

UNIVERSIDADE FEDERAL FLUMINENSE
ESCOLA DE ENGENHARIA
MESTRADO EM ENGENHARIA DE TELECOMUNICAÇÕES

GILBERT PONCIANO FERREIRA

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS COMO AUXÍLIO À PREDIÇÃO DE
COBERTURA DE SINAIS RÁDIO MÓVEIS NA FAIXA DE UHF

NITERÓI
2015

GILBERT PONCIANO FERREIRA

APLICAÇÃO DE REDES NEURAS ARTIFICIAIS COMO AUXÍLIO À PREDIÇÃO DE
COBERTURA DE SINAIS RÁDIO MÓVEIS NA FAIXA DE UHF

Dissertação apresentada ao Curso de Mestrado em Engenharia de Telecomunicações da Universidade Federal Fluminense, como requisito parcial para obtenção do Grau de Mestre. Área de Concentração: Sistemas de Telecomunicações.

Orientadora: Leni Joaquim de Matos, D. C.
Coorientador: João Marcos Meirelles da Silva, D. C.

NITERÓI
2015

Ficha Catalográfica elaborada pela Biblioteca da Escola de Engenharia e Instituto de Computação da UFF

F383 Ferreira, Gilbert Ponciano

Aplicação de redes neurais artificiais como auxílio à predição de cobertura de sinais rádio móveis na faixa de UHF / Gilbert Ponciano Ferreira. – Niterói, RJ : [s.n.], 2015.

105 f.

Dissertação (Mestrado em Engenharia de Telecomunicações) - Universidade Federal Fluminense, 2015.

Orientadores: Leni Joaquim de Matos, João Marcos Meirelles da Silva.

1. Sistema de telecomunicação. 2. Rede neural artificial. 3. UHF. 4. Canal rádio móvel. I. Título.

CDD 621.382

GILBERT PONCIANO FERREIRA

Aplicação de Redes Neurais Artificiais como Auxílio à Predição de Cobertura de Sinais
Rádio Móveis na Faixa de UHF

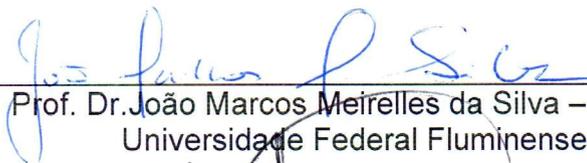
Dissertação apresentada ao Curso de
Mestrado em Engenharia de
Telecomunicações da Universidade Federal
Fluminense, como requisito parcial para
obtenção do Grau de Mestre. Área de
Concentração: Sistemas de
Telecomunicações.

Aprovado em 02 de fevereiro de 2015.

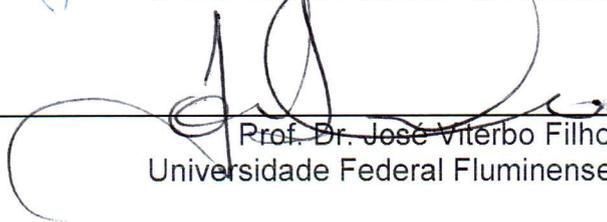
BANCA EXAMINADORA



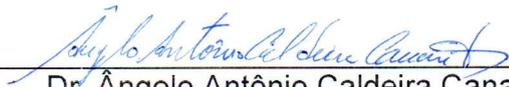
Prof.Dra. Leni Joaquim de Matos – Orientadora
Universidade Federal Fluminense - UFF



Prof. Dr. João Marcos Meirelles da Silva – Co-orientador
Universidade Federal Fluminense - UFF



Prof. Dr. José Viterbo Filho
Universidade Federal Fluminense - UFF



Dr. Ângelo Antônio Caldeira Canavitsas
Petrobras

Agradecimentos

Gostaria de agradecer a minha orientadora de monitoria, projeto final de curso e dissertação de mestrado, Leni Joaquim de Matos, pelos ensinamentos repassados, pelos projetos de pesquisa em que participamos, por incentivar o meu desenvolvimento acadêmico e, principalmente, por me tornar um profissional melhor.

Aos meus familiares, em especial à minha esposa Eng. Mariana Schaefer por revisar e colaborar em todas as etapas deste estudo e ao Brunno Bernardi e Bruna Gomes Coelho pela crucial ajuda no processamento dos dados medidos.

Agradeço a todos que, de alguma forma, também contribuíram para a elaboração desta dissertação de mestrado e pelas instituições UFF, PUC/RJ e INMETRO que disponibilizaram todos os equipamentos de medição, imprescindíveis para a realização desta pesquisa.

Prof. D. C. João Marcos Meirelles da Silva – UFF

Prof. D. C. Tadeu Nagashima Ferreira – UFF

Prof. D. C. Edson Luiz Cataldo Ferreira – UFF

Prof. D. C. Murilo Bresciani de Carvalho – UFF

Eng. D. C. Willyan David Torres Meza – PUC/RJ

Eng. M. C. Pressley Xavier Neto – UFF

Eng. Raymundo Isaac Chapermann – PETROBRAS

Eng. D. C. Ângelo Canavitsas - PETROBRAS

Obrigado a todos!
Gilbert Ponciano Ferreira

SUMÁRIO

LISTA DE FIGURAS.....	7
LISTA DE TABELAS.....	9
GLOSSÁRIO.....	10
RESUMO	11
ABSTRACT	12
1 INTRODUÇÃO.....	13
1.1 MOTIVAÇÃO.....	13
1.2 OBJETIVO DO TRABALHO.....	14
1.3 ESTRUTURA DA DISSERTAÇÃO	14
2 PREDIÇÃO DE COBERTURA	16
2.1 TIPOS DE PROPAGAÇÃO	16
2.1.1 <i>Propagação no espaço livre</i>	16
2.1.2 <i>Propagação por reflexão</i>	17
2.1.3 <i>Propagação por difração</i>	19
2.1.3.1 Princípio de Huygens.....	19
2.1.3.2 Zonas e Elipsoides de Fresnel.....	20
2.2 MODELOS DE PREDIÇÃO.....	22
2.2.1 <i>Predição Ponto-Área</i>	23
2.2.1.1 Modelo de Okumura	24
2.2.1.2 Modelo de Okumura-Hata	24
2.2.1.3 Modelo de Cost 231-Hata	24
2.2.1.4 Modelo de Ikegami.....	25
2.2.1.5 Modelo de Walfisch-Bertoni	25
2.2.1.6 Modelo de COST-Walfisch-Ikegami	26
2.2.1.7 Modelo de Lee.....	26
2.2.2 <i>Predição Ponto-a-Ponto</i>	27
2.2.2.1 Recomendação 526 - UIT-R	27
2.2.2.2 Difração sobre obstáculos isolados	28
a) Obstáculo do tipo Gume de Faca (<i>Knife Edge</i>).....	28
b) Obstáculo do tipo Arredondado.....	31
2.2.2.3 Conceito de terra lisa e ganho de obstáculo	33
2.2.2.4 Difração sobre Terra Esférica	33
2.2.2.5 Difração sobre múltiplos obstáculos	34
a) Modelo de Deygout	34
b) Modelo Epstein-Peterson.....	35
c) Modelo Giovanelli	36
d) Modelo <i>Cascade Knife Edge</i> (UIT-R 526-11).....	36
e) Modelo de Bullington.....	37
i) Correção empírica e correção “taper”	39
ii) Correção C2.....	39
f) Modelo Delta-Bullington (UIT-R 526-12).....	40
2.2.3 <i>Conclusões sobre aplicação dos modelos</i>	41
3 MEDIÇÕES EM CAMPO	42
3.1 LOCAL DAS MEDIÇÕES	42
3.2 <i>SETUP</i> DE MEDIÇÕES.....	45
3.2.1 <i>Fonte de Alimentação</i>	45
3.2.2 <i>Gerador de RF</i>	45

3.2.3	<i>Amplificador de Potência</i>	46
3.2.4	<i>Antenas de Transmissão e Recepção</i>	46
3.2.5	<i>Low Noise Amplifier - LNA</i>	47
3.2.6	<i>Analizador de Espectro</i>	47
3.2.7	<i>Receptor de GPS</i>	48
3.2.8	<i>Interface de aquisição de dados</i>	48
3.3	PARÂMETROS BÁSICOS DAS MEDIÇÕES.....	49
3.4	PROCEDIMENTOS PARA REALIZAÇÃO DAS MEDIÇÕES	49
4	COMPARAÇÃO DAS MEDIÇÕES COM AS PREDIÇÕES	52
4.1	PROCESSAMENTO DOS DADOS OBTIDOS	52
4.2	ANÁLISE DAS MEDIDAS.....	57
4.3	COMPARAÇÃO COM VALORES TEÓRICOS	58
4.4	ANÁLISE ESTATÍSTICA DOS DADOS.....	61
5	IMPLEMENTAÇÃO DAS REDES NEURAIS ARTIFICIAIS	65
5.1	OBJETIVO DAS REDES NEURAIS NO TRABALHO PROPOSTO	65
5.1.1	<i>Utilização de RNAs para Predição de Cobertura</i>	65
5.1.2	<i>Vantagens e Desvantagens na utilização das RNAs</i>	66
5.2	TREINAMENTO DA REDE.....	66
5.2.1	<i>Base de Dados</i>	67
5.2.2	<i>Ambiente de Simulação</i>	67
5.3	RESUMO DOS PARÂMETROS DAS RNAs.....	68
5.4	FUNCIONAMENTO DAS RNAs	69
6	RESULTADOS	73
6.1	UNIFICAÇÃO DOS DADOS.....	73
6.2	ANÁLISE ESTATÍSTICA DOS DADOS.....	74
6.3	COMPARAÇÃO DO DESEMPENHO COM TESTE CRUZADO.....	75
6.4	CONSOLIDAÇÃO DOS TESTES	76
6.5	AVALIAÇÃO INDIVIDUAL DE DESEMPENHO	78
6.5.1	<i>Diferença da Base de Dados (BD)</i>	79
6.5.2	<i>Diferença de Neurônios</i>	81
6.5.3	<i>Diferença de Entradas</i>	83
7	CONCLUSÃO E TRABALHOS FUTUROS	85
8	REFERÊNCIAS	87
9	APÊNDICE	90
9.1	ALGORITMO <i>MATLAB</i> DE CRIAÇÃO E TREINAMENTO DO GRUPO 01	90
9.2	ALGORITMO <i>MATLAB</i> DE CRIAÇÃO E TREINAMENTO DO GRUPO 02	95
9.3	ALGORITMO <i>MATLAB</i> DO TESTE CRUZADO	100
9.4	LOCAL DAS MEDIÇÕES COM AS 2 ROTAS PLOTADAS.	104

