são média e desvio padrão, respectivamente, da distribuição. Para representar tudo logaritmicamente, supõem-se $z = \exp(r_n)$ e analogamente, $z_m = \exp(m_{r_n})$ e $z_s = \exp(\sigma_{r_n})$, formando as equações 8, 9 e 10.

$$R = \log \log z = r_n \log \log e \quad (8)$$

$$m_R = \log \log Z_m = m_{r_n} \log \log e \quad (9)$$

$$\sigma_R = \log \log Z_S = \sigma_{r_n} \log \log e \quad (10)$$

Igualando as duas curvas de densidade $p(R)$ e $p(r)$ para as probabilidades na mesma escala, como mostrado na equação 11 e fazendo as devidas substituições obtém-se a equação 12:

$$p(R)|dR| = p(r_n)|dr_n| \quad (11)$$

$$|dR| = |dr_n| \log \log e \quad (12)$$

Assim tem-se,

$$p(R) = \frac{1}{\log \log e} p(r_n) = \frac{1}{\sqrt{2\pi} \sigma_{r_n} \log \log e} \exp \left[-\frac{1}{2} \left(\frac{r_n - m_{r_n}}{\sigma_{r_n}} \right)^2 \right] \quad (13)$$

substituindo as variáveis pelas propostas nas equações 7, 9 e 10, fornece:

$$p(R) = \frac{1}{\sqrt{2\pi} \sigma_R} \exp \left[-\frac{1}{2} \left(\frac{R - m_R}{\sigma_R} \right)^2 \right] \quad (14)$$

Considerando $R = \log(r_n)$, o resultado da f.d.p. da distribuição logarítmica $p(r_n)$ é mostrado na equação 15 e ilustrado na figura 2.

$$p(r_n) = \frac{1}{\sqrt{2\pi} r_n \sigma_{r_n}} \exp \left[-\frac{1}{2} \left(\frac{\ln r_n - m_{r_n}}{\sigma_{r_n}} \right)^2 \right] \quad (15)$$

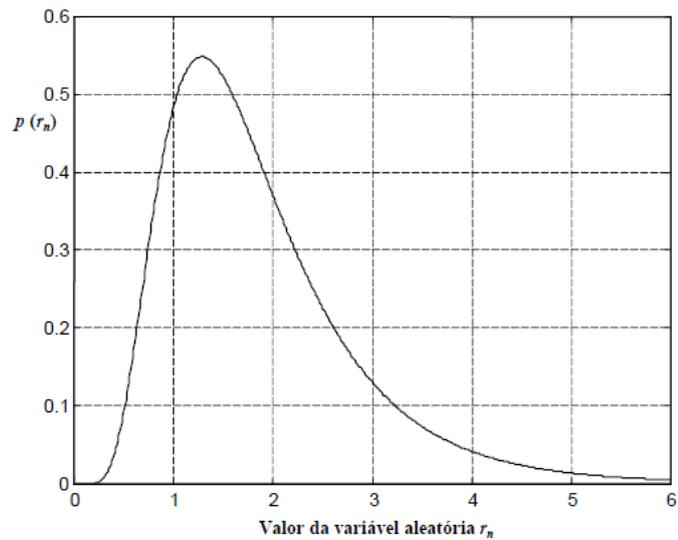


Figura 2 - Função densidade de probabilidade log-normal com média e desvio padrão do logaritmo da variável aleatória iguais à 0,5 [1].

2.2.2. Rayleigh

A distribuição Rayleigh considera que o sinal que é percebido no receptor é o somatório de uma grande quantidade de componentes de ondas espalhadas possuindo potências de baixa amplitude [2]. Isso se dá porque, nessa distribuição, não há a componente de visada direta do sinal, ou seja, não há uma componente do sinal com potência que seja muito maior que as outras. As equações 16 a 19 mostram os sinais transmitido S_t e recebido S_r neste caso, onde ω_0 é a frequência e α e θ são a frequência e fase do sinal, respectivamente.

$$S_t = \alpha \exp(j\omega_0 t) \quad (16)$$

$$S_r = \sum_{i=1}^n \alpha_i \exp \exp [j(\omega_0 t + \theta_i)] = \sum_{i=1}^n \alpha_i \exp \exp (j\theta_i) \exp[j(\omega_0 t)] \quad (17)$$

$$S_r = [r \exp \exp (j\theta)] \exp[j(\omega_0 t)] \quad (18)$$

$$S_r = r \exp[j(\omega_0 t + \theta)] \quad (19)$$

onde r é a envoltória do sinal.

$$r \exp(j\theta) = \sum_{i=1}^n \alpha_i \exp(j\theta_i) = \sum_{i=1}^n \alpha_i \cos \theta_i + j \sum_{i=1}^n \alpha_i \sin \theta_i \triangleq x + jy \quad (20)$$

$$x \triangleq \sum_{i=1}^n \alpha_i \cos \theta_i \text{ e } y \triangleq \sum_{i=1}^n \alpha_i \sin \theta_i \quad (21)$$

onde x e y são:

$$x = r \cos \theta \quad (22)$$

$$y = r \sin \theta \quad (23)$$

Como x e y são componentes em quadratura, pelo Teorema do Limite Central sabe-se que, quando um número de amostras é suficientemente grande, a distribuição da média é aproximadamente Gaussiana. Assim tem-se que o sinal obedece uma distribuição de Rayleigh, pois x e y são uma soma de sinais em quadratura gaussiana [3]. Na equação 24 e na figura 3 são representadas a f.d.p. $p(r)$ da distribuição, onde σ^2 é a variância da mesma.

$$p(r) = \left\{ \frac{r}{\sigma_r^2} \exp\left(-\frac{r^2}{2\sigma_r^2}\right), \forall r \geq 0 \right. \quad \left. , \forall r \leq 0 \right. \quad (24)$$

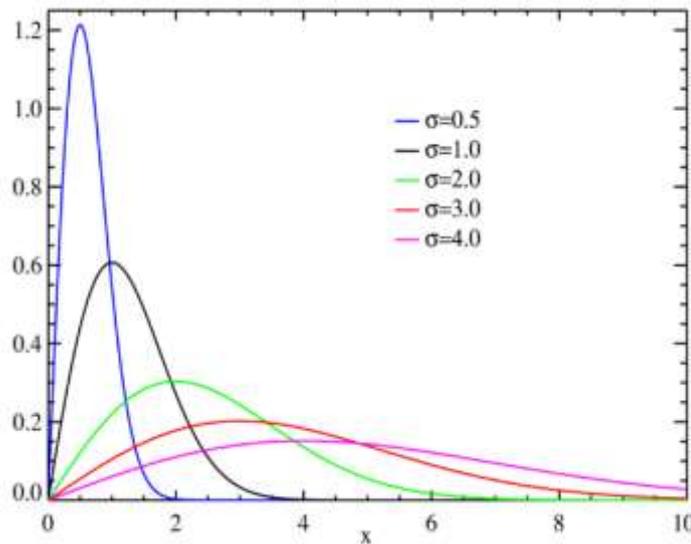


Figura 3 - Função densidade de probabilidade da distribuição Rayleigh [1].

2.2.3. Rice

A distribuição Rice leva em consideração que existe visada direta entre o transmissor e o receptor, ou seja, não existem obstáculos que obstruam o raio principal do sinal. Sendo assim, o sinal recebido é uma soma de ondas espalhadas vindas de multipercursos, assim como em Rayleigh e Log-Normal e também possui um raio de maior amplitude da visada direta [5]. O sinal tratado por Rice é senoidal e descreve variação em pequena escala pois, por ter uma amplitude maior entre as componentes do sinal, não apresenta desvanecimentos profundos.

O sinal S_r é o recebido e é descrito na equação 25, sendo composto da primeira componente a chegar ao RX (α) e do sinal espalhado (r) [5].

$$S_r = r \exp \exp(j\omega_0 t + \theta) + \alpha \exp(j\omega_0 t) \quad (25)$$

Substituindo a equação 20 na equação 25 obtemos:

$$S_r = [(x + \alpha) + jy] \exp(j\omega_0 t) \quad (26)$$

onde:

$$\begin{cases} r^2 = (x + \alpha)^2 + y^2 \\ x + \alpha = r \cos \theta \\ y = r \sin \theta \end{cases} \quad (27)$$

Assim, tem-se que a f.d.p. da distribuição Rice é mostrada pela equação 28, onde r é a envoltória do sinal, σ_r^2 é a potência da componente espalhada e $\alpha^2/2$ é a potência recebida da onda de visada direta. $I_0(x)$ é a função modificada de Bessel de primeiro tipo e ordem zero.

$$p(r) = \frac{r}{\sigma_r^2} \exp\left(-\frac{r^2 + \alpha^2}{2\sigma_r^2}\right) I_0\left(\frac{\alpha r}{\sigma_r^2}\right) \quad (28)$$

$$I_0(x) = 1 + \frac{x^2}{2^2} + \frac{x^4}{2^2 \times 4^2} + \frac{x^6}{2^2 \times 4^2 \times 6^2} + \dots \quad (29)$$

Um parâmetro muito usado nesta distribuição é $K = \alpha^2 / \sigma_r^2$, chamado de fator de Rice, que é a razão entre as duas potências das componentes do sinal. Quando $K \rightarrow 0$, a segunda componente do sinal vai a zero, logo a distribuição de Rice se aproxima de uma Rayleigh, já

que não mais possui a amplitude de visada direta do sinal. Quando $K \gg 1$, então a fase do sinal tenderá à componente dominante, logo a distribuição se aproxima a uma Gaussiana. Na figura 4, é possível ver a distribuição Rice com a variação do fator K .

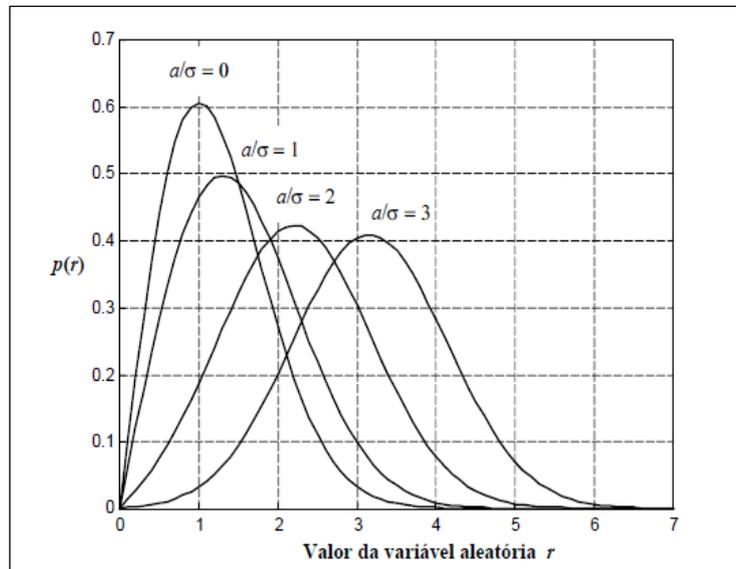


Figura 4 - Densidade de probabilidade para a distribuição de Rice [1].

2.3. Mecanismos de Propagação

No meio de transmissão real, ou não ideal, existem vários obstáculos entre o transmissor e o receptor. Mesmo no caso onde há visada direta, até que a onda chegue ao seu destino vários parâmetros influenciam no seu resultado alterando amplitude, fase, direção, entre outras componentes do sinal. Esses fatores são reflexão, difração e dispersão e chamados mecanismos de propagação [3] e são apresentados nos tópicos que se seguem.

2.3.1. Reflexão

Quando uma onda propagante colide em uma superfície relativamente grande, em relação ao seu comprimento de onda, e que apresenta propriedades dielétricas diferentes do meio em que foi transmitida, acontece a reflexão. Quando o sinal encontra o obstáculo ele tem uma parte refletida, outra transmitida e outra absorvida. As propriedades do obstáculo que influenciam no

quanto do sinal vai ser refletido são: ϵ , μ e σ , que são respectivamente, permissividade, permeabilidade e condutância do material do obstáculo

Um dielétrico com perdas, ou seja, que absorve parte do sinal apresenta permissividade constante em relação à frequência e tem sua condutância variada. Assim, o campo elétrico não é afetado, mas sim, o quanto o sinal vai penetrar no meio depende da frequência em que ele se encontra. Quando a onda transmitida encontra uma superfície condutora perfeita, ela é totalmente refletida, sendo o ângulo incidente igual ao refletido.

Neste caso as componentes do sinal são: transmitida (raio incidente), absorvida (raio refratado) e refletida (raio refletido) como se vê na figura 5.

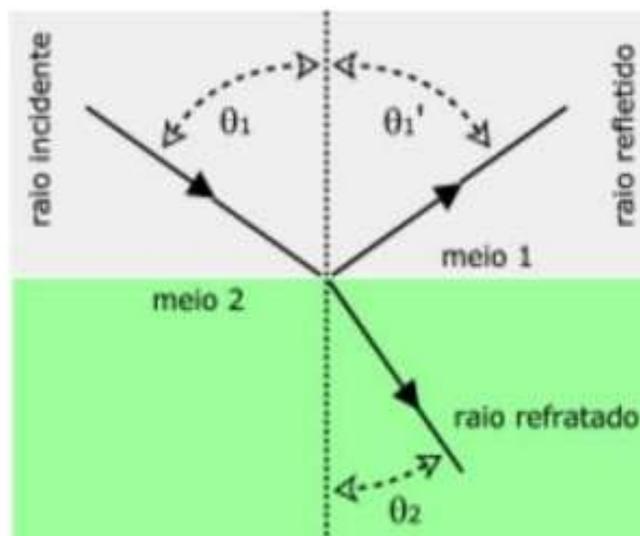


Figura 5 - Componentes do sinal: Raio incidente, raio refratado e raio refletido.

2.3.2. Difração

A difração explica o motivo de haver sinal em um ambiente de sombra. Ela é considerada a curvatura, o alargamento e o espalhamento do sinal ao encontrar um obstáculo levando a mudança de direção de propagação. O efeito da difração é mais perceptível quando o obstáculo é da ordem de grandeza do comprimento de onda do sinal incidente em baixas frequências. Esse mecanismo de propagação é conceituado no princípio de Huygens, que diz que, cada elemento da frente de onda se comporta como uma fonte pontual, originando ondas secundárias permitindo o sinal ter um bom alcance mesmo depois de espalhado.

Como pode ser visto na figura 6 após passar por uma fenda, a onda tem sua intensidade maior, no ângulo reto de incidência do que nos demais ângulos, dependentes do comprimento de onda e da abertura da fenda.

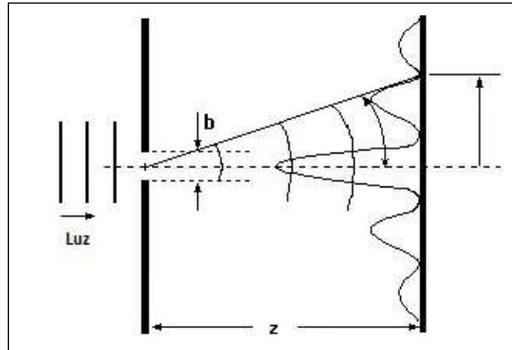


Figura 6 - Comportamento do sinal ao passar por uma fenda.

As ondas secundárias interferem umas nas outras causando uma variação nas intensidades (amplitudes) do sinal além da defasagem de tempo devido a esses multipercursos. O sinal recebido é uma combinação dessas ondas.

2.4. Zonas de Fresnel

O efeito das ondas dos multipercursos pode ser construtivo, onde há amplificação do sinal ou destrutivo, quando as ondas se somam fora de fase reduzindo sua amplitude. As Zonas de Fresnel ajuda a determinar se um obstáculo irá ter um fator de crescimento no sinal ou redutor. As zonas de Fresnel nada mais são do que regiões sucessivas, em forma de elipses concêntricas em torno da visada direta do sinal entre transmissor e receptor, como pode ser visto na figura 7.

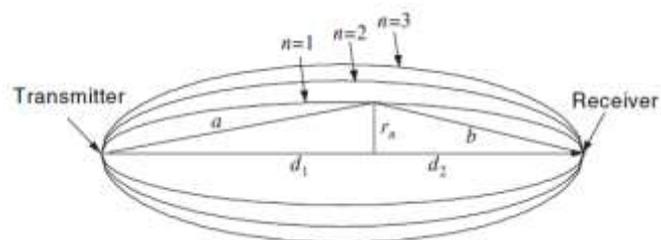


Figura 7 - Zonas de Fresnel [10].

O efeito que obstáculos, dentro dessas regiões, causam no sinal depende da distância dele até o centro das elipses. Para essa verificação é feito o cálculo do raio das zonas de acordo com a equação 30. As zonas possuem alternâncias de fatores construtivos e destrutivos em seus obstáculos. Se não há uma barreira na primeira zona de Fresnel, então o caminho pode ser considerado livre e os efeitos da difração podem ser desconsiderados [3].

$$r_n = \sqrt{\frac{n\lambda(d_1+d_2)}{d_1d_2}} \quad (30)$$

2.5. Modelos de Predição de Perda de Sinal

Com o aumento do uso de tecnologias de comunicação é cada vez mais necessário se obter boa cobertura de sinal, principalmente em lugares onde há maior concentração de usuários. Assim, faz-se necessária uma predição da perda do sinal rádio que se aproxime ao valor real. Para isso, existem modelos de predição de perda de propagação que foram estudados e testados para atender diversos tipos de canais.

Podem-se considerar três tipos de modelos: teóricos, empíricos e semi-empíricos. Modelos teóricos não levam em consideração o ambiente em que o móvel se desloca, dependem de dados geográficos para entender o terreno e são de fácil alteração dos parâmetros, pois não são feitos se adequando a um determinado ambiente. Os empíricos são os obtidos através de campanhas de medições e cálculos dos parâmetros físicos dos ambientes. Por serem feitos para se adequarem a um ambiente, é necessário serem validados para locais, frequências e condições diferentes. Os modelos semi-empíricos ou híbridos apresentam a utilização de ambos os anteriores e têm certa flexibilidade, podendo ser aferidos com medidas reais realizadas nos ambientes de propagação específicos onde são utilizados.

O efeito do meio de propagação no sinal transmitido e os modelos que se aplicam ao canal estudado por este trabalho, serão vistos ao longo do capítulo.

2.5.1. Espaço Livre

A atenuação no espaço livre pode ser vista como o modelo de perda mais simplificado, pois nele é considerada uma propagação onde não há obstruções entre o transmissor e receptor e é considerado céu claro.

A potência recebida, nessa configuração, é calculada pela equação 31 conhecida como equação de Friis, onde d é a distância entre o Tx e Rx em metros, λ é o comprimento de onda em metros, P_t é a potência transmitida e G_t e G_r são os ganhos da transmissora e receptora respectivamente.

$$P_r(d) = \frac{P_t G_t G_r \lambda^2}{(4\pi)^2 d^2} \quad (31)$$

O cálculo desta atenuação (A_e) se dá pela fórmula vista pela equação 32 onde d é a distância entre transmissor e receptor, em km, e f é a frequência transmitida em MHz.

$$A_e = 32.5 + 20 \log \log (d) + 20 \log \log (f) \quad (32)$$

2.5.2. Modelo Log-Distância

O modelo log-distância é um dos modelos simplificados para o cálculo de perda de sinal. Ele mostra como a potência média do sinal recebido diminui logaritmicamente com a distância. A fórmula para o cálculo desta perda é mostrado na equação 33, onde $PL(d_0)$ é a perda em um ponto de referência que esteja dentro do campo distante da antena transmissora e n é o fator de perda de percurso. O valor de n representa a velocidade com a qual a perda aumenta em relação à distância e sendo também conhecido como α , apresentado na seção 2.1.3.

$$PL(dB) = PL(d_0) + 10n \log \left(\frac{d}{d_0} \right) \quad (33)$$

2.5.3. Modelo de Dois Raios

Baseado em ótica geométrica para o cálculo do campo no receptor, o modelo de dois raios considera dois raios, um de visada direta e um raio refletido, em terra plana, entre transmissor e receptor, como mostra a figura 8:

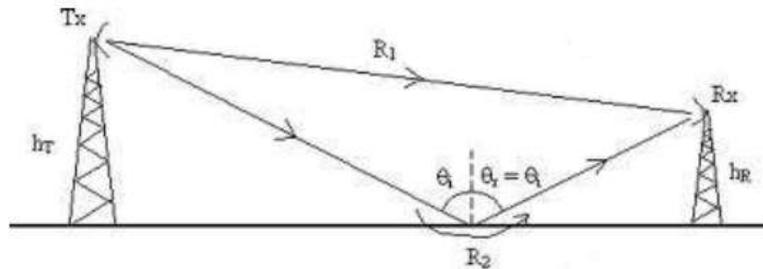


Figura 8 - Modelo de dois raios [11].

onde Tx e Rx são as antenas transmissora e receptora, respectivamente, h_T e h_R são as alturas das antenas, θ_1 e θ_2 são respectivamente os ângulos incidente e refletido, R_1 é o raio em visada direta e R_2 é o raio refletido no solo.

Este modelo tem mostrado bons resultados em ambientes de propagação com antenas de alturas de mais de 50m e microcélulas urbanas onde há visada direta. Podemos considerar seu cálculo como o de perda em terra plana, como na equação 34, sendo a distância d muito maior que a soma das alturas h das antenas.

$$PL(dB) = 40 \log \log d - (10 \log \log G_t + 10 \log \log G_r + 20 \log \log h_t + 20 \log \log h_r) \quad (34)$$

2.5.4. Gume de Faca

Com este modelo é possível o cálculo da perda por difração em obstruções como prédios e montanhas. Nele o sombreamento ocorre devido a apenas um obstáculo que esteja obstruindo o primeiro elipsóide de Fresnel. O cálculo é baseado nas integrais de Fresnel, que consideram um semi-plano transversal ao eixo de transmissão no ponto do obstáculo e que a onda eletromagnética difrate em um pico infinitamente estreito chamado de Gume de Faca. A figura 9 exemplifica a propagação nesse caso. O cálculo é mostrado pelas equações que se seguem.

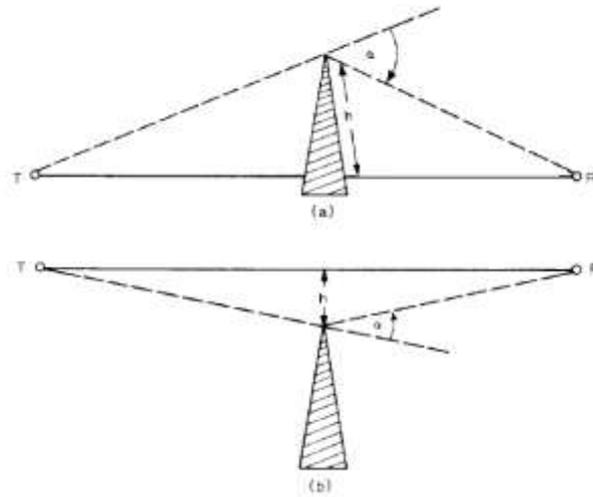


Figura 9 - Modelo Gume de faca (a) com obstrução da visada direta (b) sem obstrução [5].

$$D_{GF} = -10 \log \log 10 \left(\left\{ 0.5 \left\{ [(0.5 - C(v))^2] + [(0.5 - S(v))^2] \right\} \right\} \right) \quad (35)$$

onde v é um fator adimensional:

$$v = h \sqrt{\frac{2}{\lambda} \left(\frac{1}{d_1} + \frac{1}{d_2} \right)} \quad (36)$$

e h e λ estão em metros, d_1 e d_2 são a distância do obstáculo ao transmissor e receptor, respectivamente. $C(v)$ e $S(v)$ são as integrais de Fresnel dadas por:

$$C(v) = \int_0^v \cos \left(\frac{\pi}{2} x^2 \right) dx \quad (37)$$

$$S(v) = \int_0^v \sin \left(\frac{\pi}{2} x^2 \right) dx \quad (38)$$

2.6. Modelos Aplicados em Canal com Vegetação

Parques são ambientes de lazer e descanso onde, em geral, a população busca entretenimento nos dispositivos celulares. Focando nesse tipo de ambiente, uma praça arborizada com construções ao redor e veículos atravessando o percurso transmissor-receptor, foi o local escolhido para a realização das medições apresentadas nesse trabalho. Para esses ambientes, os modelos mais usuais de predição não costumam ter bom ajuste, uma vez que a vegetação entre transmissor (TX) e receptor (RX) tem muita influência no sinal que por ela se propaga, principalmente causando absorção e espalhamento, acarretando não só em atenuação como dispersão do mesmo, respectivamente.

Muitas vezes, é o modelo básico log-distância que acaba por ser o de melhor ajuste nesses ambientes mistos, como ocorre em [9]. Nos tópicos que se seguem, serão apresentados alguns modelos para o cálculo da perda do sinal propagado em um ambiente com vegetação. Muitos outros aparecem na bibliografia [ver DM de Diogo e Bruno].

2.6.1. Modelo Itu-R

O modelo Early ITU, foi proposto pela Organização Internacional de Telecomunicações (ITU) a partir de campanhas de medições em 1988. Sua utilização é para as frequências entre 200 MHz e 95 GHz e com profundidades de vegetação, d , inferiores a 400 metros. Este modelo ficou conhecido como modelo Early ITU, expresso matematicamente por:

:

$$A_{ITU-R} = 0,2 (f)^{0,3} (d)^{0,6} \quad (39)$$

onde f é em MHz e d em metros.

2.6.2. Modelo Chen e Kuo

O modelo proposto por Chen e Kuo foi baseado na teoria geométrica da difração com medições de 10 em 10m, para polarização vertical e para polarização horizontal. Sua fórmula empírica calcula a perda em ambientes com vegetação para as frequências entre 1 e 100 GHz e considera o ambiente caracterizado em quatro camadas: ar, troncos, copa das árvores e solo. As fórmulas empíricas para a atenuação para ambas as polarizações são dadas por:

$$L_v = (0.001f + 0.2)d + 0.5f + 3, \text{ polarização vertical (40)}$$

$$L_H = (0.0002f + 0.2)d + 0.03f + 2, \text{ polarização horizontal (41)}$$

d em metros e f em GHz.

2.6.3. Modelo Weissberg

Este modelo foi proposto em 1982 com seus parâmetros empíricos determinados em campanhas de medições utilizando faixas UHF (400 – 700MHz). Conhecido como exponencial modificado, surgiu após a análise de modelos de decaimento exponencial na faixa de frequências entre 230MHz e 95 GHz. Para o caso em que a propagação ocorre, principalmente através da copa das árvores, esse modelo é o mais apropriado.

As Equações 42 e 43 mostram o cálculo da perda de acordo com a distância d , entre transmissor e receptor na visada direta.

$$L(dB) = 0,45 (f)^{0,284} d, \text{ para } d \leq 14 \text{ metros} \quad (42)$$

$$L(dB) = 0,45 (f)^{0,284} d^{0,588}, \text{ para } 14 \leq d \leq 400 \text{ metros} \quad (43)$$

Sendo a frequência f em GHz e d é a distância entre o ponto de transmissão e recepção ao longo da vegetação, em metros.

Capítulo 3 - Redes Neurais Artificiais

Uma rede neural artificial (RNA) é uma ferramenta de inteligência artificial baseada no funcionamento do cérebro humana com estrutura composta de uma rede de neurônios artificiais. A RNA é implementada através de simulações computacionais.

De forma simplificada, as Redes Neurais Artificiais ou RNAs, são constituídas de um estímulo de entrada que alimenta um ou mais neurônios que são interconectados entre si e/ou com outras camadas de neurônios através das sinapses, que são seus sinais de saída repassados, transportando as informações aprendidas e gerando uma ou mais respostas ao estímulo inicial. O processo para a geração das informações aprendidas até a saída final é constituído de algumas etapas que serão apresentadas ao longo desse capítulo.

3.1. Modelo de um Neurônio

O processamento da informação ocorre em elementos chamados neurônios. Os sinais são propagados de um elemento a outro através de conexões ou sinapses.

A Figura 10 mostra um esquema da representação matemática de um neurônio artificial.

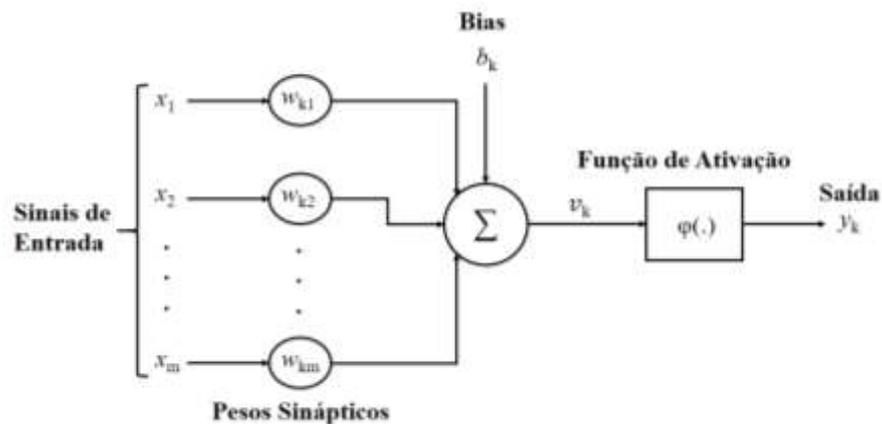


Figura 10 - Esquema da representação matemática de um neurônio.

Os sinal x_j na entrada da sinapse conectada ao neurônio é multiplicado pelo peso sináptico w_{kj} , onde k é o neurônio e j representa o terminal de entrada da sinapse de cada peso. Após serem multiplicados pelos pesos, os sinais são somados. No somador, b_k é o bias que aumenta, se positivo, ou diminui, se negativo, a entrada da função de ativação. A função de ativação $\varphi(\cdot)$, também conhecida como função restritiva, é aplicada para restringir a amplitude da saída de um neurônio a um valor finito.

Os valores dos sinais em cada passo são dados por:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (44)$$

$$v_k = u_k + b_k \quad (45)$$

$$y_k = \varphi(u_k + b_k) \quad (46)$$

3.1.1. Funções de Ativação

Entre outros exemplos de funções de ativação, destacam-se a função Degrau, Linear, Sigmoide Logarítmica, Tangente hiperbólica e Gaussiana.