LISTA DE FIGURAS

FIGURA 2-1 - RADIOENLACE COM LINHA DE VISADA DIRETA. [1].....	16
FIGURA 2-2 - REFLEXÃO SOBRE SUPERFÍCIE REGULAR. [1]	17
FIGURA 2-3 - REFLEXÃO SOBRE SUPERFÍCIE IRREGULAR. (FONTE: GOOGLE)	18
FIGURA 2-4 - FONTES DE ONDAS SECUNDÁRIAS GERADAS DEVIDO AOS OBSTÁCULOS. (FONTE: GOOGLE)	20
FIGURA 2-5 - TODA A SUPERFÍCIE DA FRENTE DE ONDA CONSIDERADA UM IRRADIADOR ELEMENTAR. [3].....	21
FIGURA 2-6 - ZONAS DE FRESNEL. [3]	21
FIGURA 2-7 - ELIPSOIDES DE FRESNEL. [1].....	22
FIGURA 2-8 – GEOMETRIA DO OBSTÁCULO INTERCEPTANDO A LOS. [14].....	29
FIGURA 2-9 – GEOMETRIA DO OBSTÁCULO SEM INTERCEPTAR A LOS. [14]	29
FIGURA 2-10 - ATENUAÇÃO DO OBSTÁCULO GUME DE FACA. [14]	30
FIGURA 2-11 – GEOMETRIA DE UM OBSTÁCULO ARREDONDADO. [14]	31
FIGURA 2-12 – PERFIL VERTICAL DO OBSTÁCULO ARREDONDADO. [14].....	33
FIGURA 2-13 – LINHA DE VISADA PARA CÁLCULO DO CAMPO DIFRATADO POR DEYGOUT. [18]	34
FIGURA 2-14 – GEOMETRIA DA LINHA DE VISADA PARA DO MODELO EPSTEIN-PETERSON. [19]	35
FIGURA 2-15 – GEOMETRIA DA LINHA DE VISADA DO MODELO GIOVANELLI. [20]	36
FIGURA 2-16 - GERAÇÃO DE OBSTÁCULO EQUIVALENTE. [23]	38
FIGURA 2-17 – SITUAÇÃO COM LINHA DE VISADA. [23]	38
FIGURA 2-18 – SITUAÇÃO COM APENAS UM OBSTÁCULO. [23]	38
FIGURA 3-1 – REGIÃO DE CAMPO GRANDE – RJ. (FONTE: <i>GOOGLE EARTH</i>)	42
FIGURA 3-2 – MORFOLOGIA DO TERRENO DE CAMPO GRANDE – RJ. [26]	43
FIGURA 3-3 – TOPOGRAFIA DO TERRENO DE CAMPO GRANDE – RJ. [26].....	44
FIGURA 3-4 – VISÃO 3D DO TERRENO DE CAMPO GRANDE – RJ. [26]	44
FIGURA 3-5 – FONTE DE ALIMENTAÇÃO PARA ALIMENTAR O PA.....	45
FIGURA 3-6 - TRANSMISSOR R&S.....	45
FIGURA 3-7 – AMPLIFICADOR DE ALTA POTÊNCIA.	46
FIGURA 3-8 - ANTENA DISCÔNICA UTILIZADA PARA TRANSMISSÃO.....	46
FIGURA 3-9 – ANTENA MONOPOLO PARA RECEPÇÃO.	47
FIGURA 3-10 – <i>LOW NOISE AMPLIFIER</i>	47
FIGURA 3-11 - ANALISADOR DE EPECTRO UTILIZADO NA RECEPÇÃO.	48
FIGURA 3-12 - GPS UTILIZADO NAS MEDIÇÕES.....	48
FIGURA 3-13 – INTERFACE UTILIZADA NA RECEPÇÃO DOS DADOS.....	49
FIGURA 3-14 – BANCADA DE TRANSMISSÃO.	50
FIGURA 3-15 – VIATURA UTILIZADA PARA RECEPÇÃO.	50
FIGURA 3-16 – BANCADA DE RECEPÇÃO.	50
FIGURA 3-17 – ESQUEMÁTICO DO SISTEMA DE MEDIÇÃO.	51
FIGURA 3-18 – PORTADORA DO SINAL TRANSMITIDO VISTA NO ANALISADOR DE ESPECTRO MS2034A.	51
FIGURA 4-1 - PONTOS MEDIDOS DA ROTA 1. (FONTE: <i>GOOGLE EARTH</i>)	52
FIGURA 4-2 - PONTOS MEDIDOS DA ROTA 2. (FONTE: <i>GOOGLE EARTH</i>)	52
FIGURA 4-3 – GERADOR DE SINAIS RECONFIGURADO.	54
FIGURA 4-4 – INTERFACE ENTRE GERADOR E O ANALISADOR.....	55
FIGURA 4-5 – MULTÍMETRO UTILIZADO NA MEDIÇÃO DA SAÍDA DO ANALISADOR.....	55
FIGURA 4-6 – CURVA DE CALIBRAÇÃO DO ANALISADOR ANRITSU MS2781B.	56
FIGURA 4-7 - GRÁFICO DA ROTA 1 NAS RUAS DE CAMPO GRANDE.....	58
FIGURA 4-8 - GRÁFICO DA ROTA 2 SEGUINDO PELA AV. BRASIL.	58
FIGURA 4-9 – GRÁFICO COMPARATIVO DA ROTA 1.	60

FIGURA 4-10 - GRÁFICO COMPARATIVO DA ROTA 2.	61
FIGURA 4-11 – EXEMPLO DE UM PERFIL DE ENLACE COM MORFOLOGIA. [26].....	61
FIGURA 4-12 – GRÁFICO DOS DESVIOS DA ROTA 1.....	62
FIGURA 4-13 - GRÁFICO DOS DESVIOS DA ROTA 2.	63
FIGURA 4-14 - GRÁFICO COMPARATIVO DA MÉDIA DOS DESVIOS NAS DUAS ROTAS.	63
FIGURA 5-1 – ESQUEMÁTICO DO FUNCIONAMENTO DA RNA.	68
FIGURA 5-2 - ORGANIZAÇÃO DAS RNAs DA ROTA 1.....	69
FIGURA 5-3 - ORGANIZAÇÃO DAS RNAs DA ROTA 2.....	71
FIGURA 5-4 - CONFIGURAÇÃO COM 2 ENTRADAS E 10 NEURÔNIOS. (FONTE: MATLAB).....	71
FIGURA 5-5 – ESQUEMÁTICO DO TREINAMENTO DE CADA RNA.	72
FIGURA 6-1 - COMPARATIVO ENTRE A RNA 4 E OS VALORES MEDIDOS.....	74
FIGURA 6-2 - COMPARATIVO DE DESEMPENHO DO GRUPO 1.	77
FIGURA 6-3 - COMPARATIVO DE DESEMPENHO DO GRUPO 2.	78
FIGURA 6-4 - COMPARATIVO DE DESEMPENHO DA BD DAS RNAs DO GRUPO 1.	79
FIGURA 6-5 - COMPARATIVO DE DESEMPENHO DA BD DAS RNAs DO GRUPO 2.	80
FIGURA 6-6 - COMPARATIVO DE DESEMPENHO DE NEURÔNIOS DAS RNAs DO GRUPO 1.	81
FIGURA 6-7 - COMPARATIVO DE DESEMPENHO DE NEURÔNIOS DAS RNAs DO GRUPO 2.	82
FIGURA 6-8 - COMPARATIVO DE DESEMPENHO DE <i>INPUTS</i> DAS RNAs DO GRUPO 1.....	83
FIGURA 6-9 - COMPARATIVO DE DESEMPENHO DE <i>INPUTS</i> DAS RNAs DO GRUPO 2.....	84

LISTA DE TABELAS

TABELA 2-1 – VALORES DO COEFICIENTE DE REFLEXÃO PARA DIFERENTES OCASIÕES.	18
TABELA 3-1 - PARÂMETROS BÁSICOS DO SISTEMA.	49
TABELA 4-1 - TABELA COM OS PRIMEIROS PONTOS MEDIDOS DA ROTA 1.	56
TABELA 4-2 - TABELA COM OS PRIMEIROS PONTOS MEDIDOS DA ROTA 2.	57
TABELA 4-3 – TABELA COMPARATIVA COM OS MÉTODOS DA UIT-R PARA A ROTA 1.	59
TABELA 4-4 – MÉTRICA D APLICADA NAS ROTA 1 E ROTA 2.	62
TABELA 4-5 – COMPARAÇÃO ESTATÍSTICA DA ROTA 1 E 2.	63
TABELA 6-1 – TABELA COMPARATIVA UNIFICADA DA ROTA 1.	73
TABELA 6-2 – TABELA COMPARATIVA UNIFICADA DA ROTA 2.	73
TABELA 6-3 – MÉTRICA D DAS RNAs DO GRUPO 1 APLICADAS NA ROTA 1.	74
TABELA 6-4 – MÉTRICA D DAS RNAs DO GRUPO 2 APLICADAS NA ROTA 2.	75
TABELA 6-5 – MÉTRICA D DAS RNAs DO GRUPO 1 APLICADAS NA ROTA 2.	76
TABELA 6-6 – MÉTRICA D DAS RNAs DO GRUPO 2 APLICADAS NA ROTA 1.	76
TABELA 6-7 – DESVIOS MÉDIOS DE TODOS OS MÉTODOS NAS DUAS ROTAS.	77

GLOSSÁRIO

ANATEL – Agência Nacional de Telecomunicações.

C.K.E – *Cascade Knife Edge* (Gume de Faca em Cascata)

D.B – Delta-Bullington.

ERB – Estação Rádio Base.