- A função Degrau é modelada pela equação 47 e tem seu comportamento visto na figura 11.

$$y = \varphi(x) = \begin{cases} 1, & \text{se } x > 0 \\ 0, & \text{se } x < 0 \end{cases} \quad (47)$$

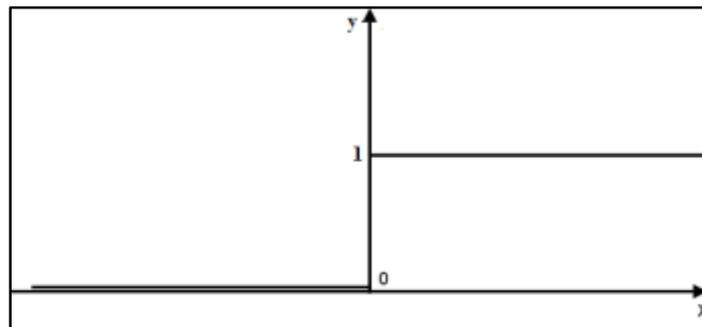


Figura 11 - Função Degrau.

- A função linear é comumente utilizada nos neurônios de saída de RNAs usadas em predição de sinal [12]. Sua equação é mostrada por 48 e representada pela figura 12.

$$y = \varphi(x) = x \quad (48)$$

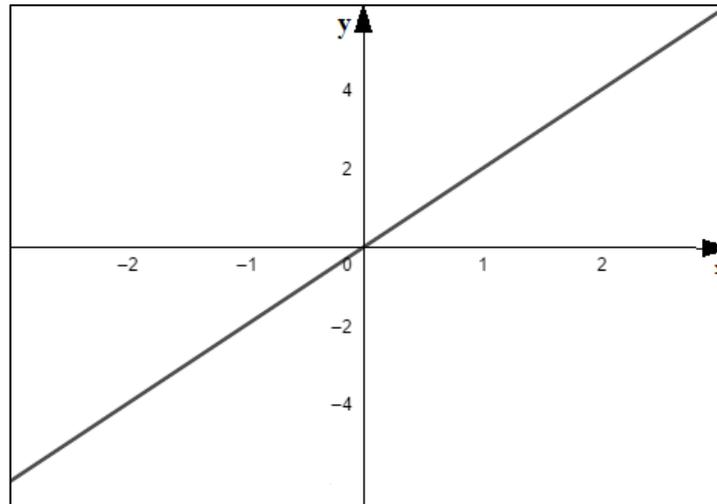


Figura 12 - Função Linear.

- A função de ativação Sigmoide Logarítmica é vista pela figura 13 e tem seu resultado dados pelo cálculo da equação:

$$y = \varphi(x) = \frac{1}{1+e^{-\beta x}} \quad (49)$$

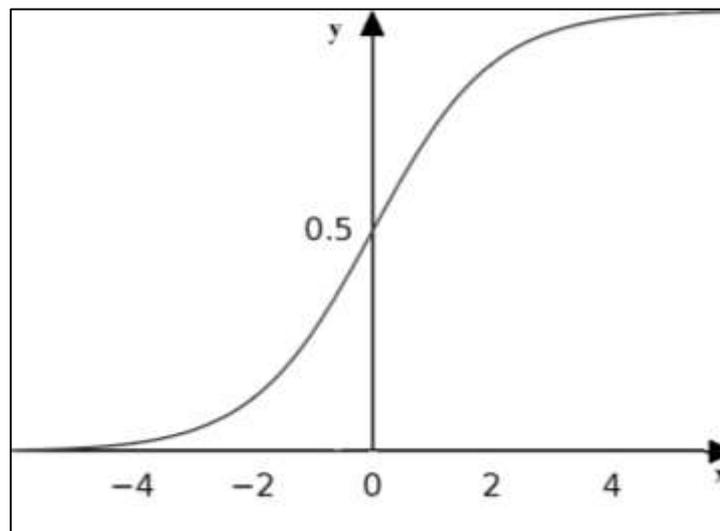


Figura 13 - Função Sigmoide Logarítmica.

- A função Tangente Hiperbólica preserva a forma sigmoide da função anterior, mas apresenta valores no intervalo de $[-1,1]$. Neste trabalho ela foi utilizada nos neurônios da camada escondida. Sua função pode ser vista em (50) e na figura 14.

$$\varphi(x) = \frac{1-e^{-\beta x}}{1+e^{-\beta x}} \quad (50)$$

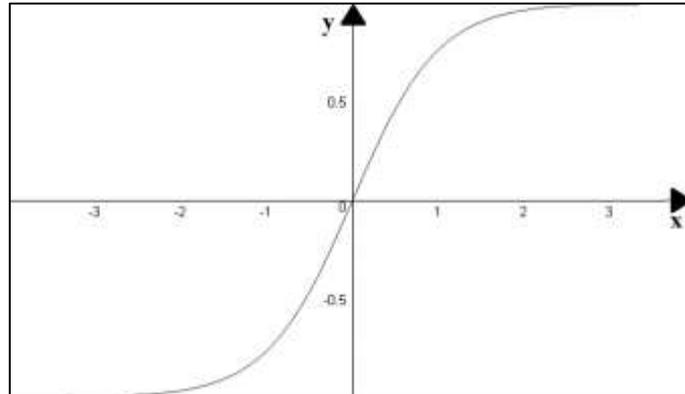


Figura 14 - Função Tangente Hiperbólica.

3.2. Arquitetura de Redes Neurais Artificiais

As redes neurais artificiais podem ser classificadas de acordo com a arquitetura em que foram implementadas, topologias, características de suas conexões, treinamento e tipos de modelos de neurônio. Dependendo de sua estrutura, a arquitetura de redes neurais pode ser constituída ainda de única camada ou múltiplas camadas. As conexões entre os neurônios podem se dar apenas no sentido de ida, tanto no sentido de ida como no sentido de volta, conectadas lateralmente, ou híbridas. Serão apresentadas a seguir, três categorias específicas.

3.2.1. Redes Alimentadas Adiante (Feed-Forward) com Camada Única

A estrutura básica de uma rede neural artificial é formada pelos nós de entrada (x_n) e uma camada de saída, com os neurônios de saída (y_n). Apenas é considerada como uma camada a de saída, pois não é feito nenhum tipo de computação nos nós de entrada. As redes são chamadas de Feed-Forward, pois apenas a camada de entrada alimenta a camada de saída assim as informações sempre vão para frente, ou seja, o movimento não é cíclico. Na figura 15 pode ser visto o exemplo de um esquema de RNA.

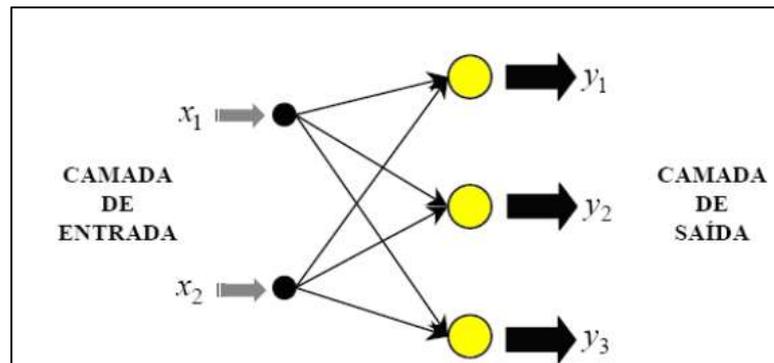


Figura 15 - Fedes feed-forward com camada única [13].

3.2.2. Rede Feed-Forward com Múltiplas Camadas

As redes são consideradas de múltiplas camadas, pois apresentam camadas chamadas ocultas entre a camada de entrada e a camada de saída. Os neurônios que compõem essas camadas, também são chamados de ocultos e são capazes de extrair estatísticas de ordem elevada. Devido ao conjunto extra de conexões sinápticas e da dimensão extra de interações neurais a rede adquire uma perspectiva global apesar de sua conectividade local [27]. A junção entre as camadas é feita pelas conexões, já descritas anteriormente como sinapses. Cada neurônio de uma camada é interligado com todos os outros da camada seguinte, sendo assim a rede toda conectada. O grafo arquitetural na figura 16 ilustra a planta de uma rede neural de múltiplas camadas alimentada adiante para o caso de duas camadas ocultas.

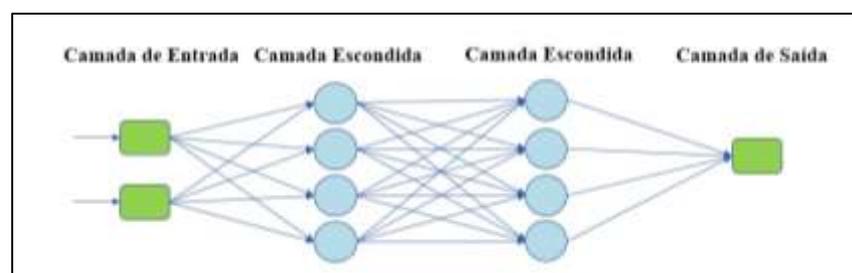


Figura 16 - Rede feed-forward com múltiplas camadas.

3.2.3. Redes Recorrentes

Redes recorrentes têm os sinais de saída final ou das camadas ocultas, alimentando as entradas. Neste caso, o sinal de saída de um neurônio não alimentaria sua própria entrada, como ocorre em uma auto-realimentação, mas sim a entrada geral da rede. A rede recorrente possui uma profunda capacidade de aprendizagem e melhora em seu desempenho, em relação a outras redes, pois o sinal é processado mais de uma vez em cada neurônio. A figura 17 ilustra essa arquitetura.

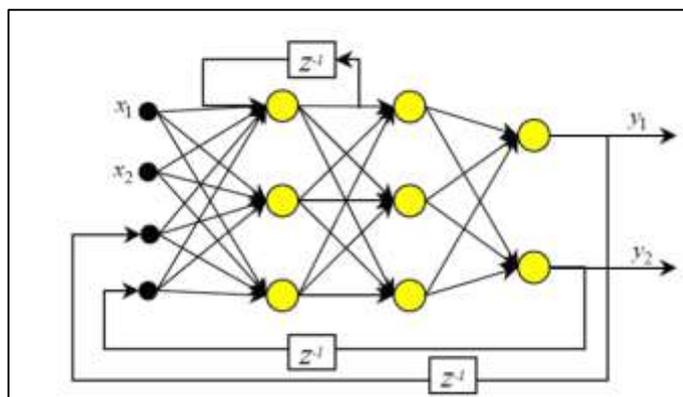


Figura 17 - Rede Recorrente [13].

Devido à baixa complexidade da demanda, o modelo utilizado neste trabalho foi uma Feed-Forward Multicamadas e será visto mais adiante, a quantidade de neurônios e camadas escondidas que apresentaram melhor resultado.

3.3. Treinamento de Uma Rede Neural

A aprendizagem da RNA ocorre na fase de treinamento, onde os conjuntos de dados (entradas e saídas correspondentes) são usados para treinar a rede através de um algoritmo para determinar os pesos das conexões. O objetivo do treinamento da rede é obter o menor erro possível do resultado, quando comparado com as saídas que deveriam ser obtidas. O treinamento de RNA's pode ser dividido em:

3.3.1. Supervisionado

Necessita de um “professor” durante a fase de aprendizagem. Neste caso, os dados usados no treinamento podem ser considerados como exemplos do resultado que deverá ser obtido a partir de certos dados de entrada. Assim os erros são calculados pelo erro médio quadrado ou da soma de erros quadrados entre o sinal de saída dos neurônios e o valor que é considerado como o alvo (*target*).

Um exemplo de algoritmo de aprendizagem supervisionada é o *backpropagation*. Ele consiste em retropropagar os erros das respostas dos neurônios a fim de ajustar os pesos para que, a cada iteração ocorra uma redução mais rápida e significativa do erro. Em resumo, primeiramente os erros nos neurônios são calculados e, depois, na camada de saída, os erros são propagados para trás ajustando os pesos das sinapses a fim de reduzir os erros na rede.

Para encontrar a correção dos pesos Δw_{ji} que minimize o erro da rede, é necessário o uso de um algoritmo. O algoritmo gradiente descendente determina o fator que indicará a direção e o sentido da maior variação dessa descida do erro no processo de treinamento. De (51) chega-se ao resultado dessa correção dos pesos apresentada por (52) onde $\delta_j(n)$, o gradiente local, é descrito por (53).

$$\frac{\partial \varepsilon(n)}{\partial w_{ji}(n)} = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (51)$$

$$\Delta w_{ji} = \eta \delta_j(n) y_i(j) \quad (52)$$

$$\delta_j(n) = e_j(n) \varphi_j'(v(n)) \quad (53)$$

onde η é a taxa de aprendizado e $y_i(j)$ é o sinal de entrada no neurônio.

O algoritmo utilizado neste trabalho foi o Levenberg-Marquardt (LM) O método de LM consiste em um aperfeiçoamento do método Gauss-Newton, que é uma variante do método de Newton.

O método de Newton utiliza a expansão de Taylor de segunda ordem da função de custo em torno do erro $w(n)$. Assim tem-se que o ajuste do peso para esse método é dado pela equação 54 onde $H = \nabla^2 \varepsilon(w)$ representa a hessiana da função custo $\varepsilon(w)$ e g seu vetor gradiente.

$$\Delta w = -H^{-1}g \quad (54)$$

Esse método converge rapidamente. Entretanto, para que o método de Newton funcione, a hessiana $H(n)$ deve ser uma matriz definida positiva para todo n , o que não é possível de ser garantido em toda a iteração do algoritmo, por isso faz-se necessária a modificação do método [14]. O método de Gauss-Newton foi então criado como essa modificação e tem seus ajustes de pesos dados em (55). Pelo fato da matriz $H = [J^T(w)J(w)]$ por não possuir inversa [8] foi criado o modelo *Levenberg-Marquadt*. Este modelo propôs somar a parcela μI a essa matriz, onde μ é um escalar e I é a matriz identidade. Com esse ajuste, a matriz $H = [J^T(w)J(w) + \mu I]$ sempre possuirá inversa [9]. O escalar μ deve ser diminuído para reduzir a influência do gradiente descendente e tem seu valor aumentado para seguir a direção do gradiente descendente. Todas as aproximações são feitas de modo a reduzir o erro da saída da rede. A equação (56) mostra o ajuste do modelo.

$$\Delta w = [J^T(w)J(w)]^{-1}J^T(w)e(w) \quad (55)$$

$$\Delta w = [J^T(w)J(w) + \mu I]^{-1}J^T(w)e(w) \quad (56)$$

3.3.2. Não-Supervisionado

Esse treinamento é utilizado em circunstâncias onde não é possível ter os parâmetros alvos ou quando o objetivo é classificar os parâmetros de entrada. Como não é necessário ter um “professor” para esse aprendizado, é utilizada a regra de aprendizagem competitiva onde a estratégia é do tipo "o vencedor leva tudo" (*winner-takes-all*). Nesta regra os neurônios competem entre si, pela oportunidade de corresponderem com um bom resultado aos dados de entrada. Assim o neurônio com o melhor desempenho "ganha" a competição e se torna ligado; todos os outros neurônios, então, se tomam desligados [7].

Capítulo 4 - Aquisição e Processamento dos Dados

Para a aquisição dos dados de treinamento e teste da rede, foi feita uma campanha de medições na praça Nilo Peçanha, na rua Passo da Pátria, no bairro de São Domingos, em Niterói, Rio de Janeiro. A praça possui três entradas com caminhos de chão de areia, que os interliga, arbustos e árvores de espécies e tamanhos variados, na maior parte do espaço, e um restaurante. Sua localização é urbana, sendo rodeada por casas e ruas com alta movimentação de veículos de transporte de massa.

Garantindo uma diversidade de medidas e cobrindo toda a extensão da praça, duas rotas foram fixadas, ambas partindo de uma das entradas, mas terminando, cada uma, em entradas opostas. A antena transmissora foi colocada a 39,7 metros do começo das rotas na entrada do Campos Praia Vermelha da Universidade Federal Fluminense. A distância do ponto de transmissão até o final das rotas foi 78 metros para a rota 1 e 88.9 metros para a rota 2. A figura 18 mostra o *layout* da medição e as setas indicam as rotas medidas.



Figura 18 - Ambiente de medição e rotas medidas [18].

4.1. *Setup de Medições*

As medições começaram no fim da manhã com céu claro com poucas núvens e não choveu. Por ter sido feita em época de férias escolares, poucos pedestres circulavam na praça, mas a movimentação de automóveis foi considerável, inclusive entre a antena transmissora e receptora.

A antena transmissora foi ajustada em duas alturas diferentes: A1 igual a 1,7 metro e A2 em 4.2 metros. Cinco sinais CW foram transmitidos para cada altura com as cinco frequências: 705 MHz, 1790 MHz, 2,4 GHz, 3,5 GHz e 4 GHz. Cada rota foi percorrida dez vezes, uma para cada frequência e respectivas alturas. Os equipamentos utilizados bem como seus ganhos e perdas serão apresentados nas sessões que se seguem.

4.1.1. *Setup de Transmissão*

Toda a estrutura do sistema de transmissão (Tx) foi montada no lado de dentro do portão, por questões de segurança e organizacional, da rua Passo da Pátria do campus Praia Vermelha da UFF em Niterói (vide figura 19). A antena foi colocada em um pedestal que estava no chão do lado de fora do portão, para a altura A1 (1,7 m), como mostrado na figura 20 e no mesmo pedestal, mas em cima do muro para a altura A2 (4,2 m), visto na figura 21.



Figura 19 - Setup de Transmissão.



Figura 20 - Antena transmissora na altura de 1,7 m.



Figura 21 - Antena transmissora na altura de 4,2 m.

Os equipamentos e cabos utilizados na transmissão foram:

- Gerador de sinais MG3700A da Anritsu, mostrado na figura 22, trabalha com sinais vetoriais e apresenta algumas características importantes como: faixa de frequências de transmissão de 250 kHz a 6 GHz; transmissão modulada em banda larga até 150 MHz; alta capacidade de *buffer* (até 512.000 amostras/canal); armazenamento interno de 40 GB e transmissão simultânea de dois sinais.



Figura 22 - Gerador de sinais Anritsu MG3700A.

- Cabos coaxiais para ligação do gerador de sinais ao amplificador e do amplificador à antena de transmissão. Foram usados três cabos cujas atenuações foram medidas em laboratório, para cada frequência portadora empregada, com o analisador vetorial de rede MS2038A, e estão descritas na tabela 2.

Tabela 2 – Perdas dos cabos usados na transmissão de acordo com as frequências utilizadas.

Frequência (MHz)	Perda (dB) (Anritsu)	Perda (dB) (R&S)	Perda (dB) (Nacional)
705	1,8	1,8	1,7
1790	1,9	2,1	5,5
2400	0,9	0,1	1,6
3500	3,65	3,4	1,6
4000	5,9	2,6	3,0

- Amplificador de potência (PA) com operação na faixa de frequência de 1800 até 4000 MHz. Foram levantados seus ganhos reais no laboratório (LAPROP), como mostra a tabela 3. Assim, como em 705 MHz o PA já fornecia alto ganho, foi empregado em todas as medições. A alimentação do amplificador de potência é de 28 VDC e 4,3 A, sendo fornecida por uma fonte da ICEL, modelo PS-5000. Sua imagem pode ser vista na figura 23.

Tabela 3 – Ganho para cada frequência do amplificador de potência.

Frequência (MHz)	Ganho (dB)
705	40
1790	43,8
2400	41,2
3500	45,8
4000	46,8

**Figura 23 - Amplificador de Potência: Mini-circuits ZHL-16W-43+.**

- Antena omnidirecional, com polarização linear e vertical. Opera na faixa de frequência de 380 até 6000 MHz, e fornece um ganho máximo que varia de 1 a 6 dB, de acordo com a frequência. Para as duas alturas de transmissão, em ambas as rotas, foram calculadas o ganho real para frequência, como mostrado na tabela 4.

Tabela 4 – Perdas e ganhos da antena transmissora.

Frequência (MHz)	Ganho (dB) RFS	Valor do Diagrama (~ 90°)	Valor Ganho real (dB)
705	1	-5	-4
1790	5	-5	0
2400	6	-5	1
3500	6	-5	1
4000	6	-5	1

4.1.2. Setup de Recepção

O sistema de recepção foi todo montado em um carrinho para que as rotas pudessem ser percorridas com velocidade média de 1,5 m/s em um tempo de 60 segundos. Na figura 24 é possível ver o carrinho com os equipamentos utilizados e os cabos e extensões, utilizados para alimentá-los.

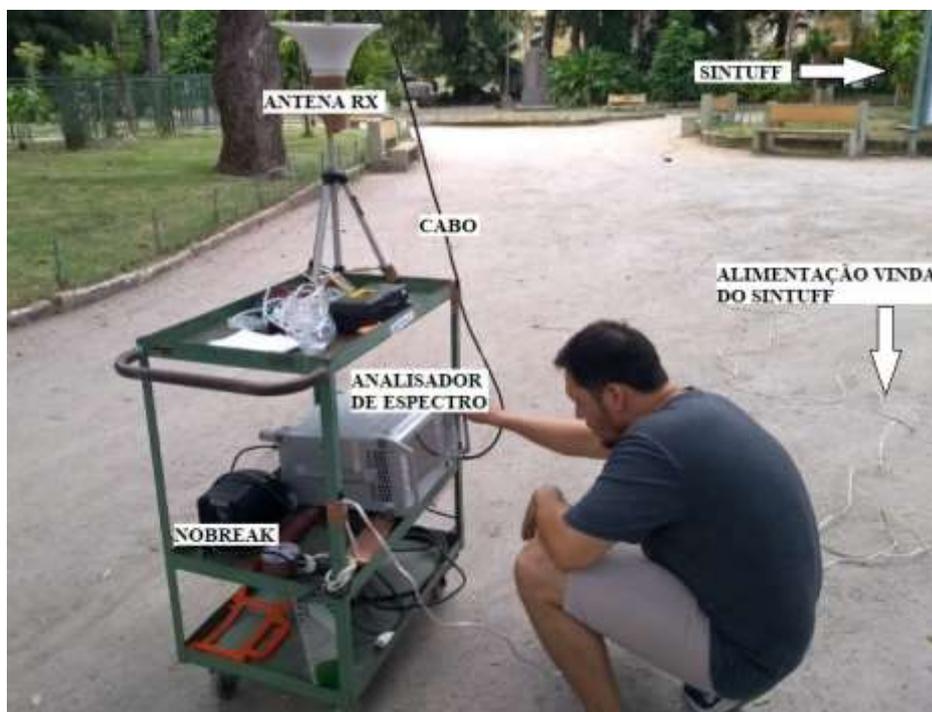


Figura 24 - Setup de Recepção.

Os componentes dessa configuração para a recepção do sinal foram:

- Antena receptora, de mesmo modelo da antena utilizada na transmissora, foi colocada a uma altura fixa de 1.59m em relação ao chão. Seus ganhos para as duas alturas da antena transmissora são apresentados pelas tabelas 5 e 6.

Tabela 5 - Ganho real da antena de Recepção para A1 de 1.7 metros.

Frequência (MHz)	Ganho (dB) RFS	Valor do Diagrama (~ 90°)	Valor Ganho real (dB)
705	3	-2,5	-0,5
1790	5	-6,5	-1,5
2400	6	-11,5	-5,5
3500	6	-5	1
4000	6	-7	-1

Tabela 6 - Ganho real da antena de Recepção para A2 de 4.2 metros.

Frequência (MHz)	Ganho (dB) RFS	Valor do Diagrama (~ 90°)	Valor Ganho real (dB)
705	3	-2	1
1790	5	-6,5	-1,5
2400	6	-8	-2
3500	6	-4,5	1,5
4000	6	-6	0

- O cabo utilizado para conectar o analisador de espectro à antena de recepção é da marca Anritsu, com comprimento de 1 metro. Sua atenuação, para cada frequência, foi levantada no laboratório (LAPROP) com o analisador vetorial de rede MS2038A e pode ser visto na tabela 7.

Tabela 7 - Perdas no Cabo para as portadoras empregadas.

Frequência (MHz)	Perda (dB) (Anritsu)
705	1,8
1790	2,2
2400	0,12
3500	3,7
4000	4,9

- O Analisador de espectro *Anritsu MS2692A* utilizado, possui RBW (*Resolution Bandwidth*) = 3 kHz, e *span* nulo. Seu tempo de varredura pode variar de 10 μ s a 600 s (*zero span*) e em cada varredura (60s) ele capturou 10001 amostras do sinal, que foram armazenadas em sua memória interna. A figura 25 mostra o analisador.



Figura 25 - Analisador de Espectro *Anritsu MS2692A*.

4.2. Ajuste dos Dados

O analisador de espectro armazenou as 10001 amostras por percurso, da potência do sinal recebido, em dBm, assim como algumas informações como frequência e RBW. Foi possível a recuperação desses dados em formato .csv como planilha de Excel.

Com o intuito de utilizar os dados medidos no treinamento e teste de uma rede neural, fez necessário um ajuste de maneira a ter os dados de *input* e *target* para isso foi usada a plataforma *Matlab*[®]. Foram formadas matrizes com os valores de entrada separadas de acordo

com a altura da antena transmissora (A), potência transmitida (P), frequência utilizada (F) e rota percorrida (R) que foram salvos em uma planilha para que pudessem ser utilizados em vários modelos de redes. Os valores de alvo da rede, que são as potências recebidas foram também separados pela mesma configuração e salvos em uma planilha.

Assim os dados foram separados pelos 20 percursos da maneira como mostrado na tabela 8, onde R1 é a rota 1, R2 é a rota 2.

Tabela 8 – Organização dos dados medidos.

Frequência (MHz)	Altura da Transmissora /Rota			
	A1/R1	A2/R1	A1/R2	A2/R2
705	A1F1R1	A2F1R1	A1F1R2	A2F1R2
1790	A1F2R1	A2F2R1	A1F2R2	A2F2R2
2400	A1F3R1	A2F3R1	A1F3R2	A2F3R2
3500	A1F4R1	A2F4R1	A1F4R2	A2R4R2
4000	A1F5R1	A2F5R1	A1F5R1	A2F5R2

Capítulo 5 - Aplicação da Rede Neural Artificial

Para a criação da rede neural artificial foram escolhidos parâmetros que variaram ao longo dos testes e outros que se mantiveram fixos. Os parâmetros variáveis foram: os dados de entrada inicialmente sendo a altura da antena transmissora, potência transmitida, frequência utilizada e distância entre a antena transmissora e cada ponto da rota, os dados de saída que foram o nível de sinal recebido em cada ponto da rota e a função de criação da rede sendo: *newfit*, *fitnet* e *feedforwardnet*. Os hiperparâmetros fixos foram escolhidos de acordo com seu bom desempenho apresentado em trabalhos como [11] – [12], sendo eles: a estrutura de múltiplas camadas (3.2.2), a função de ativação tangente hiperbólica usada nos neurônios da camada oculta e a função de ativação linear nos neurônios da camada de saída (3.1.1) e algoritmo de aprendizagem supervisionada backpropagation com modelo *Levenberg-Marquand* de otimização (3.3.1).

Para a comparação dos resultados das redes de diferentes configurações foi utilizado o cálculo do Erro Médio Quadrático (RMSE), cuja fórmula é dada por:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (f_i - g_i)^2}{N}} \quad (57)$$

Após escolhidos os parâmetros, foram testadas diversas configurações, modificando os parâmetros de entrada, saída, a quantidade desses dados, o número de neurônios na camada oculta e a função do *Matlab*® sendo escolhida a que apresentou o menor erro médio quadrático (RMSE). Todo o processo de criação e teste de uma das redes, que serão apresentadas em 5.2 com 1000 iterações no treinamento, teve um custo computacional de aproximadamente 9 minutos e 25 segundos e foi feito em um sistema de 64 bits, processador Intel® Core™ i5-8400 2,8GHz com uma memória RAM de 8GB. A eficácia da rede foi também comprovada pela comparação de seu valor RMSE com o do modelo de predição de perda de sinal que melhor se ajustou ao ambiente de teste. No tópico seguinte é mostrada a comparação entre os modelos.

5.1. Comparação dos Modelos de Predição

Para que fosse feita a comparação da rede com o melhor modelo de predição de perda para o ambiente de medições, provando assim sua eficácia na predição do sinal em ambientes com vegetação, foram calculados os sinais preditos pelos modelos de predição apresentados em 2.6, para os dados utilizados. A figura 26 mostra a comparação entre as perdas de percurso dos modelos Log-Distância, *Chen e Kuo*, *Weissberg* e ITU-R com o ajuste dos dados reais medidos na campanha de medições para um percurso. Os gráficos comparativos para os demais percursos estão no anexo B.

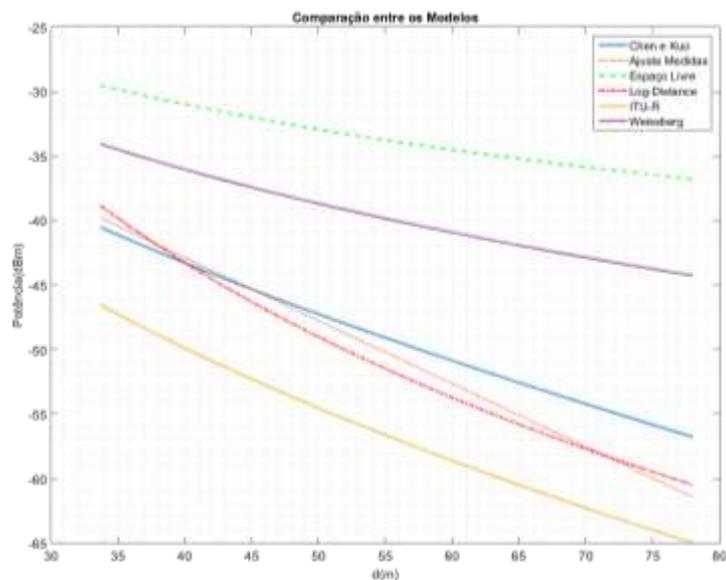


Figura 26 - Comparação entre os modelos de predição de perda de sinal e o ajuste dos dados medidos para o conjunto: altura Tx de 1,7 m, frequência de 2.4 GHz e rota 1.

Pela figura é possível ver que o modelo que melhor se ajusta aos dados medidos, logo que melhor se ajusta ao ambiente de medições, foi o modelo Log-distância. Assim para comparar com a saída da rede, foram utilizados os valores RMSE do modelo.

Tabela 9 – Valores RMSE do modelo Log-distância.

Frequência (MHz)	Altura da Transmissora /Rota			
	A1/R1	A2/R1	A1/R2	A2/R2
705	0,055	0,108	0,045	0,059
1790	0,062	0,089	0,058	0,044
2400	0,044	0,063	0,046	0,060
3500	0,042	0,071	0,057	0,048
4000	0,045	0,048	0,063	0,104

Nos próximos tópicos deste capítulo serão apresentadas a organização dos parâmetros da rede, seus treinos, testes bem como seus resultados.