LNA – *Low Noise Amplifier* (Amplificador de Baixo Ruído)

LOS – *Line of Sight* (Linha de Visada)

MLP - *Multilayer Perceptron* (*Perceptron* de Múltiplas Camadas)

NLOS – *No Line of Sight* (Sem linha de Visada)

PA – *Power Amplifier* (Amplificador de Potência)

RF – Radiofrequência.

RNA – Redes Neurais Artificiais.

UHF – *Ultra High Frequency* (Frequência Ultra Alta)

UIT-R – União Internacional de Telecomunicações – Radiocomunicação.

VHF – *Very High Frequency* (Frequência Muito Alta)

RESUMO

Com a crescente demanda por maiores velocidades e variedade de serviços, as empresas de telecomunicações disputam um mercado altamente competitivo. Para acompanhar este ritmo acelerado, as operadoras realizam uma série de investimentos para atualização de sua infraestrutura e, principalmente, expansão de seus serviços sem fio para o máximo possível de regiões em todo o território nacional. Baseado nesse contexto, quanto mais preciso for o planejamento das futuras expansões, mais otimizado e direcionado será o investimento, garantindo plena cobertura em regiões de difícil acesso.

Almejando uma melhor predição para sinais de rádio móveis na faixa de UHF, este trabalho parte de medições realizadas em campo e compara os valores medidos com os valores preditos utilizando as Recomendações da UIT-R, presentes em ferramentas de predição de cobertura disponíveis no mercado. São analisados o desempenho dos dois métodos de cálculo de difração presentes na Recomendação 526-11 e 526-12, de 2011 e 2012, verificando se o atual método recomendado apresenta melhor aderência ao tipo de topografia do Brasil.

Numa segunda etapa, a aplicação das redes neurais artificiais é realizada inserindo não só os dados medidos, como também, os dados obtidos utilizando os métodos recomendados pela UIT-R, com o objetivo de aperfeiçoar o desempenho dos atuais métodos e buscando, também, tentar identificar quais parâmetros possam ser fundamentais nesta melhoria.

Palavras-chave: predição de cobertura, redes neurais artificiais, cobertura de sinal em UHF

ABSTRACT

Telecommunications companies face a highly competitive market with the increasing demand for higher speed and range of services. In order to meet the ever-increasing demands, companies perform a number of investments to upgrade infrastructure and expand wireless services for attaining a maximum regional coverage across the country. Based on this context, a more accurate planning for investment and future expansions, designed to be more optimized and targeted, is necessary, ensuring full coverage in areas of difficult access.

The first step of this study was to conduct signal level measurements in the range of Ultra High Frequency (UHF), comparing the measured values with the calculated values, using the ITU recommendations, as available in the prediction software. Further analysis were carried out on the performance of the most recent diffraction calculation methods present in recommendation 526 (2011 and 2012), ensuring that the current recommended method has better adhesion to the natural terrain topography of Brazil.

The second step was the application of artificial neural networks using measured data, as well as the data obtained using the recommended ITU-R methods, with the aim of improving the performance of existing methods, so that we can identify which parameters are critical for this improvement.

Keywords: coverage prediction, artificial neural networks, signal coverage in UHF.

1 INTRODUÇÃO

Com a crescente demanda por maiores velocidades e variedade de serviços, as empresas de telecomunicações disputam um mercado altamente competitivo. Para atender esse novo mercado, as operadoras realizam uma série de investimentos para atualização de sua infraestrutura com objetivo de oferecer novas modalidades de serviços presentes no mercado mundial atual e, principalmente, garantir maior cobertura, o que aumenta consideravelmente sua base de clientes, devendo utilizar o menor número possível de estações rádio base (ERB), pois estas geram um alto custo de investimento.

Além dessa evolução natural das tecnologias, o Brasil conta com a Agência Nacional de Telecomunicações (ANATEL), que tem como uma das principais premissas defender os direitos dos usuários brasileiros, exigindo que toda empresa de telecomunicações atenda metas de universalização e de qualidade, podendo ser severamente penalizada pelo descumprimento, garantindo, assim, uma constante necessidade de investimentos no setor.

1.1 MOTIVAÇÃO

A motivação deste trabalho surgiu da necessidade de grandes investimentos por parte das operadoras de telecomunicações, de modo a garantirem uma boa colocação no mercado. Um dos maiores gastos das empresas, além da compra de equipamentos mais modernos, é a compra de insumos das ferramentas de planejamento que devem incluir bases de dados dos territórios de interesse, mapas precisos com a morfologia das cidades, Recomendações mais recentes da União Internacional de Telecomunicações - Radiocomunicação (UIT-R), como, também, fatores de qualidade mínimos para atender os critérios da ANATEL.

Além dos altos investimentos em infraestrutura, tanto na Rede de Acesso quanto na Rede *Core*, são necessárias rotinas de operação e manutenção do sistema planejado a fim de garantir o pleno atendimento das leis e a qualidade de serviço, que é medido, principalmente, pela satisfação dos usuários.

Baseado nesse contexto, quanto mais preciso for o planejamento do sistema, mais otimizado e direcionado será o investimento e menores serão os gastos posteriores com as rotinas supracitadas.

1.2 OBJETIVO DO TRABALHO

O principal objetivo deste trabalho é continuar as atividades do trabalho final de curso [1] [2], onde foram realizadas, durante a graduação, medições em campo na faixa de VHF (*Very High Frequency*) para aplicação de 4 métodos de cálculo de difração ponto a ponto, Bullington, Epstein-Peterson, Gume de Faca e Deygout. Neste mesmo estudo foram utilizadas Redes Neurais Artificiais (RNAs) como alternativa aos modelos existentes, a fim de verificar o melhor desempenho entre eles.

A primeira etapa deste estudo é a realização de medições em campo, na faixa de UHF (*Ultra High Frequency*), comparando os valores obtidos com os valores calculados utilizando as Recomendações da UIT-R, através dos métodos Gume de Faca em Cascata (*Cascade Knife Edge C.K.E*) e Delta Bullington, presentes em ferramentas de predição de cobertura disponíveis no mercado, e verificar qual deles apresenta menores desvios.

A segunda etapa é aplicar as RNAs na predição de cobertura, utilizando em seu treinamento parâmetros gerados no método que apresentou menor desvio, e testar algumas configurações possíveis de redes, com a finalidade de verificar o desempenho de cada uma delas, buscando, entre elas, além do aperfeiçoamento da predição do método da UIT-R, a identificação de quais parâmetros podem ser fundamentais nesta melhoria.

1.3 ESTRUTURA DA DISSERTAÇÃO

Um embasamento teórico é apresentado para o desenvolvimento do objetivo proposto neste trabalho, que está estruturado da seguinte forma:

- Capítulo 2 – apresenta os conceitos básicos sobre predição de cobertura, englobando alguns métodos de predição ponto-a-ponto e ponto-multiponto em suas principais aplicações.
- Capítulo 3 – mostra os fundamentos e montagem do experimento de propagação. Descreve, com detalhes, os componentes utilizados, as limitações encontradas e soluções aplicadas.
- Capítulo 4 – detalha todas as etapas do processamento dos dados obtidos em campo, com a preparação e organização dos mesmos para predição teórica e comparação dos valores, bem como aplicação de

análise estatística para verificação do desempenho dos modelos empregados.

- Capítulo 5 – apresenta os conceitos básicos resumidos das RNAs, que serão utilizadas no trabalho, e detalha a construção e aplicação das redes utilizadas neste estudo.
- Capítulo 6 – com os resultados obtidos através da utilização das técnicas recomendadas pela UIT-R e aplicação das RNAs é possível avaliar o desempenho geral das redes e verificar se o objetivo de aperfeiçoar a predição de cobertura foi alcançado.
- Capítulo 7 – apresenta as considerações finais e sugestões para trabalhos futuros.

2 PREDIÇÃO DE COBERTURA

A UIT é uma grande fomentadora do uso das mais recentes tecnologias de telecomunicações, servindo como referência para engenheiros e órgãos regulamentadores de todo o mundo.

Para o planejamento eficaz da cobertura dos sistemas de telecomunicações sem fio usa-se, como premissa, as Recomendações da UIT-R, que através da subseção de radiopropagação detalha os métodos de predição com suas respectivas características e aplicações, que foram inseridas ao longo dos anos, em diversos programas computacionais.

O objetivo de cada modelo é recriar, através de expressões matemáticas, fenômenos comuns às transmissões sem fio, e aplicá-los de forma prática em equipamentos e serviços. Este planejamento é muito importante, pois permite maximizar a capacidade da rede, o que retorna grandes benefícios econômicos relacionados à implantação dos sistemas nas cidades.

2.1 TIPOS DE PROPAGAÇÃO

2.1.1 Propagação no espaço livre

Este tipo de propagação é o mais básico, onde, tanto o emissor quanto o receptor estão com ausência de obstruções ao longo do caminho (*Line of Sight - LOS*) e sem perturbações na recepção do sinal, como mostrado na Figura 2-1. Embora seja o modo mais simples e particular, o seu entendimento é a base do cálculo para propagações em outros tipos de ambiente.

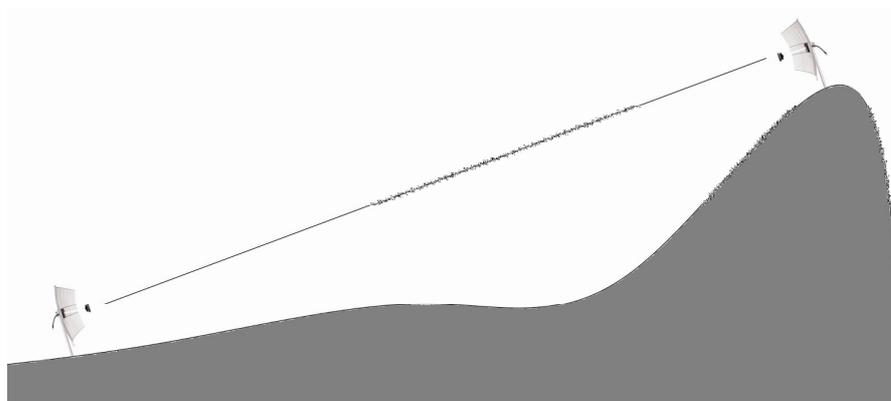


Figura 2-1 - Radioenlace com linha de visada direta. [1]

Para calcular a atenuação do sinal, necessita-se determinar a relação entre a potência recebida e a potência transmitida. Inicialmente, calcula-se a propagação entre antenas isotrópicas (irradiação uniforme em qualquer direção) e, posteriormente, são avaliadas outras antenas, inserindo-se o ganho destas [3].