5.2. Processo de Criação da RNA

As variações na configuração da RNA se deram da seguinte forma: inicialmente, foi selecionada a rota que teria seus dados utilizados, depois foram escolhidos os dados de entrada e de saída, a quantidade dos dados utilizados, a porcentagem desses dados nos hiperparâmetros para treinamento, validação e teste e a quantidade de neurônios na camada escondida. De posse do resultado da rede que melhor se aplicou na predição do ambiente, foram testadas outras funções de criação dessa rede, que para o programa, variou entre *newfit*, *fitnet* e *feedforwardnet*. Os códigos para todas as redes criadas neste trabalho podem ser vistos no anexo C.

Para a criação da primeira rede, foram selecionados os elementos da rota 1, empregada *feedforwardnet* como função de criação e escolhido o maior número de dados de entrada para serem, depois, reduzidos gradativamente. Assim os dados de entrada da primeira configuração foram: altura da antena transmissora, potência transmitida, frequência utilizada e distância entre a antena transmissora e cada ponto da rota. A nível de sinal recebido em cada ponto da rota foi a saída da rede. Como dito em 4.2, o analisador de espectro capturou 10001 amostras por percurso. Assim como a rota 1 foi percorrida 10 vezes, a quantidade de conjunto de dados de entrada e saída foram de 100010, ou seja, 100% dos dados medidos.

Ajustados esses dados para o treinamento, como mostrado no anexo A, a rede foi configurada considerando 60% dos dados para treino, 20% para validação e 20% para teste. As

figuras 27 e 28 mostram os gráficos de saída da rede que melhor se ajustou, em relação aos dados reais coletados para um percurso da rota 1, onde a rede foi treinada e para um percurso da rota 2, respectivamente. A tabela 10 mostra seu valor RMSE.

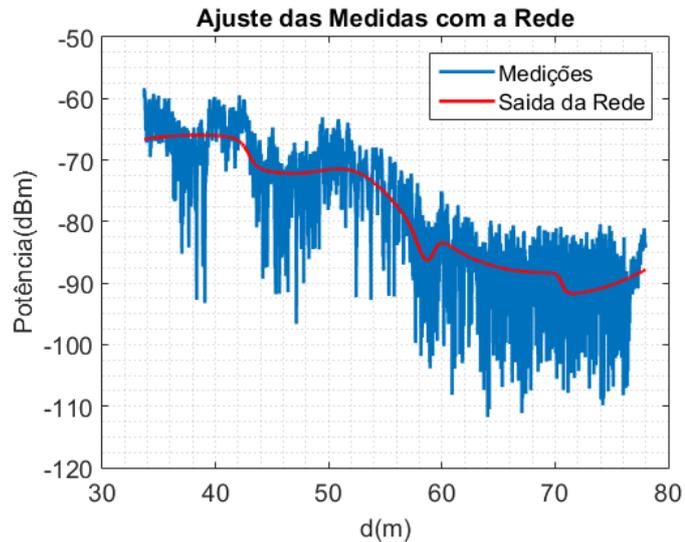


Figura 27 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 4 GHz e rota 1 treinada com divisão 60%, 20%, 20% dos dados da rota 1 e 12 neurônios na camada escondida.

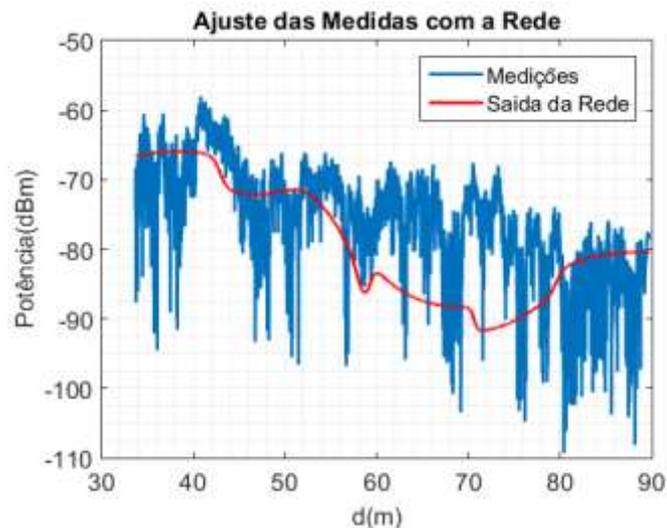


Figura 28 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 4 GHz e rota 2 treinada com divisão 60%, 20%, 20% dos dados da rota 1 e 12 neurônios na camada escondida.

Tabela 10 - Valores RMSE da rede treinada com divisão 60%, 20%, 20% dos dados da rota 1 e 12 neurônios na camada escondida.

Frequência (MHz)	Altura da Transmissora /Rota			
	A1/R1	A2/R1	A1/R2	A2/R2
705	0,025	0,028	0,07	0,073
1790	0,032	0,035	0,1	0,067
2400	0,036	0,04	0,071	0,064
3500	0,034	0,04	0,1	0,066
4000	0,041	0,038	0,079	0,07

Pela comparação entre as tabelas 9 e 10 é possível ver que a rede apresenta todos os valores RMSE da rota 1 e um valor da rota 2, menores do que os de log-distância, já provando sua eficácia em relação ao melhor modelo aplicado. Com os mesmos parâmetros de entrada e números de neurônios na camada escondida, foi criada a rede para a configuração de 80% treino, 10% validação e 10% teste. As figuras 29 e 30 mostram a comparação da rede com os dados obtidos na medição e a tabela 11, seu RMSE.

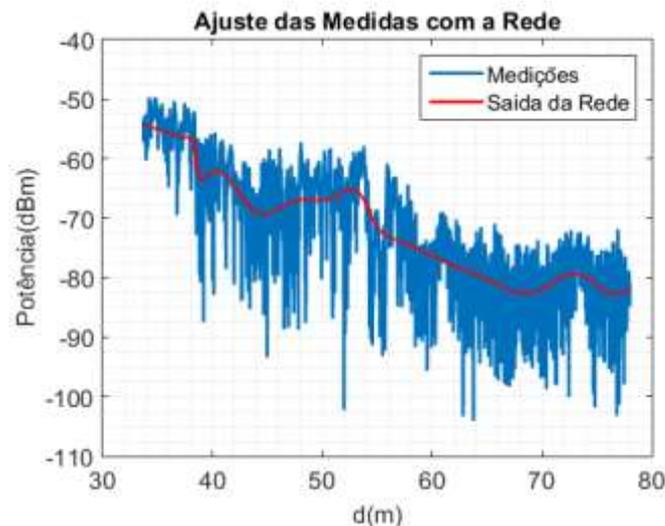


Figura 29 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 1,7 m, frequência de 4 GHz e rota 1 treinada com divisão 80%, 10%, 10% dos dados da rota 1 e 20 neurônios na camada escondida.

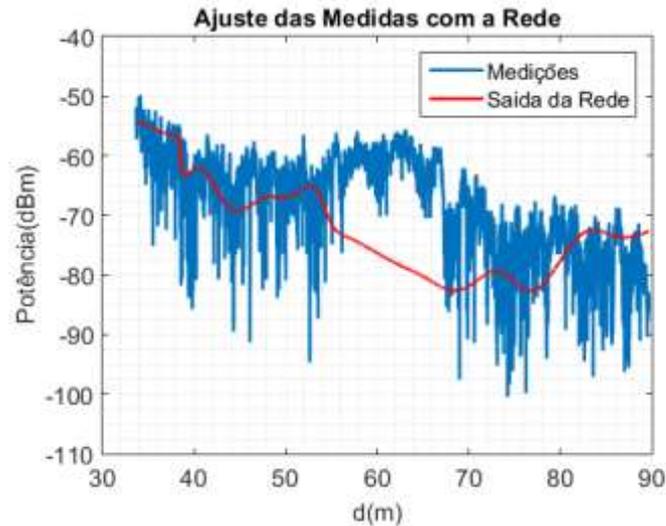


Figura 30 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 1,7 m, frequência de 4 GHz e rota 2 treinada com divisão 80%, 10%, 10% dos dados da rota 1 e 20 neurônios na camada escondida.

Tabela 11 - Valores RMSE da rede treinada com divisão 80%, 10%, 10% dos dados da rota 1 e 20 neurônios na camada escondida.

Frequência (MHz)	Altura da Transmissora /Rota			
	A1/R1	A2/R1	A1/R2	A2/R2
705	0,026	0,026	0,100	0,097
1790	0,030	0,035	0,146	0,127
2400	0,035	0,038	0,135	0,123
3500	0,032	0,039	0,105	0,109
4000	0,039	0,036	0,079	0,080

Pela comparação entre as tabelas 10 e 11, vê-se que a rede treinada com a configuração 60%, 20%, 20% apresentou menor erro. Após este resultado, foi feita uma variação na quantidade dos dados utilizados na rede e dos números de neurônios na camada escondida. A rede que melhor se ajustou para os mesmos quatro parâmetros de entrada e divisão de 60%, 20% e 20%, foi a que utilizou 100% dos dados e 12 neurônios na camada escondida, que foi mostrada anteriormente.

Os dados de entrada e saída obtidos na medição da rota 2 foram, então ajustados e aplicados para treinamento e teste da rede melhor ajustada, cuja configuração foi apresentada

anteriormente. As figuras 31 e 32 mostram seu comportamento. Assim foi possível ver, pela comparação entre as tabelas 9 e 12, que a rede treinada com os dados da rota 2 apresentou 3 percursos da rota 1 com valores de erro médio quadrático menores do que log-distância. O que caracteriza a rota 2 como mais diversificada.

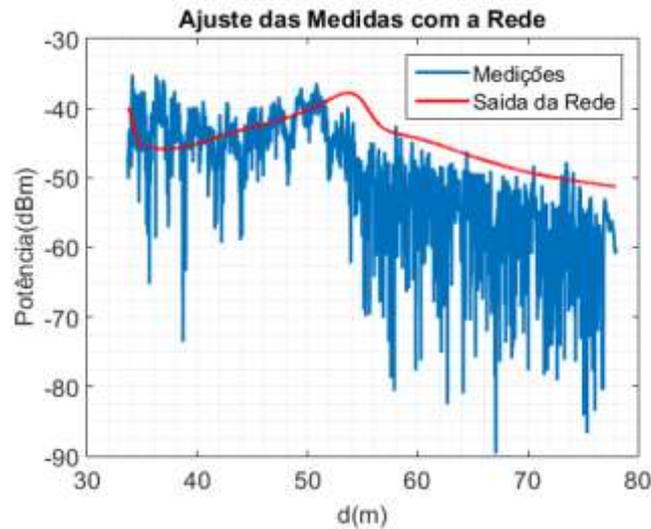


Figura 31 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 1790 MHz e rota 1 treinada com divisão 60%, 20%, 20% dos dados da rota 2 e 12 neurônios na camada escondida.

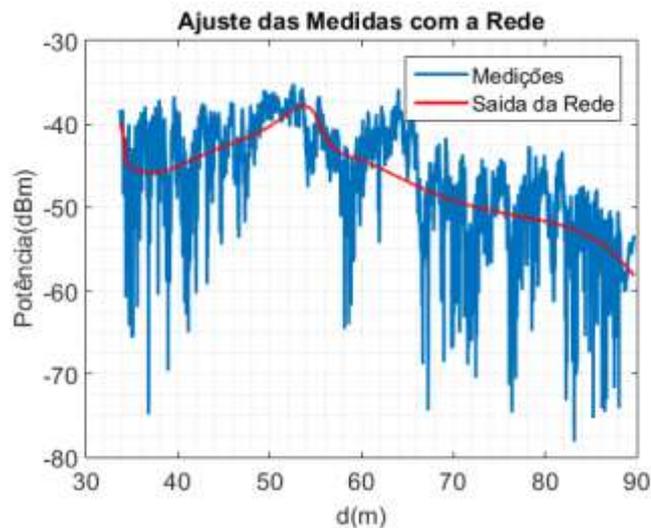


Figura 32 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 1790 MHz e rota 2 treinada com divisão 60%, 20%, 20% dos dados da rota 2 e 12 neurônios na camada escondida.

Tabela 12 - Valores RMSE da rede treinada com divisão 60%, 20%, 20% dos dados da rota 2 e 12 neurônios na camada escondida.

Frequência (MHz)	Altura da Transmissora /Rota			
	A1/R1	A2/R1	A1/R2	A2/R2
705	0,069	0,074	0,025	0,027
1790	0,111	0,065	0,037	0,036
2400	0,069	0,068	0,039	0,038
3500	0,103	0,069	0,037	0,038
4000	0,083	0,075	0,036	0,038

São comumente encontrados na literatura, testes de redes neurais artificiais onde a frequência transmitida é a única informação do sistema de transmissão. Com o intuito de tornar a rede facilmente aplicável em outros ambientes e conjunto de dados, foram feitas as mudanças citadas, a seguir, nos parâmetros de entrada. Foi retirada, dos dados de entrada, a potência transmitida para cada percurso, ficando então a nova configuração: Altura da antena transmissora, frequência utilizada e distância entre transmissor e cada ponto da rota. Os testes foram realizados como descrito anteriormente. A rede que melhor se ajustou foi a treinada com 30% dos dados da rota 2 com divisão de 80%, 10%, 10% e 10 neurônios na camada escondida. As figuras 33 e 34 mostram seu comportamento para um percurso da rota 1 e para um percurso da rota 2, respectivamente e na tabela 13 é possível ver a melhoria da rede para a rota 2 em relação ao modelo log-distância em porcentagem.

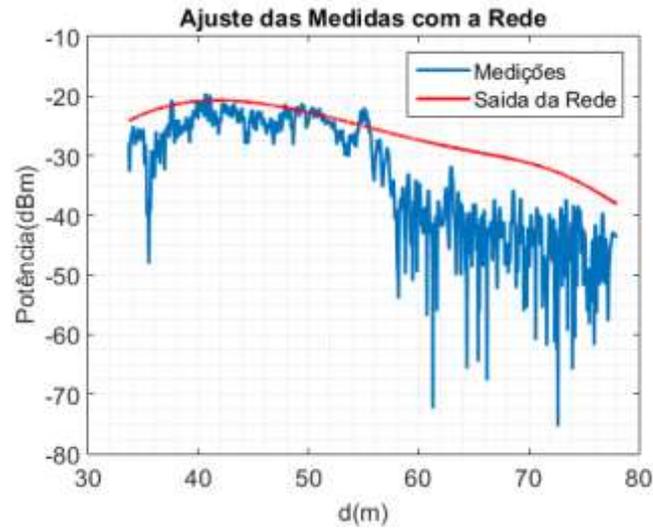


Figura 33 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 705 MHz e rota 1 treinada com divisão 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida.

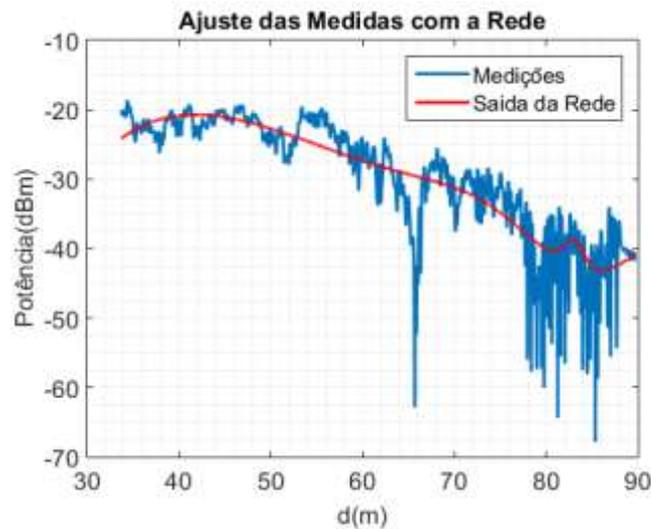


Figura 34 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 4,2 m, frequência de 705 MHz e rota 2 treinada com divisão 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida.

Tabela 13 - Percentual de melhoria na predição de sinal da rede treinada com divisão 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida em comparação com o modelo log-distância.

Frequência (MHz)	Altura da Transmissora /Rota	
	A1/R2	A2/R2
705	36,9%	56,8%
1790	38,8%	15,6%
2400	14,9%	31,5%
3500	33,5%	12,1%
4000	38,8%	60,2%

Foi realizada ainda mais uma redução dos parâmetros de entrada restando apenas a frequência utilizada e a distância entre a antena transmissora e cada ponto da rota. As figuras 35 e 36 mostram a rede treinada com 30% dos dados da rota 2 com divisão de 80% para treinamento, 10% de validação e 10% de teste. A tabela 14 mostra a melhoria em porcentagem da rede em relação ao modelo log-distância.

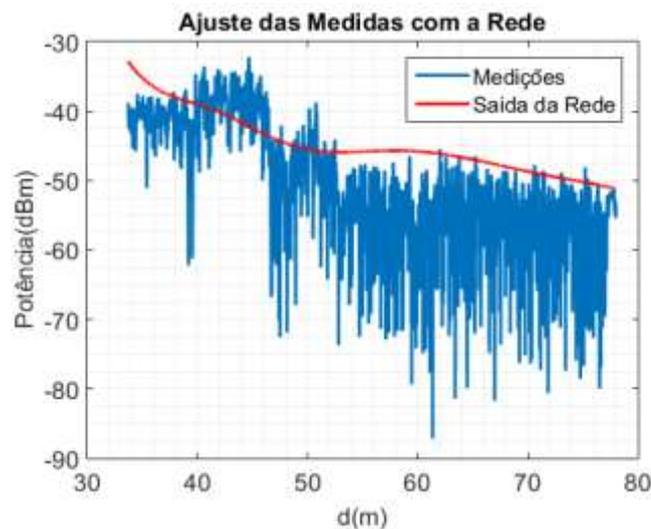


Figura 35 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 1,7 m, frequência de 2,4 GHz e rota 1 treinada com divisão 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida.

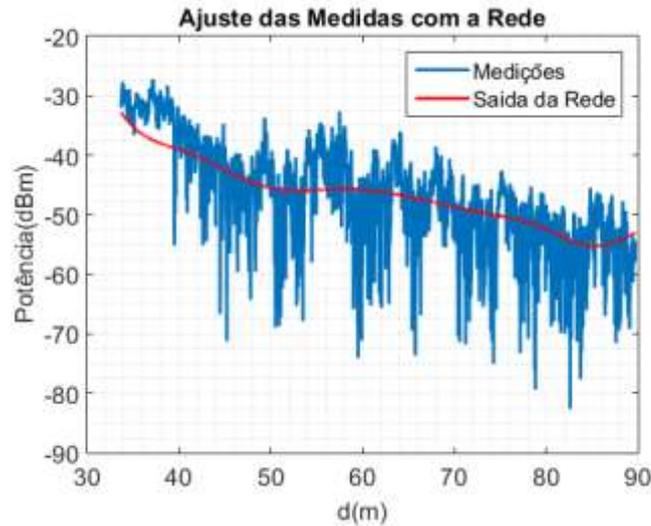


Figura 36 - Comparação entre o sinal medido e a rede para o conjunto: altura Tx de 1,7 m, frequência de 2,4 GHz e rota 2 treinada com divisão 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida.

Tabela 14 - Percentual de melhoria na predição de sinal da rede treinada com 80%, 10%, 10% dos dados da rota 2 e 10 neurônios na camada escondida em comparação com o modelo log-distância.

Frequência (MHz)	Altura da Transmissora /Rota	
	A1/R2	A2/R2
705	30,8%	42,2%
1790	18,3%	9,7%
2400	6,6%	28,1%
3500	4,4%	1,1%
4000	10,2%	51,3%

Comparando todas as redes neurais criadas neste trabalho a rede que melhor se adaptou ao ambiente, ou seja, que apresentou menor valor RMSE na rota em que foi treinada foi a rede treinada com divisão 80%, 10%, 10% de todos os dados da rota 1 e 20 neurônios na camada escondida. A rede que apresentou menor valor RMSE na rota em que não foi treinada foi a rede treinada com divisão 60%, 20%, 20% de todos os dados da rota 1 e 12 neurônios na camada escondida.

Pelas comparações entre as tabelas 13 e 14, é possível observar que a melhoria da rede neural com três parâmetros de entrada, em relação ao modelo *Log-Distance*, é maior do que aquela com apenas dois parâmetros. Mesmo apresentando uma melhora inferior, a rede com dois parâmetros de entrada demonstra capacidade de prever o sinal em ambientes em vegetação com precisão.

Capítulo 6 - Conclusões e Trabalhos Futuros

A partir de dados experimentais obtidos em uma campanha de medições em ambiente de parque com vegetação foram feitas diversas comparações, descobrindo-se que os atuais métodos utilizados para a predição de perda de sinal nesses ambientes apresentam considerável diferença em relação aos dados reais. Entre os modelos existentes, destaca-se o modelo log-distância por ser o modelo que apresentou melhor ajuste na maioria dos percursos das rotas medidas com erro médio quadrático variando de 0,042 dB a 0,108 dB.

Com o intuito de se ter um modelo de predição de sinal que fosse mais eficaz, foi criada uma rede neural artificial *feedforward backpropagation* que, após treinamento e testes, mostrou-se eficiente na predição do nível de sinal do canal rádio móvel com vegetação em comparação com o modelo Log-Distância aplicado ao mesmo conjunto de dados. A rede com menor erro médio quadrático em comparação com as rotas cujos dados foram usados no treinamento foi a treinada com divisão 80%, 10%, 10% de todos os dados da rota 1 e 20 neurônios na camada escondida apresentando uma variação de erro de 0,026 dB a 0,039 dB. A rede com menor erro para os percursos onde não foi treinada foi a rede treinada com 60%, 20%, 20% dos dados da rota 1 e 12 neurônios na camada escondida com erro variando de 0,064 dB a 0,1 dB.

Outros testes e comparações foram feitos e verificou-se que o uso das redes neurais artificiais são de muita relevância na predição de sinal em ambientes também em vegetação. Com resultado destacado para o caso em que a RNA foi treinada em uma rota e aplicada em outra rota, leva-se a crer que é possível aplicar a mesma rede em outros ambientes com as mesmas características e ainda assim obter resultados satisfatórios.

Mesmo com a eficácia da rede sendo comprovada, no futuro, outros testes poderão ser realizados como a aplicação de dados coletados em outros ambientes, modificação dos hiperparâmetros e do número de camadas e neurônios em cada uma delas e variação da quantidade de dados nos parâmetros de entrada. Quanto aos componentes do neurônio como pesos e *bias*, é possível averiguar, através de cálculos, suas reais influências no problema proposto variando seus valores e buscando a redução do erro médio quadrático. Outros indicadores de comparação dos resultados da rede também podem ser aplicados como a chamada métrica D. Todos os testes foram sempre realizados com o intuito de otimizar a predição do sinal.

Bibliografia

- [1] MENDONÇA, L.A. DM “Análise da Propagação de Ondas Eletromagnéticas em Canais com Desvanecimento”. Inatel, Santa Rita de Sapucaí, 2002.
- [2] “Probability distributions relevant to radiowave propagation modelling”. Recommendation ITU-R P.1057-1, 1994-2001.
- [3] RAPPAPORT, T. “Wireless Communications Principles and Practice”. Second Edition, Prentice Hall, 2001.
- [4] PAHLAVAN, K., LEVESQUE, A. “Wireless information networks”. Hoboken, NJ: John Wiley, 2005.
- [5] PARSONS, J. “The mobile radio propagation channel”. Chichester: John Wiley, 2001.
- [6] CHEN, H. Y., KUO, Y. Y. “Calculation of radio Loss in Forest Environments by an Empirical Formula.” *Microwave and Optical Technology Letters*, vol. 31, no 6, pp. 474-480, 2001.
- [7] HAYKIN, S. “Neural Networks and Learning Machines.” Third Edition, McMaster University Hamilton, Ontario, Canada, Pearson Education, 2009.
- [8] NETO, L.B. SIEIRA, A.C. “Utilização de Redes Neurais Artificiais na determinação do coeficiente de influência para carregamentos triangulares e trapezoidais.” *Engevista*, v. 9, n. 1, pp. 22-34, junho 2007.
- [9] ROWEIS, S. “Levenberg Marquardt Optimization.” Disponível em (www.cs.toronto.edu/~roweis/notes/lm.pdf), 2003.
- [10] SAUNDERS, S. R., ZAVALA, A. A. “Antennas and Propagation for Wireless Communication Systems.” Second Edition, JohnWiley & Sons Ltd, The Atrium, Southern Gate, England, 2007.
- [11] FERREIRA, G. P. “Aplicação De Redes Neurais Artificiais Como Auxílio À Predição De Cobertura De Sinais Rádio Móveis Na Faixa De UHF.” UFF, Niterói, 2015.
- [12] MOURA, M. B. “Melhoria na Predição de Cobertura de Sinal Rádio Móvel Outdoor-Indoor na Faixa de 700 MHz Através de Redes Neurais.” Dissertação de Mestrado, UFF, Niterói, 2017.
- [13] BIONDI, L. “Introdução a Redes Neurais Artificiais.” Notas de Aula: Curso de Inteligência Computacional, 2010.
- [14] POWELL, M.J.D. “Radial basis function approximations to polynomials, *Numerical Analysis 1987 Proceedings*.” Dundee, UK, 1988.

- [15] HAGAN, M. e MENHAJ, M. B. “Training Feedforward Networks with the Marquardt Algorithm.” *IEEE Transactions on Neural Networks*, v.5, n.6, 1994.
- [16] VILOVIC, I., BURUM, N. “A Comparison of MLP and RBF Neural Networks Architectures for Electromagnetic Field Prediction in Indoor Environments.” *5th European Conference on Antennas and Propagation*, 2011.
- [17] CAVALCANTI, B. “Análise de Modelos de Predição de Perdas de Propagação em Redes de Comunicações LTE e LTE-Advanced usando Técnicas de Inteligência Artificial.” Tese de Doutorado, Natal, 2017.
- [18] MAGALHÃES, D. A. B. “Análise de Cobertura Modelagem do Sinal Rádio Móvel em Ambiente com Vegetação na Faixa 700 – 4000 MHz.” Dissertação de Mestrado, UFF, Niterói, 2020.
- [19] OKUMURA, Y. “Field strength and its variability in UHF and VHF land-mobile radio service.” *Rev. Elec. Commun. Lab.*, vol. 16, 1968.
- [20] ERCEG, V., GREENSTEIN, L. J., TJANDRA, S. Y., PARKOFF, S. R., GUPTA, A., B., KULIC, A., JULIUS, A., BIANCHI, R. “An empirically based path loss model for wireless channels in suburban environments.” *Selected Areas in Communications, IEEE*, vol. 17, Issue 7, Jul 1999, pp. 1205-1211.
- [21] COST 235 “Radio Propagation Effects on Next Generation Fixed-Service Terrestrial Telecommunication Systems.” Luxembourg. Final Rep, 1996.
- [22] SEKER, S. S., SCHNEIDER, A. “Experimental Characterization of UHF Radiowave Propagation Through Forests.” *IEE Proceedings*, vol.140, N.5, pp. 329-335, October 1993.
- [23] TEWARI, R. K., SWARUP, S., ROY, M. N. “Radio Wave Propagation Through Rain Forests of India.” *IEEE Trans. Antennas Propagation*, vol. 38, N.4, pp. 443-449, 1990.
- [24] MELLO, B. R. S., PINNA, P. A., DIAS, M. S., FONSECA, F. J. B., MATOS, L. J. “Measurements in vegetation and modeling of a radio mobile channel in an urban park.” *SBrT – International Telecommunications Symposium*, São Paulo, 2014.
- [25] TORRICO, S. A., BERTONI, H.L., LANG, R. H. “Modeling Tree Effects on Path Loss in a Residential Environment.” *IEEE Trans. Antennas Propagat.*, vol.46, N.6, pp. 99-302, 1998.
- [26] MENG, Y. S., LEE, Y. H. “Investigations of foliage Effect on Modern Wireless Communication Systems: A REVIEW.” *Progress In Electromagnetics Research*, vol. 105, 2010.
- [27] CHURCHLAND, P. S., SEJNOWSKI, T. J. “The Computational Brain.” Cambridge, MA: MIT Press. 1992.

[28] SOTIROUDIS S., SIAKAVARA K., SAHALOS J., “A neural network approach to the prediction of the propagation path-loss for mobile communications systems in urban environments,” *Piers Online*, vol. 3, pp. 1175–1179, 01 2007.

[29] MASOOD, U., FAROOQ, H. “A Machine Learning Based 3D Propagation Model For Intelligent Future Cellular Networks” *IEEE Global Communications Conference (GLOBECOM)*, 2019.

Anexo A – Ajustes dos Dados

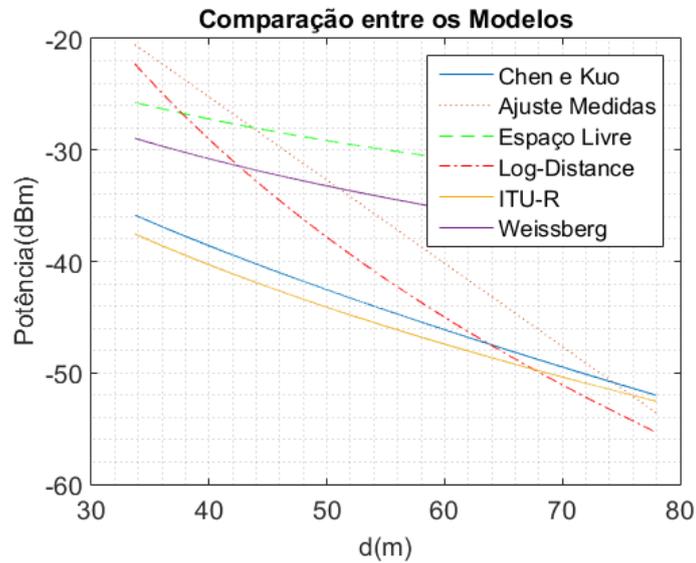
Cem primeiros conjunto de dados de entrada e saída para o percurso com altura da antena transmissora em 4,2 m, frequência de 4GHz e rota 2:

Altura Tx	Potência Tx	Frequência	Distância Tx - Rx	Potência Rx (dados de saída)
4,2	26	4000	33,7	-74,497
4,2	26	4000	33,7056	-71,303
4,2	26	4000	33,7112	-69,532
4,2	26	4000	33,7168	-68,575
4,2	26	4000	33,7224	-68,345
4,2	26	4000	33,728	-68,899
4,2	26	4000	33,7336	-70,416
4,2	26	4000	33,7392	-73,335
4,2	26	4000	33,7448	-77,988
4,2	26	4000	33,7504	-85,389
4,2	26	4000	33,756	-87,651
4,2	26	4000	33,7616	-80,902
4,2	26	4000	33,7672	-79,488
4,2	26	4000	33,7728	-78,319
4,2	26	4000	33,7784	-76,079
4,2	26	4000	33,784	-74,209
4,2	26	4000	33,7896	-74,026
4,2	26	4000	33,7952	-75,445
4,2	26	4000	33,8008	-79,077
4,2	26	4000	33,8064	-80,584
4,2	26	4000	33,812	-76,637
4,2	26	4000	33,8176	-73,584
4,2	26	4000	33,8232	-72,823
4,2	26	4000	33,8288	-73,126
4,2	26	4000	33,8344	-74,195
4,2	26	4000	33,84	-74,842
4,2	26	4000	33,8456	-74,455
4,2	26	4000	33,8512	-73,527
4,2	26	4000	33,8568	-72,866
4,2	26	4000	33,8624	-72,39
4,2	26	4000	33,868	-71,394
4,2	26	4000	33,8736	-69,913
4,2	26	4000	33,8792	-69,006
4,2	26	4000	33,8848	-68,262
4,2	26	4000	33,8904	-68,024
4,2	26	4000	33,896	-68,237