A equação que descreve a perda do espaço livre é:

$$L_{[dB]} = 92,44 + 20 \log(d) + 20 \log(f) + G_{TX} + G_{RX} \quad \mathbf{2-1}$$

Onde G_{TX} é o ganho da antena de transmissão em dB_i , G_{RX} é o ganho da antena de recepção em dB_i , f é a frequência em GHz e d é a distância em quilômetros.

2.1.2 Propagação por reflexão

Na propagação de um sinal, os raios da antena transmissora podem ser fortemente refletidos em diversos terrenos com ou sem relevo, ou na água. A Figura 2-2 mostra este exemplo com as variáveis que entram na determinação do campo recebido. Com a ocorrência de tal efeito tem-se, na recepção, diversos sinais que chegam defasados do transmitido (multipercursos), o que pode resultar, ao se compor com o feixe direto, numa atenuação que pode variar desde pequena até a anulação total do campo resultante, assim como um ganho no sinal recebido.

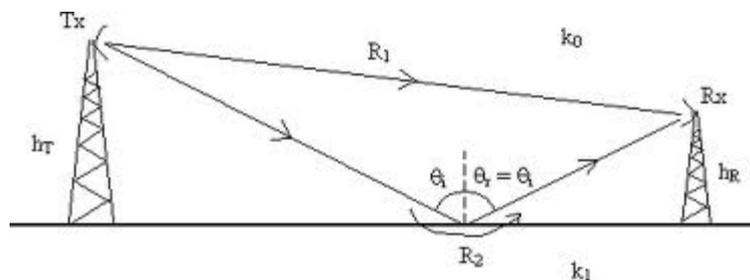


Figura 2-2 - Reflexão sobre superfície Regular. [1]

onde são definidos:

- Tx – transmissão
- Rx – recepção
- h_T – Altura de transmissão
- h_R – Altura de recepção
- k_0 – coeficiente dielétrico do ar
- k_1 – coeficiente dielétrico do solo
- R_1 – raio direto

- R_2 – raio refletido
- Θ_i – ângulo de incidência
- Θ_r – ângulo de reflexão

A reflexão em terrenos rugosos (irregulares) se torna difusa, ou seja, resulta em um espalhamento da onda incidente para diversas direções, como mostra a Figura 2-3. Neste caso, a propagação da onda pode se tornar muito melhor, por não chegarem raios refletidos e defasados na recepção, acarretando, portanto, em menor atenuação.

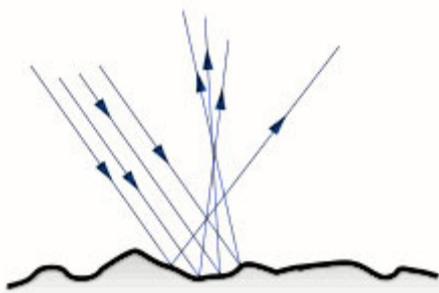


Figura 2-3 - Reflexão sobre superfície irregular. (Fonte: Google)

Quanto maior a frequência, maior é a rugosidade do terreno em comparação com o comprimento de onda. A partir destes dados, criou-se a Tabela 2-1 com os valores do módulo do coeficiente de reflexão em alguns tipos de terrenos para determinadas frequências [3]. Quanto maior este coeficiente, maior a reflexão, o que resulta numa maior atenuação dos raios.

Tabela 2-1 – Valores do coeficiente de reflexão para diferentes ocasiões.

	Superfície do Mar	Terreno muito irregular	Terreno normal	Cidade, Floresta, Montanha
2 GHz	1.0	0.8	0.6	0.3
4 GHz	1.0	0.8	0.5	0.2
6 GHz	1.0	0.8	0.5	0.2
11 GHz	1.0	0.8	0.4	0.16

Outros fatores que também influenciam na atenuação das ondas refletidas são o ângulo de incidência no terreno e a polarização da onda.

Considerando o primeiro caso, temos que a reflexão tende a ocorrer mais frequentemente com valores de ângulos pequenos, geralmente encontrados em ligações de micro-ondas, que chegam a ter grandes distâncias e alturas de antenas relativamente baixas, frente a tais distâncias.

A polarização horizontal é a mais propícia a maiores reflexões, devido ao fato de que, considerando a terra um meio condutor, o que é verdade para as frequências mais baixas, não há campo elétrico paralelo à superfície, contribuindo para que haja reflexão total da onda incidente.

2.1.3 Propagação por difração

O fenômeno de difração consiste na incidência das ondas de rádio sobre um anteparo, que nas situações reais são as irregularidades dos terrenos, árvores, prédios ou até mesmo a curvatura da terra. A Recomendação UIT-R 526 *Propagation by diffraction* mostra como devem ser calculados os valores da perda causada pela difração das ondas nos obstáculos. Esta Recomendação será abordada no item 2.2.2.1.

Este anteparo não atenua a onda em sua totalidade, visto que ela o ultrapassa e irradia após o obstáculo. Este efeito é melhor observado em frequências menores, ou seja, com maior comprimento de onda. Existem alguns métodos clássicos para cálculo da atenuação devido aos obstáculos dos terrenos.

2.1.3.1 Princípio de Huygens

Grande parte da frente de onda incidente é obstruída na presença de um obstáculo, porém há algumas exceções. Onde não há exceção, uma região de penumbra será criada logo atrás do anteparo.

Nessas exceções, o Princípio de Huygens estabelece que cada ponto de uma frente de onda funcionará como uma fonte de ondas secundárias que, somadas, resultam na continuação da propagação após o obstáculo [13], como mostra a Figura 2-4.

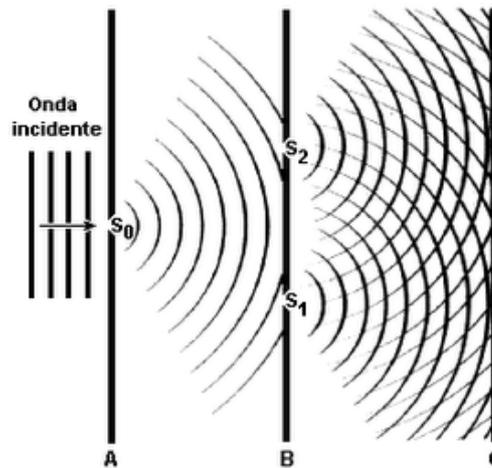


Figura 2-4 - Fontes de Ondas Secundárias geradas devido aos obstáculos.
(Fonte: Google)

2.1.3.2 Zonas e Elipsoides de Fresnel

A partir do irradiador secundário, conforme explicado no item anterior, ou a partir de outras fontes de transmissão, cada frente de onda percorre caminhos distintos até a chegada ao ponto de observação. Estas diferentes distâncias influenciam na intensidade de cada componente e na sua fase. Os estudos destas defasagens nos diversos percursos dão origem às Zonas de Fresnel, e devido a esta defasagem, cada uma das fontes secundárias da irradiação poderá influenciar positiva ou negativamente no campo recebido.

Considerando-se o caso em que o anteparo irradia fontes de ondas secundárias em toda sua extensão, sendo considerado um irradiador elementar. Delimitam-se as áreas demarcadas, de modo que a diferença máxima de fase entre as contribuições originadas dessa região seja igual a π radianos, conforme representado na Figura 2-5. Tomando-se uma região mais externa, pode-se ver que elas terão fase variando entre π e 2π .

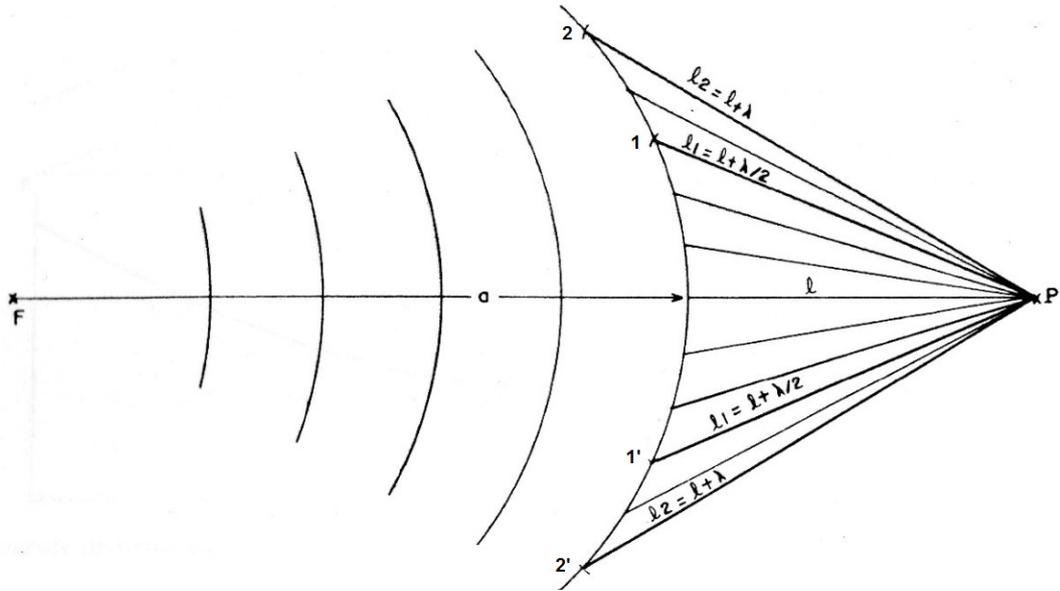


Figura 2-5 - Toda a superfície da frente de onda considerada um irradiador elementar. [3]

Pode-se, desta forma, redesenhar as várias regiões constituídas de anéis circulares, correspondentes às diferenças de fase $n\lambda/2$. Estes anéis denominam-se Zonas de Fresnel e são mostrados na Figura 2-6.

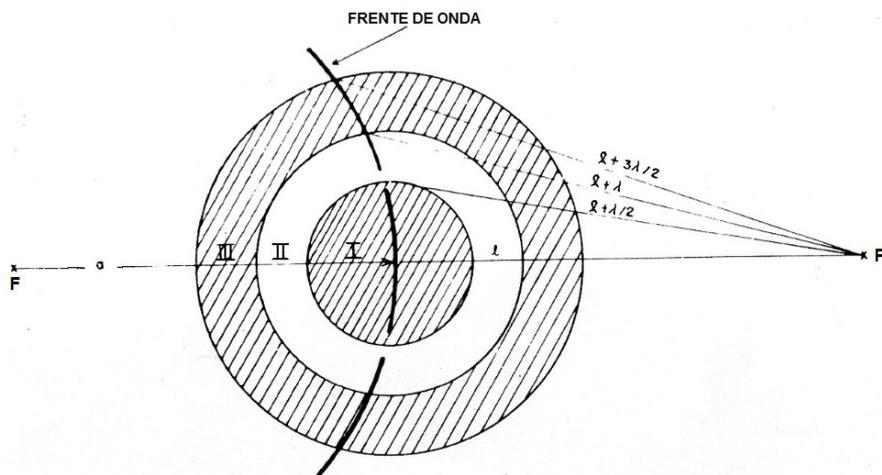


Figura 2-6 - Zonas de Fresnel. [3]

Considerando, ainda, a Figura 2-6, as contribuições no ponto P deveriam ser canceladas devido às defasagens de 180° , porém isso não ocorre por causa das diferenças nas distâncias.

Desta forma, somando a contribuição de todas as zonas a partir da 2ª, tem-se que o valor final é, aproximadamente, igual à metade do valor da 1ª Zona de Fresnel, isto devido às irradiações que ajudaram negativamente. Desta forma, tem-se outra

propriedade, à qual mostra que, se tirássemos todas as contribuições das zonas pares, o campo recebido seria maior que no espaço livre.

Sendo F a fonte transmissora e P a antena receptora, a Figura 2-7 exemplifica os elipsoides de Fresnel em determinado enlace.

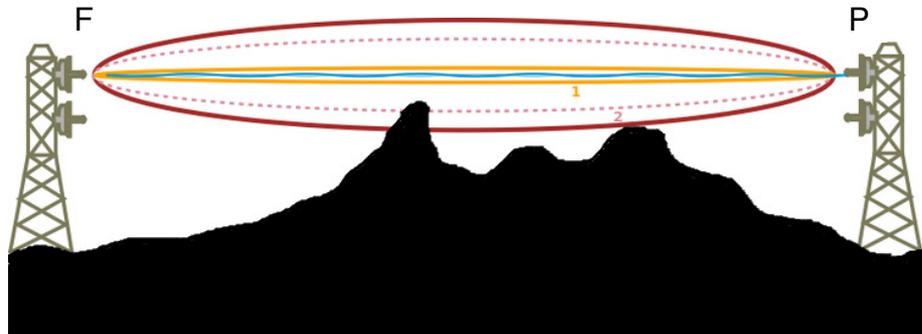
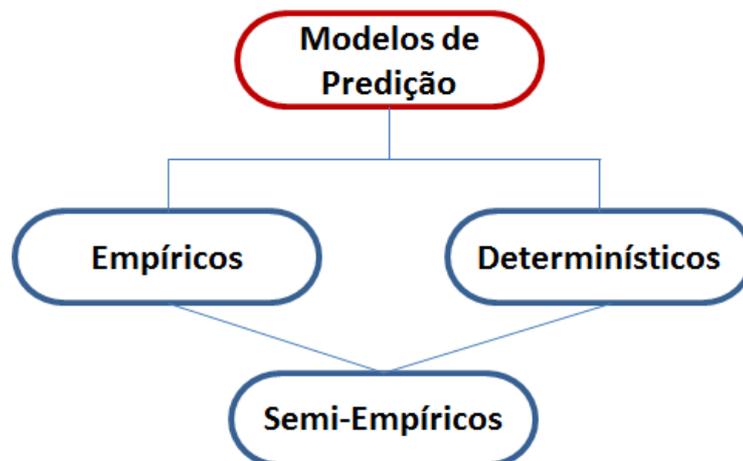


Figura 2-7 - Elipsoides de Fresnel. [1]

Pode-se observar que a potência no receptor será função do terreno por onde a onda se propaga. É preciso utilizar critérios de desobstrução que garantam o nível de sinal desejado.

2.2 MODELOS DE PREDIÇÃO

Os modelos de propagação utilizados pela UIT-R podem ser divididos da seguinte forma:



- **Empíricos**

- São baseados em medições e possuem relação simples entre a atenuação e a distância.

- Estão inclusos todos os fatores que podem afetar a propagação.
 - Conduzem a curvas e equações que melhor se ajustam às medições.
 - Necessitam de validação para diferentes locais, frequências e condições do ambiente de medida.
- **Determinísticos**
 - Também chamados de modelos teóricos, necessitam da utilização de base de dados topográficos.
 - Não levam em consideração todos os fatores que afetam a propagação, nem os ambientes em que um receptor móvel se desloca.
 - Fácil alteração dos valores dos parâmetros.
 - Dependem da definição da base de dados geográficas.
- **Semi-Empíricos**
 - Atualmente, não existe um modelo genérico para ser utilizado em todas as situações, assim, são utilizados modelos híbridos que possuem características de ambos. Desta forma, tem-se a possibilidade de comparação com as medidas reais, podendo haver realimentação dos dados medidos para calibração dos modelos, minimizando-se os erros e otimizando a predição.

2.2.1 Predição Ponto-Área

Existem muitos modelos de predição na literatura e um modelo é considerado bom quando 68% dos valores previstos estão dentro de um desvio padrão máximo na faixa de 6 a 8 dB quando comparado com os valores medidos [5]. Pode-se afirmar que nenhum modelo atende todos os ambientes, e assim, uma avaliação cuidadosa é necessária [6].

Para esta pesquisa serão abordados alguns dos modelos mais utilizados e reconhecidamente mais eficientes em macro células, com as variações de região, como densa, urbana, suburbana, bem como as demais características morfológicas. Experimentos de campo na localidade alvo do projeto aliam-se a estes modelos para que se tenha maior precisão no estudo de propagação e, conseqüentemente, no planejamento da cobertura das estações.

2.2.1.1 Modelo de Okumura

Este modelo de propagação é baseado em uma série de medições ocorridas em Tóquio na década de 1960, para a faixa de 200 MHz a 1920 MHz, muitas vezes extrapolado até 3 GHz e com distâncias de 1 a 100 km. É um método de predição empírico, ou seja, baseando-se unicamente nos dados medidos.

Este modelo é um dos mais utilizados para predição de sinal em áreas urbanas. Os fatores de correção são utilizados com base em gráficos e dados do enlace [6] [7].

O modelo de Okumura é muito prático e é considerado um dos mais simples e melhor em termos de precisão na predição de perdas de propagação para sistemas celulares maduros e de rádio móvel terrestre em ambientes desordenados. Os desvios padrão comuns entre os valores de perda de propagação preditos e medidos estão entre 10 a 14 dB [8], no entanto, a desvantagem do modelo é a lenta resposta às mudanças bruscas do terreno, sendo razoável em áreas urbanas e suburbanas e não tendo um bom desempenho em áreas rurais [8].

2.2.1.2 Modelo de Okumura-Hata

O objetivo de Hata era estabelecer relações matemáticas empíricas para descrever a informação dada pelos gráficos de Okumura, mantendo a média dos desvios padrões anteriores.

A formulação de Hata torna o modelo de Okumura muito mais fácil de usar e é, geralmente, a forma como o modelo de Okumura é aplicado [7], no entanto, a formulação é limitada e restringe a determinadas faixas de parâmetros de entrada. Trabalha apenas na faixa de 150 a 1500 MHz [7], sendo aplicável em terreno quase liso e não inclui nenhuma das correções de perdas específicas disponíveis no modelo original [6] [8]. Por este motivo, acabou sendo utilizado, principalmente, por sistemas de grandes células móveis, o que implica em não atender suficientemente sistemas de comunicações pessoais.

2.2.1.3 Modelo de Cost 231-Hata

A cooperativa europeia criou a comissão de trabalho COST-231 para desenvolver uma versão estendida do modelo de Hata [8]. Os modelos de Hata e Cost 231-Hata são base para a maior parte das ferramentas comerciais de planejamento de radiofrequência (RF) para telefonia móvel [7].

Este modelo estende a aplicação da formulação de Hata, sendo válida para os mesmos intervalos de valores das alturas das antenas e distância, porém com o aumento da largura da faixa de frequência, que passou a ser de 1500 a 2000 MHz [7]. Também é restrito a grandes células e onde a antena da estação rádio base está acima do nível dos edifícios adjacentes [6]. Após novos estudos estendeu-se a aplicação deste modelo à faixa de 6,6 GHz.

2.2.1.4 Modelo de Ikegami

O modelo de Ikegami é um modelo do tipo semi empírico, recomendado para ambientes urbanos que apresentam características homogêneas em relação à densidade e altura das construções [9]. É um modelo que tenta produzir uma precisão totalmente determinista das intensidades dos campos em pontos específicos.

Para a obtenção da expressão que permite calcular a atenuação média de percurso, foram empregadas óptica geométrica e teoria da difração, aplicadas a uma região urbana ideal, considerando construções, cujo espaçamento e altura exibem características uniformes. Neste contexto, uma situação de *No Line of Sight* (NLOS) foi criada, na qual somente duas trajetórias possíveis para as ondas eletromagnéticas que chegam ao ponto obstruído são consideradas.

Deve ser utilizado um mapa detalhado das alturas das edificações, formatos e posições. São traçadas linhas do percurso entre o transmissor e o receptor, com a restrição de que são contabilizadas apenas reflexões únicas nas paredes. A difração é calculada usando uma aproximação de um único obstáculo no prédio mais próximo do móvel e a perda por reflexão é, assim, dada como um valor constante [9].

Embora represente razoavelmente bem para variações próximas na intensidade do campo, é falha a suposição de que a altura da antena da ERB não afeta a propagação, da mesma forma a variação com frequência também é subestimada em relação às medições [9].

2.2.1.5 Modelo de Walfisch-Bertoni

O modelo de Walfisch-Bertoni é modelo do tipo semi empírico, desenvolvido para áreas urbanas e faixa de frequências de UHF. Permite, também, calcular a atenuação de sinal mesmo em situações nas quais a linha de visada entre a ERB e o receptor (móvel) esteja comprometida (NLOS) [10].