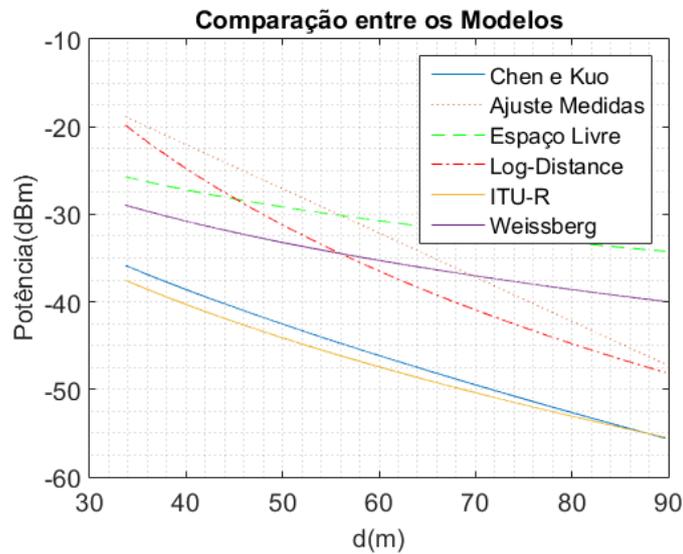
4,2	26	4000	33,9016	-68,521
4,2	26	4000	33,9072	-67,7
4,2	26	4000	33,9128	-67,22
4,2	26	4000	33,9184	-67,518
4,2	26	4000	33,924	-67,805
4,2	26	4000	33,9296	-68,241
4,2	26	4000	33,9352	-69,242
4,2	26	4000	33,9408	-71,192
4,2	26	4000	33,9464	-75,612
4,2	26	4000	33,952	-86,113
4,2	26	4000	33,9576	-84,924
4,2	26	4000	33,9632	-78,632
4,2	26	4000	33,9688	-75,336
4,2	26	4000	33,9744	-72,126
4,2	26	4000	33,98	-68,999
4,2	26	4000	33,9856	-67,232
4,2	26	4000	33,9912	-66,982
4,2	26	4000	33,9968	-67,814
4,2	26	4000	34,0024	-69,63
4,2	26	4000	34,008	-72,123
4,2	26	4000	34,0136	-74,209
4,2	26	4000	34,0192	-75,655
4,2	26	4000	34,0248	-76,91
4,2	26	4000	34,0304	-76,694
4,2	26	4000	34,036	-72,907
4,2	26	4000	34,0416	-69,516
4,2	26	4000	34,0472	-68,189
4,2	26	4000	34,0528	-69,049
4,2	26	4000	34,0584	-71,169
4,2	26	4000	34,064	-73,857
4,2	26	4000	34,0696	-75,253
4,2	26	4000	34,0752	-74,659
4,2	26	4000	34,0808	-73,786
4,2	26	4000	34,0864	-73,894
4,2	26	4000	34,092	-73,559
4,2	26	4000	34,0976	-72,756
4,2	26	4000	34,1032	-71,523
4,2	26	4000	34,1088	-71,009
4,2	26	4000	34,1144	-71,1
4,2	26	4000	34,12	-70,05
4,2	26	4000	34,1256	-67,938
4,2	26	4000	34,1312	-66,22
4,2	26	4000	34,1368	-65,496
4,2	26	4000	34,1424	-65,584
4,2	26	4000	34,148	-66,39

4,2	26	4000	34,1536	-67,382
4,2	26	4000	34,1592	-68,542
4,2	26	4000	34,1648	-69,383
4,2	26	4000	34,1704	-68,969
4,2	26	4000	34,176	-67,24
4,2	26	4000	34,1816	-65,556
4,2	26	4000	34,1872	-64,562
4,2	26	4000	34,1928	-63,93
4,2	26	4000	34,1984	-63,553
4,2	26	4000	34,204	-63,33
4,2	26	4000	34,2096	-63,307
4,2	26	4000	34,2152	-63,559
4,2	26	4000	34,2208	-64,152
4,2	26	4000	34,2264	-65,062
4,2	26	4000	34,232	-65,974
4,2	26	4000	34,2376	-66,237
4,2	26	4000	34,2432	-65,812
4,2	26	4000	34,2488	-65,448
4,2	26	4000	34,2544	-65,366

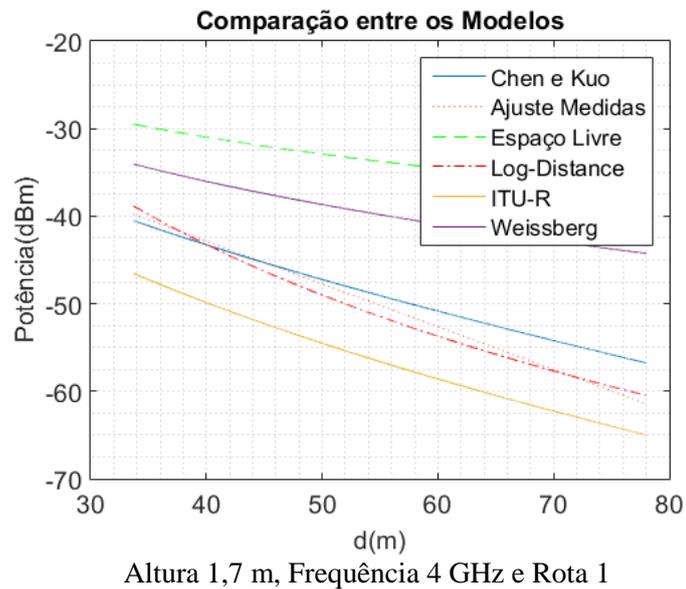
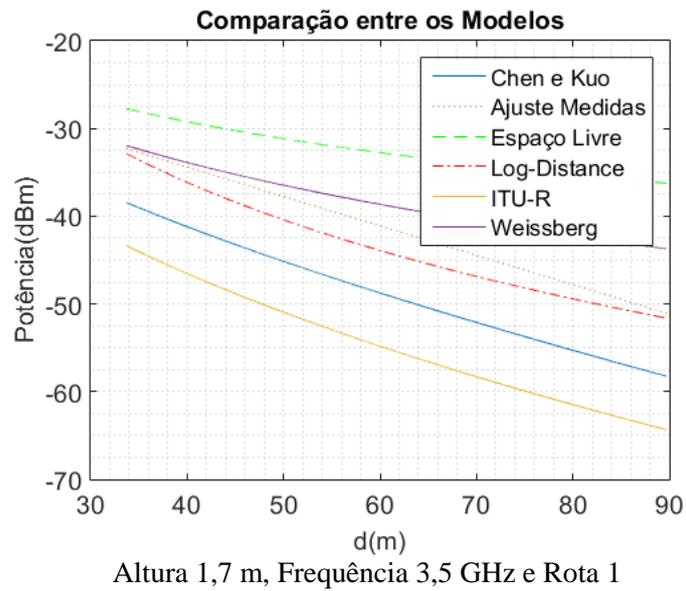
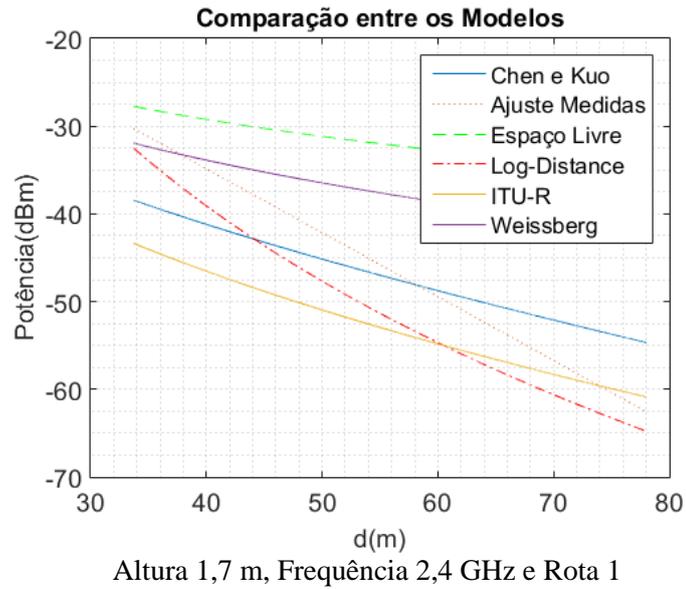
Anexo B – Gráficos Comparativos dos Modelos de Predição

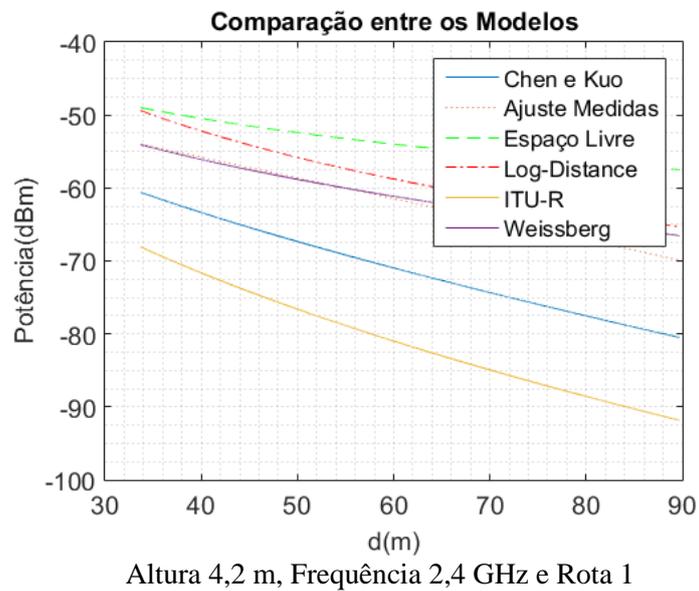
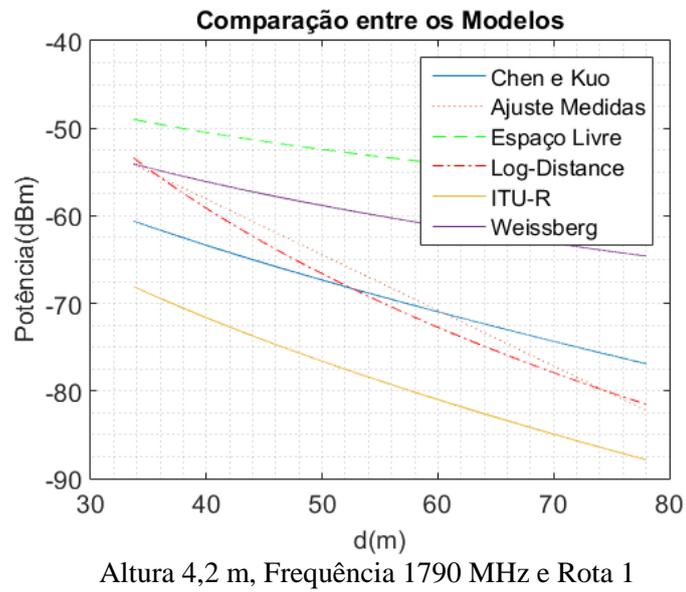
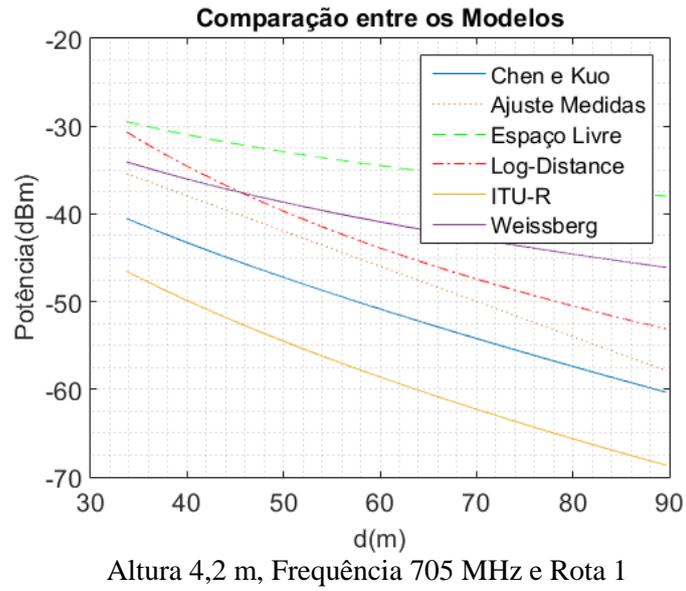


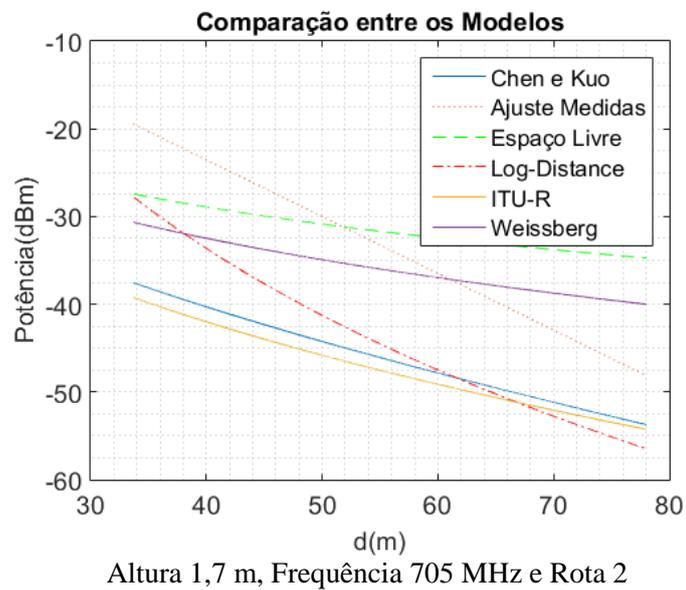
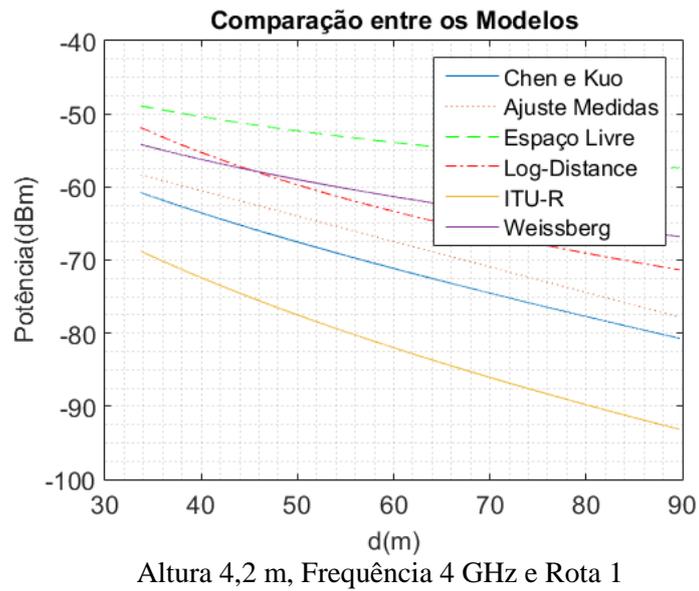
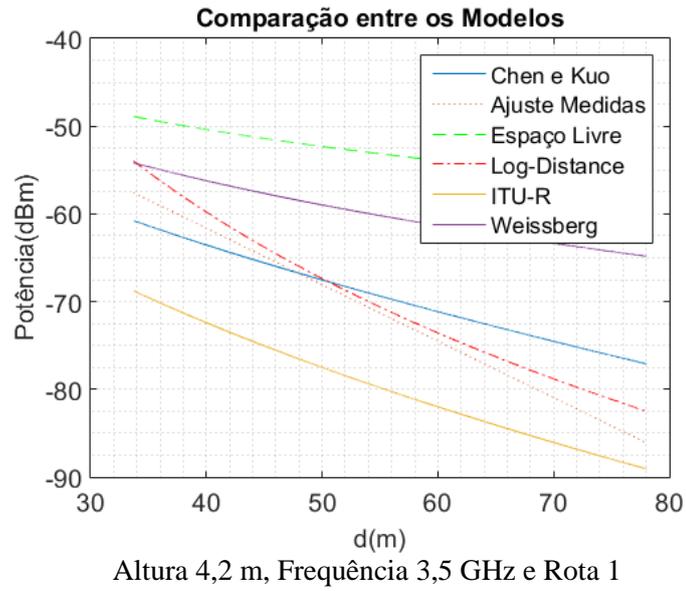
Altura 1,7 m, Frequência 705 MHz e Rota 1