Tal modelo leva em consideração as características moderadas das construções em ambientes residenciais, comerciais e industriais, responsáveis pela composição da maior parte da morfologia urbana de uma cidade. O desenvolvimento deste modelo baseou-se em premissas de que o sistema irradiante da ERB, mais elevado em relação ao nível das construções, irradia ondas eletromagnéticas que se propagam acima da linha do ambiente construído e que, por um processo de múltiplas difrações no topo destas, atingem o nível da rua, onde se localiza o equipamento móvel [10].

2.2.1.6 Modelo de COST-Walfisch-Ikegami

O modelo de Walfisch–Ikegami é um modelo do tipo semi empírico e foi criado com o objetivo de melhorar a estimativa das perdas no percurso. Subgrupos de estudos de propagação propuseram uma combinação dos modelos já existentes [6].

Foi desenvolvido a partir de medições realizadas em Estocolmo, tendo a mesma forma que a equação da perda de percurso com base no espaço livre, onde as constantes são escolhidas com base nas informações do ambiente, como por exemplo, largura das ruas, alturas das edificações, separação das edificações, orientação em relação linha de visada livre ou não, etc. [6]

Este modelo apresenta limitações como os demais modelos, funcionando apenas para frequências de 800 a 2000 MHz, distâncias de 0,02 km a 5 km e entre intervalos de alturas específicos para a estação base e a estação móvel [6].

As previsões são bem aderentes com as medições quando a antena da estação base está acima da altura das edificações, produzindo erro médios por volta de 3 dB, e desvio padrão na faixa de 4 a 8 dB, porém, deteriorando-se rapidamente quando esta condição não se aplica, o que ocorre em micro células [6]. Um fenômeno muito associado a este tipo de modelo é guiamento de sinal de RF ao longo do arruamento [11].

2.2.1.7 Modelo de Lee

O modelo de Lee é um modelo do tipo empírico, usado na predição de sinais em macro células em áreas urbanas e suburbanas. Foi desenvolvido a partir de medições em ambientes de algumas cidades americanas e japonesa (Tokyo) [12].

O modelo baseia-se no princípio de que é possível predizer a atenuação sobre uma região relativamente plana, sem conhecimento de particularidades da

configuração do terreno, porém se a previsão de cobertura ocorrer em uma região acidentada, existe alta probabilidade de se obter grandes desvios entre os valores teóricos e aqueles obtidos por meio de medições. Mesmo em regiões consideradas planas, a atenuação obtida também varia devido, principalmente, às diferenças existentes na ocupação da topografia local, ou seja morfologia das construções.

O modelo de Lee, também denominado de área-para-área [13], depende basicamente de 2 parâmetros:

- Do nível de potência de sinal existente a 1 milha (\cong 1,609 km) do ponto de transmissão; e
- Da taxa de variação da atenuação com a distância.

O desvio padrão dos valores médios obtidos por meio das equações aplicadas deve ser, no máximo, 8 dB acima ou abaixo dos valores teóricos de referência [13].

2.2.2 Predição Ponto-a-Ponto

2.2.2.1 Recomendação 526 - UIT-R

A Recomendação 526 da UIT-R apresenta alguns modelos ponto-a-ponto aplicáveis a diversos tipos de obstáculos e geometrias de percurso, que permitem avaliar os efeitos da difração no campo elétrico recebido em um determinado ponto. São abordadas a difração sobre a terra esférica, difração sobre obstáculos isolados e difração sobre múltiplos obstáculos. A modelagem geométrica descrita na Recomendação é aplicável para comprimentos de onda relativamente pequenos em relação às dimensões dos obstáculos, sendo aplicável em frequências acima de 30 MHz. Não foi considerada, neste estudo, a análise de obstáculos com geometria diferente do tipo Gume de Faca e Arredondados, bem como ao possível vazamento lateral de energia.

Como o interesse deste trabalho está na faixa de UHF, tais aproximações supracitadas podem ser usadas sem restrições. Neste estudo, serão consideradas as duas versões da Recomendação 526-11 (ano de 2011) e 526-12 (ano de 2012), onde são abordadas difração sobre obstáculos isolados e sobre múltiplos obstáculos, utilizando os modelos de cálculo *Gume de Faca em Cascata* e *Delta-Bullington*.

2.2.2.2 Difração sobre obstáculos isolados

Em um percurso de propagação é possível que existam um ou mais obstáculos independentes e, portanto, é necessário calcular as perdas causadas por eles. Para realizar este cálculo, é preciso idealizar a forma de um obstáculo, seja possuindo a forma de um semiplano condutor reto de espessura desprezível, chamado de obstáculo gume de faca, seja aproximando-o por um cilindro circular de superfície condutora suave, posicionado transversalmente à linha de visada, denominado obstáculo arredondado.

Um obstáculo pode ser considerado isolado se não existir interação entre o obstáculo e o terreno que o cerca. Em outras palavras, a atenuação por difração ocorre apenas devido ao obstáculo, sem nenhuma contribuição do terreno.

a) Obstáculo do tipo Gume de Faca (*Knife Edge*)

Supondo um obstáculo do tipo “Gume de Faca”, que é fino e transversal às frentes de ondas, tem-se a possibilidade de estudo da variação de energia recebida após esta obstrução, que dependerá principalmente de sua altura. Neste cenário idealizado, todos os parâmetros geométricos são combinados num único parâmetro adimensional v . Este pode ser calculado por um conjunto de fórmulas que dependem dos parâmetros disponíveis, conforme a seguir:

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

$$v = h \cdot \sqrt{\frac{2}{\lambda \cdot \left(\frac{1}{d_1} + \frac{1}{d_2}\right)}} \quad 2-3$$

$$v = \sqrt{\frac{2h\theta}{\lambda}} \quad 2-4$$

$$v = \sqrt{\frac{2d}{\lambda} \cdot \alpha_1 \alpha_2} \quad 2-5$$

onde:

- h : altura do topo do obstáculo sobre uma linha reta que une os dois extremos do percurso. Se o topo do obstáculo estiver abaixo da linha de visada, h assume um valor negativo;
- λ : comprimento de onda;

- d_1 e d_2 : distâncias das duas extremidades do percurso até o topo do obstáculo;
- d : comprimento do percurso;
- θ : ângulo de difração. Tem o mesmo sinal que h e deve ser menor que 12° ;
- α_1 e α_2 : ângulos entre as extremidades do percurso e o topo do obstáculo. Tem mesmo sinal que h .

Os elementos geométricos presentes no cálculo de ν estão ilustrados na Figura 2-8 e Figura 2-9:

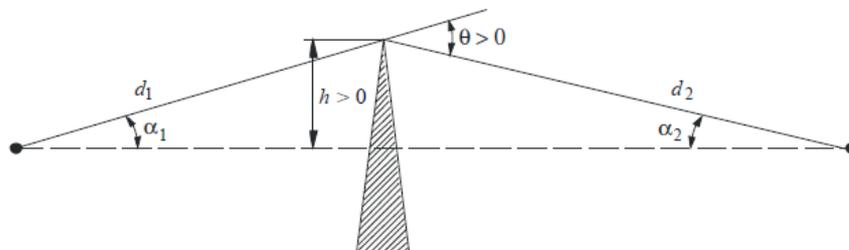


Figura 2-8 – Geometria do obstáculo interceptando a LOS. [14]

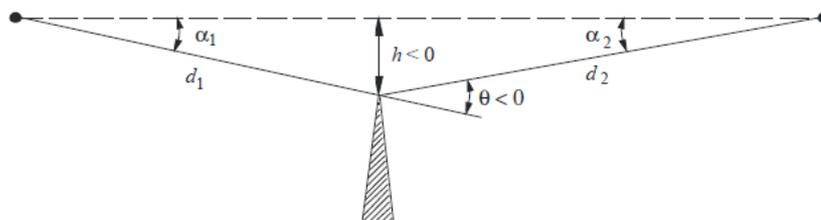


Figura 2-9 – Geometria do obstáculo sem interceptar a LOS. [14]

A perda por difração para o obstáculo gume de faca é dada por:

$$J(\nu) = -20 \log \left(\frac{\sqrt{[1-C(\nu)-S(\nu)]^2 + [C(\nu)-S(\nu)]^2}}{2} \right) [dB] \quad 2-6$$

onde $C(\nu)$ e $S(\nu)$ são as partes real e imaginária da integral complexa de Fresnel $F(\nu)$, dadas por:

$$C(v) = \int_0^v \cos\left(\frac{\pi s^2}{2}\right) ds \quad 2-7$$

$$S(v) = \int_0^v \sin\left(\frac{\pi s^2}{2}\right) ds \quad 2-8$$

Para um valor de $v > -0,78$, a seguinte aproximação é válida:

$$J(v) = 6,9 + 20 \log\left(\sqrt{(v - 0,1)^2} + v - 0,1\right) \text{ [dB]} \quad 2-9$$

Uma boa aproximação para determinar o valor da perda do obstáculo é obtida pelas equações de Lee [14], com valores $J(v)$ em dB:

$$L_{dif}(v) = \begin{cases} 0 & v \leq -1 \\ -20 \log(0,5 - 0,62v) & -1 \leq v \leq 0 \\ -20 \log\left(\frac{e^{-0,95v}}{2}\right) & 0 \leq v \leq 1 \\ -20 \log\left(0,4 - \sqrt{0,1184 - (0,38 - 0,1v)^2}\right) & 1 \leq v \leq 2,4 \\ -20 \log\left(\frac{0,225}{v}\right) & v > 2,4 \end{cases} \quad 2-10$$

Conforme estudos consagrados da literatura [3], se h é a altura do topo do obstáculo à linha de visada das antenas e r_1 , o raio da primeira zona de Fresnel, então $h/r_1 > 0$ é chamada de “zona de visibilidade”, e $h/r_1 < 0$, de “Zona de sombra”. A Figura 2-10 mostra a atenuação suplementar, em dB, em função de v .