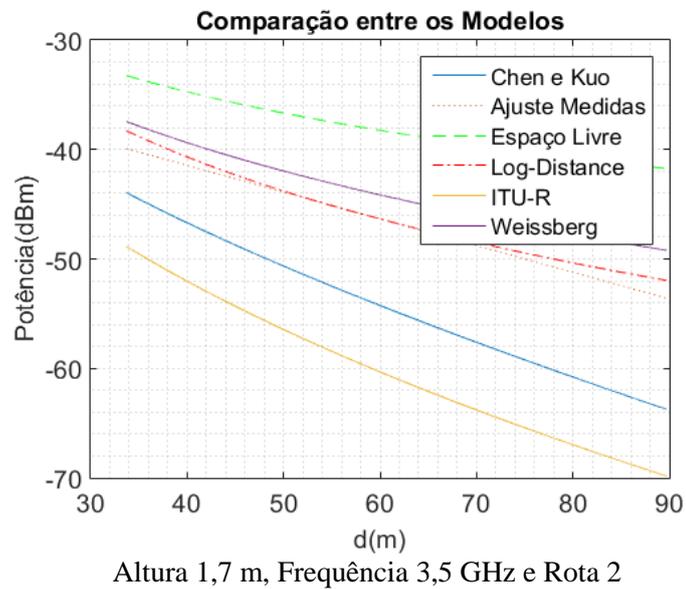
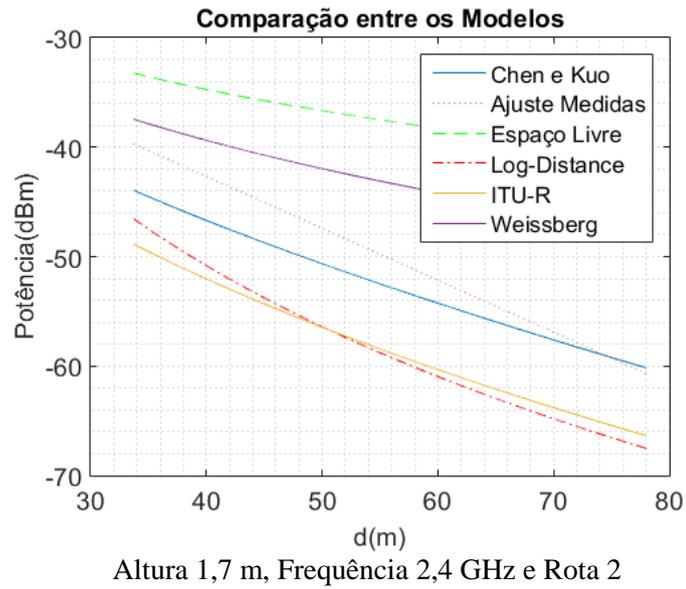
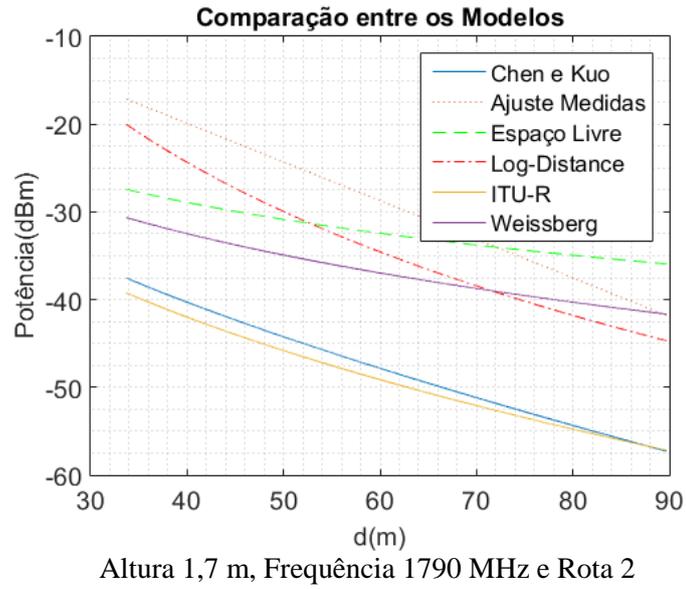


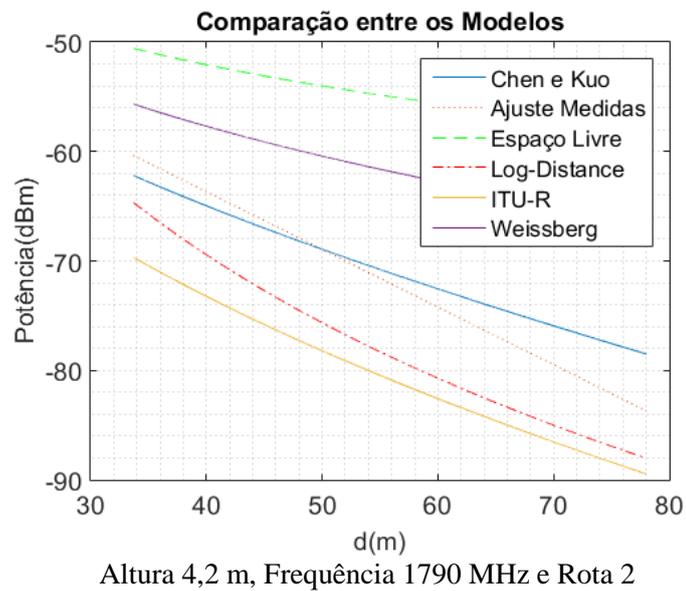
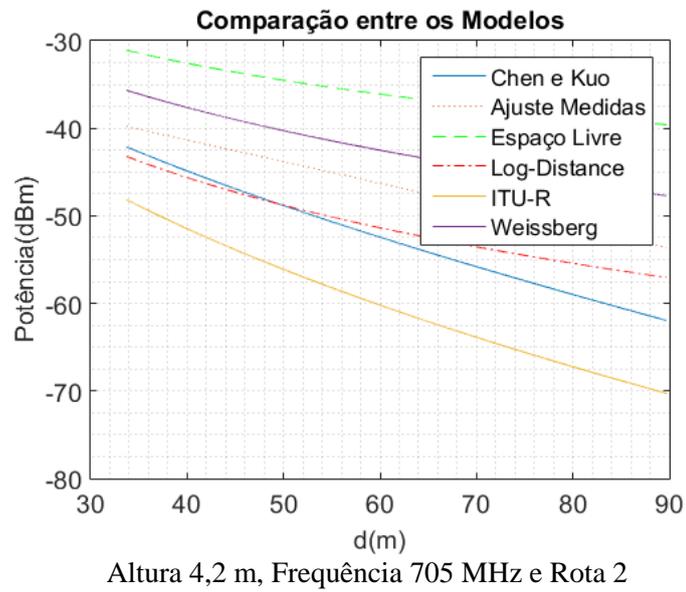
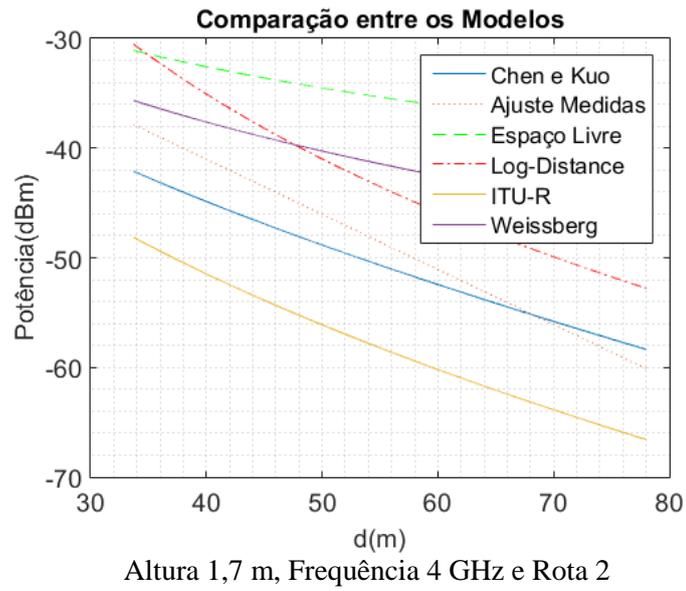
Altura 1,7 m, Frequência 1790 MHz e Rota 1

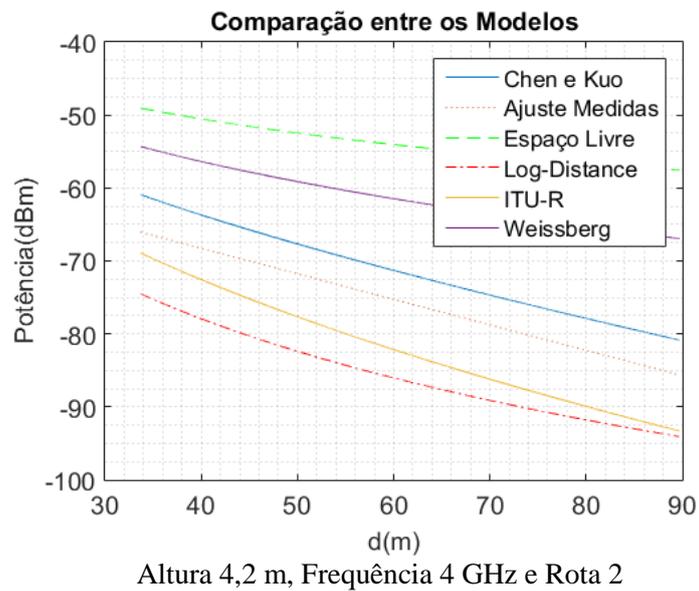
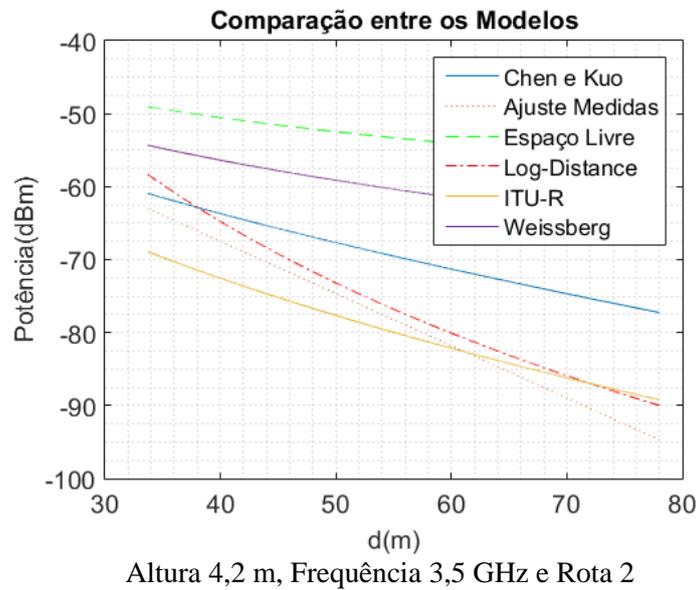
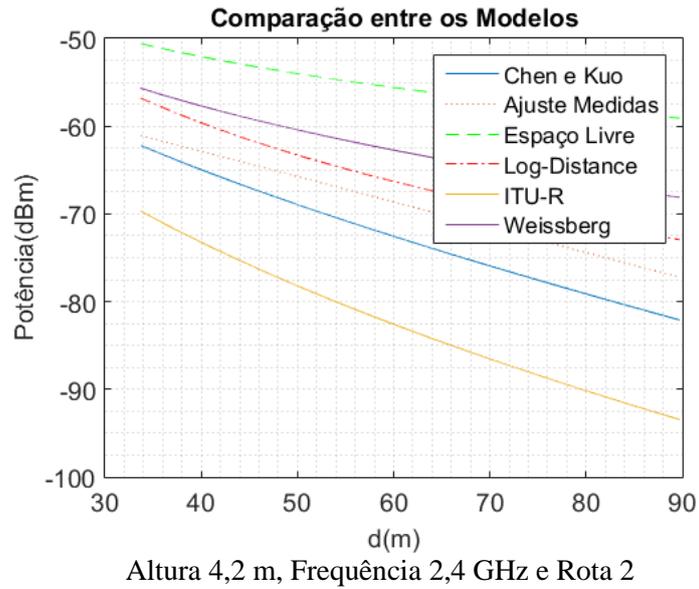












Anexo C – Código da Rede Neural Artificial

Rede neural com divisão 80% 10% 10%:

```
%%FEED FOWARD BACKPROPAGATION%%
clear all
close all
input_treinamento = xlsread('Input_100%dosdados_total.xlsx');
target_treinamento = xlsread('Target_100%dosdados_total.xlsx');

%%Criação da rede neural%%
TransFcn = {'tansig'};
TrainFcn = 'trainlm'; neuronios = [22];
rede = feedforwardnet(neuronios);

%%Divisão dos parâmetros de treinamento, validação e teste%%
rede.trainParam.min_grad = 1e-13;
rede.trainParam.mu = 0.001;
rede.trainParam.mu_dec = 0.1;
rede.trainParam.mu_inc = 10;
rede.trainParam.lr = 0.9;
rede.trainParam.mu_max = 1e15;
rede.trainParam.epochs = 1000;
rede.trainParam.goal = 1e-3;
rede.trainParam.max_fail = 70;
rede.divideParam.trainRatio = 80/100;
rede.divideParam.valRatio = 10/100;
rede.divideParam.testRatio = 10/100;

%%Treinamento%%
[rede,tr] = train(rede,input_treinamento',target_treinamento')
outputs = sim(rede,input_treinamento');
output_rede = rede(input_treinamento');
```

```
% Plot  
figure  
plotperf(tr)  
figure  
plotfit(rede,input_treinamento,target_treinamento)  
figure  
plotregression(target_treinamento,outputs)
```