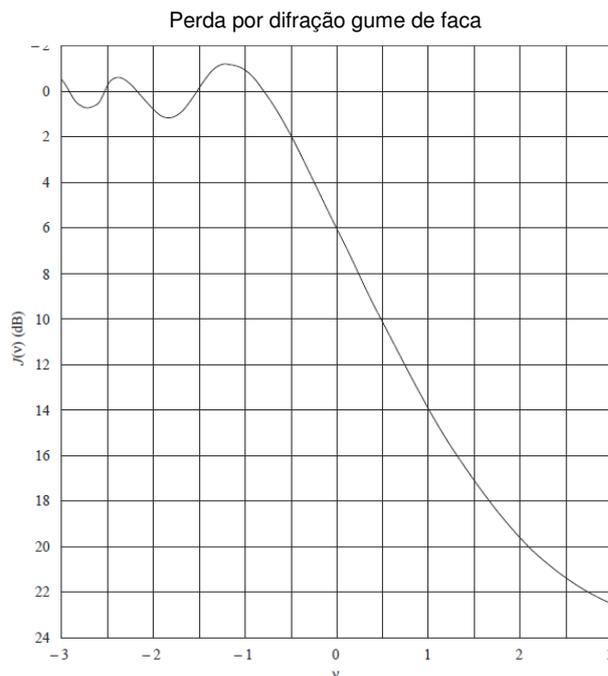


Figura 2-10 - Atenuação do obstáculo Gume de Faca. [14]

Observam-se as seguintes características quanto à variação de h/r_1 :

- Com $h/r_1 > 2,6$, tem-se a onda difratada com o campo aproximadamente igual ao do espaço livre.
- Para $h/r_1 = 0$, onde o topo do obstáculo coincide com a linha de visada, tem-se a perda da metade da primeira zona de Fresnel, diminuindo a potência de 6 dB ao comparar com a do espaço livre.
- Para $h/r_1 = 0,6$, tem-se o mesmo campo do espaço livre.
- Com $h/r_1 = 0,8$, tem-se o campo recebido maior que no espaço livre (aproximadamente 1,4 dB), sendo a melhor opção.

Em propagação na atmosfera, utiliza-se o conceito de Fator K, onde se considera o enlace sem curvatura, mas alterando o raio da terra, tomando-se um raio equivalente $R' = KR$, onde R é o raio original da terra. O valor de K depende de cada região, mas é usualmente utilizado com os valores de $4/3$, para caso padrão, ou $2/3$, para o pior caso [14]. Desta forma, numa região com um determinado valor do Fator K , uma desobstrução de $0,6 \times r_1$ já seria suficiente [3].

b) Obstáculo do tipo Arredondado

A geometria de um obstáculo arredondado de raio R é ilustrada na Figura 2-11. É importante notar que as distâncias d_1 e d_2 e a altura h sobre a linha base que liga os dois pontos do enlace são todas medidas com relação ao vértice onde os raios projetados se interceptam acima do obstáculo.

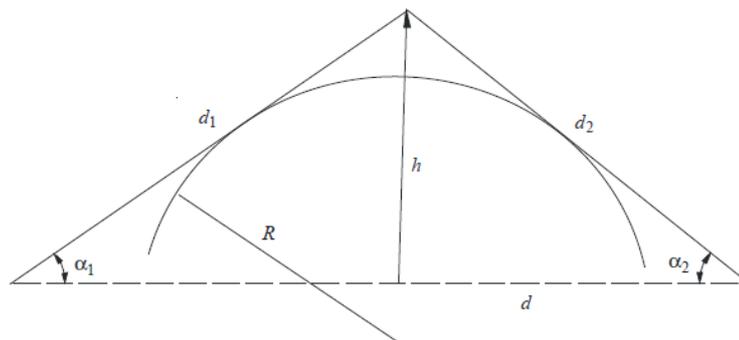


Figura 2-11 – Geometria de um obstáculo arredondado. [14]

A perda por difração para essa geometria é dada por:

$$A = J(v) + T(m, n) [dB] \quad 2-11$$

$J(v)$ é a perda de Fresnel-Kirchhoff devido a um gume de faca equivalente, posicionado com o pico coincidente ao vértice. O parâmetro v pode ser escrito, em unidades práticas, como:

$$v = 0,0316h \left[\frac{2(d_1+d_2)}{hd_1d_2} \right]^{1/2} \quad 2-12$$

onde:

- h e λ são dados em metros;
- d_1 e d_2 em quilômetros;
- $J(v)$ pode ser obtido da Figura 2-10 ou das equações 2-6 e 2-9, uma vez que a linha de visada está obstruída e, conseqüentemente, v é positivo.

$T(m,n)$ é a atenuação adicional devido à curvatura do obstáculo, dada por:

$$\left\{ \begin{array}{l} T(m, n) = 7,2m^{1/2} - (2 - 12,5n)m + 3,6m^{3/2} - 0,8m^2 [dB], \text{ para } mn \leq 4 \quad 2-13 \\ T(m, n) = -6 - 20 \log(mn) + 7,2m^{1/2} - (2 - 12,5n)m + 3,6m^{3/2} - 0,8m^2 [dB], \\ \text{para } mn > 4 \quad 2-14 \end{array} \right.$$

e:

$$m = R \cdot \frac{\left[\frac{d_1+d_2}{d_1d_2} \right]}{\left[\frac{\pi R}{\lambda} \right]^3} \quad 2-15$$

$$n = h \cdot \frac{\left[\frac{\pi R}{\lambda} \right]^{2/3}}{R} \quad 2-16$$

Observa-se que se R tende a zero, a equação 2-11 se reduz à difração por gume de faca, tornando este um caso particular do obstáculo arredondado, onde R é nulo. O raio de curvatura do obstáculo corresponde ao raio de curvatura no ápice de uma parábola ajustada ao perfil do terreno, nas proximidades do topo. No ajuste da parábola, a distância vertical máxima do ápice a ser usada neste procedimento deve ser da ordem do raio da primeira zona de Fresnel, no ponto em que o obstáculo está localizado. Este procedimento está exemplificado na Figura 2-12, onde:

$$y_i = \frac{x_i^2}{2r_i} \quad 2-17$$

e r_i é o raio de curvatura correspondente à amostra i do perfil do cume. No caso de N amostras, o raio médio de curvatura do obstáculo é dado por:

$$r = \frac{1}{N} \sum_{i=1}^N \frac{x_i^2}{2y_i} \quad 2-18$$

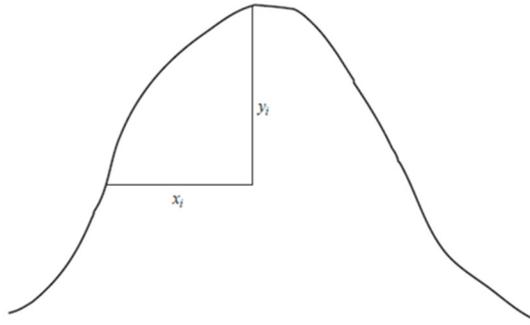


Figura 2-12 – Perfil vertical do obstáculo arredondado. [14]

2.2.2.3 Conceito de terra lisa e ganho de obstáculo

O conceito de ganho de obstáculo foi introduzido por Dickson [16] para analisar percursos que apresentavam o efeito combinado de reflexão no solo e difração por um obstáculo dominante do terreno. Define-se ganho de obstáculo, em dB, como a diferença entre os valores de atenuação, também em dB, sem e com o obstáculo no trajeto de propagação. Dependendo da frequência e distância considerada, o aumento da relação h/R aumenta proporcionalmente este ganho, que pode atingir valores consideráveis. Em contrapartida, à medida que a relação decresce, este ganho tende para zero, ou seja, o efeito do obstáculo pode ser ignorado, criando o cenário de terra lisa.

2.2.2.4 Difração sobre Terra Esférica

O conceito de terra esférica é definido para distâncias consideráveis, em que a curvatura da terra começa a obstruir a linha de visada do enlace, causando uma perda, que é chamada de difração sobre terra esférica. Inicialmente, foi estudada por Watson [17] para o caso particular do solo com condutividade perfeita. Apresenta uma solução geral muito complicada e de aplicabilidade restrita, geralmente utilizando a série dos resíduos para distâncias maiores que o horizonte do transmissor e para distâncias inferiores utiliza-se a solução da aproximação óptica geométrica [15].

2.2.2.5 Difração sobre múltiplos obstáculos

Em situações onde mais de um obstáculo existe no caminho na linha de visada entre um transmissor e um receptor, o fenômeno da difração ocorre predominantemente. Um dos erros, mais cometidos na realização destas análises, é considerar a perda em cada obstáculo individualmente, e considerar a soma das perdas individuais como sendo a perda total na transmissão, porém isto não funciona na maioria dos casos.

Alguns modelos físicos de propagação levam em consideração os efeitos das difrações múltiplas ocorridas em picos de difração, arredondados ou afiados, sem somar as perdas individuais, mas simplificando a geometria dos obstáculos e dos caminhos de propagação para obter aproximações de valor para a perda total. Essas simplificações facilitam os cálculos realizados e geram resultados satisfatórios, se comparados às medições reais realizadas nestas situações.

a) Modelo de Deygout

Admitindo a existência de dois ou mais obstáculos no trajeto, considera-se o obstáculo principal como sendo o que apresenta maior penetração no primeiro elipsoide de Fresnel. Calcula-se o efeito desse obstáculo através de v , supondo que não exista outro, e em seguida, considera-se um enlace entre o ponto de origem e o topo do obstáculo principal, determinando a influência do segundo obstáculo, e assim sucessivamente, como pode ser observado na Figura 2-13.

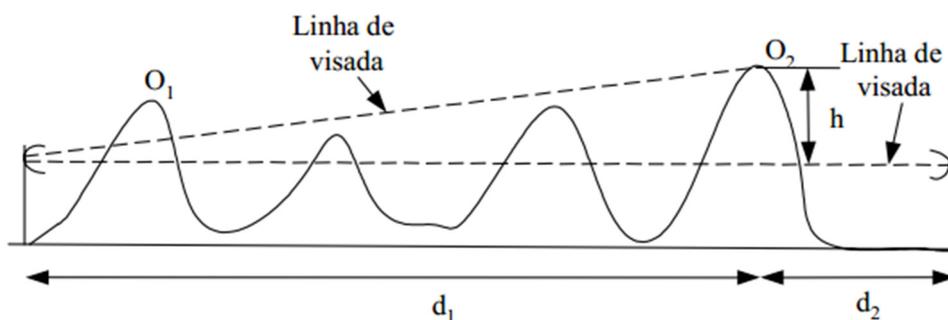


Figura 2-13 – Linha de visada para cálculo do campo difratado por Deygout.

[18]

Simplificando, calcula-se primeiramente a influência do primeiro obstáculo e depois os efeitos dos demais obstáculos em relação ao obstáculo principal [8]. A atenuação total será a soma, em dB, das perdas individuais dos obstáculos. Este

procedimento tem sido muito usado na prática, pois apresenta resultados confiáveis para o efeito dos obstáculos sobre a atenuação do enlace. Neste exemplo, descrevemos a perda total por difração na equação 2-19:

$$L_{\text{total}} = L_{\text{dif}}(O_1) + L_{\text{dif}}(O_2) \quad 2-19$$

onde L_{dif} é a perda individual pela difração de cada obstáculo em seu semiperfil, em dB, que pode ser calculado pela equação 2-10. Apesar dos resultados apresentados serem satisfatórios em diversas situações, ele superestima as perdas nas situações em que os obstáculos secundários apresentam alturas próximas à do obstáculo dominante, e em casos em que os obstáculos estão próximos entre si. Outro limitante para o método é a necessidade de uma grande quantidade de dados sobre um ambiente para que o método seja preciso em condições específicas.

b) Modelo Epstein-Peterson

Nesse método, considera-se cada obstáculo individualmente e admite-se que a perda total seja a soma das atenuações introduzidas por cada um deles, isto é, considera-se, inicialmente, a trajetória entre o transmissor e o segundo obstáculo, determinando o efeito do primeiro obstáculo. Em seguida, determina-se a trajetória entre o primeiro obstáculo e o terceiro, calculando-se o efeito do segundo e assim por diante. Similar ao modelo de Deygout, em situações em que os obstáculos estão próximos, ou possuem alturas próximas, os resultados não são satisfatórios [18].

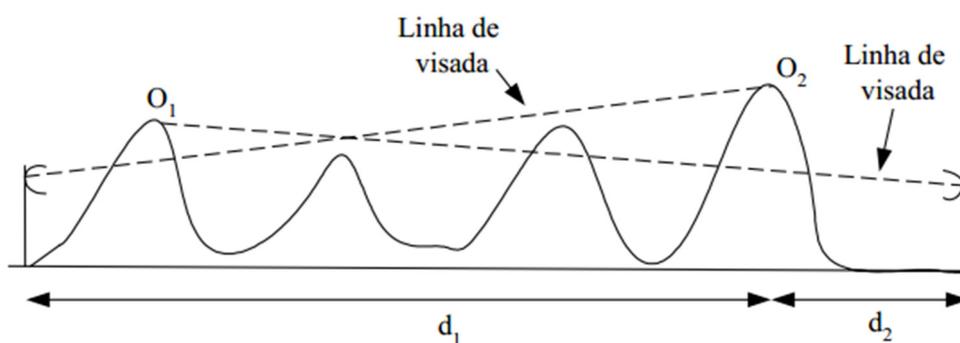


Figura 2-14 – Geometria da linha de visada para do modelo Epstein-Peterson.

[19]

c) Modelo Giovanelli

O modelo de Giovanelli é um desenvolvimento do modelo de Deygout, para diminuir o problema de obstáculos com alturas próximas e obstáculos muito próximos um dos outros. A geometria para o método está ilustrada na Figura 2-15.

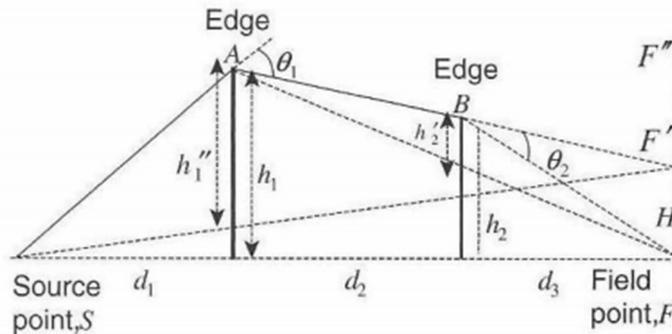


Figura 2-15 – Geometria da linha de visada do modelo Giovanelli. [20]

Como no modelo de Deygout, o obstáculo dominante deve ser identificado, neste caso denominado A. O ponto F' deve ser encontrado projetando AB e h1'' no eixo FF''. A altura h1'' é a altura relativa do obstáculo A acima dos pontos transmissor (S) e receptor (F) sobre a reta SF', e é dada por [19]:

$$h_1'' = h_1 - \frac{d_3 \cdot H}{d_1 + d_2 + d_3}, \text{ onde } H = h_2 + m \cdot d_3, \text{ e } m = (h_2 - h_1) / d_2 \quad 2-20$$

A altura relativa do obstáculo secundário B é dada pela equação:

$$h_2' = h_2 - \frac{d_3 \cdot h_1}{d_2 + d_3} \quad 2-21$$

e as perdas por difração são calculadas seguindo as mesmas premissas:

$$L = L_{KE}(v(d_1, d_2 + d_3, h_1'')) + L_{KE}(v(d_2, d_3, h_2')) \quad 2-22$$

Apesar deste modelo diminuir o problema ocorrido das alturas próximas, ele necessita de uma grande quantidade de informações sobre o ambiente estudado para que seja eficiente.

d) Modelo *Cascade Knife Edge* (UIT-R 526-11)

É o modelo utilizado nas Recomendações UIT-R P.452-14 [20] e P.1812-1 [21] e, conforme descrito na seção 4.4.2 da Rec. UIT P.526-11, inicialmente deve-se encontrar a amostra do perfil com maior valor do parâmetro v , ou seja, maior relação

H/R, entre os terminais transmissor e receptor. O parâmetro v da amostra principal do percurso é calculado e denominado v_p , e a atenuação correspondente denominada $J(v_p)$. Se $v_p > -0,78$ ($H/R > -0,55$) esse procedimento é aplicado mais duas vezes, conforme descrito abaixo:

- entre Tx e a amostra principal, obtendo v_t , e assim $J(v_t)$;
- entre a amostra principal e Rx, obtendo v_r , e assim $J(v_r)$.

A atenuação total do percurso é dada, então, por:

$$L = J(v_p) + T [J(v_t) + J(v_r) + C] \text{ para } v_p > -0,78 \quad 2-23$$

$$L = 0 \text{ para } v_p \leq -0,78 \quad 2-24$$

onde:

$$C = 10 + 0,04d \text{ (d – distância total do enlace em km)}. \quad 2-25$$

$$= 1 - e^{\frac{-J(v_p)}{6}} \quad 2-26$$

Esse procedimento, para percursos além do horizonte, é baseado no método Deygout [22] limitado a três obstáculos, entretanto, para percursos com linha de visada, difere do modelo de Deygout, porque a contribuição dos obstáculos das visadas dos semiperfis Tx-P e P-Rx, são sempre consideradas quando $J(v_p) \neq 0$.

e) Modelo de Bullington

Este modelo consiste em se reduzir o número de obstruções para um único obstáculo equivalente do tipo gume de faca com determinada elevação, localizado em um ponto conveniente do trajeto. Para isto, identificam-se dois obstáculos que contribuem com a maior perda no enlace e, a partir das antenas, traçam-se trajetórias retilíneas e, em sua interseção, localiza-se o obstáculo equivalente com sua altura e folga em relação à linha de visada [23] [8].

No modelo de Bullington original, são consideradas três condições, que são: linha de visada, linha de visada marginal e sem linha de visada. Posteriormente, foram incluídas 3 correções, uma empírica, outra denominada “taper” e uma terceira “C2”, que serve para corrigir o aumento do erro médio, que se acentua com o tamanho do percurso [24].

No exemplo ilustrado na Figura 2-16, basta traçar uma reta ao topo dos obstáculos O_1 e O_2 , a partir da transmissão e da recepção, e no ponto de cruzamento destas duas linhas (ponto de Bullington) é criado um único obstáculo equivalente, de modo a desconsiderar todos os outros. A perda por difração é calculada utilizando as equações para obstáculo do tipo gume de faca, descrito na seção 2.2.2.2a) desta dissertação.

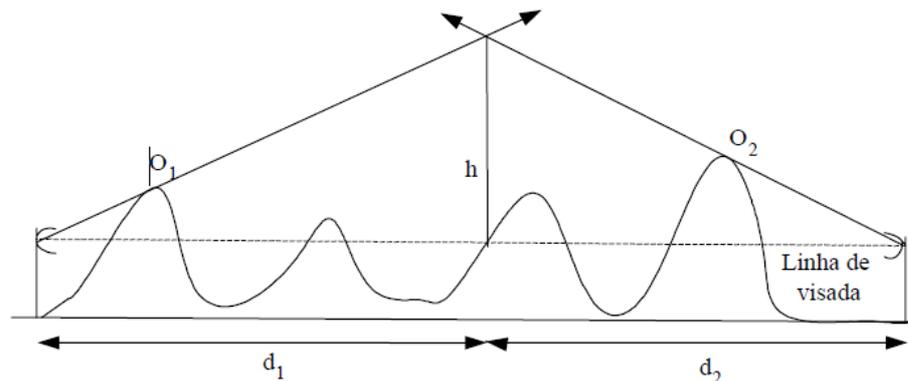


Figura 2-16 - Geração de obstáculo equivalente. [23]

No caso de haver apenas um obstáculo ou linha de visada, o ponto de Bullington é o próprio obstáculo ou o ponto mais alto do perfil do enlace, como pode ser visto na Figura 2-17 e Figura 2-18, respectivamente.

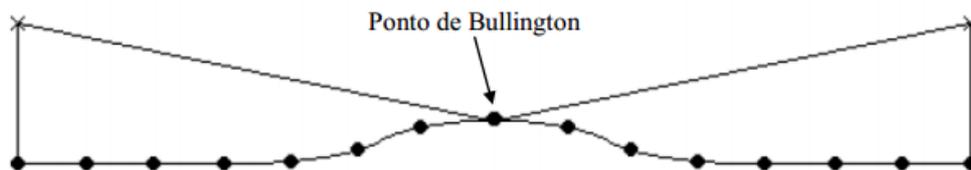


Figura 2-17 – Situação com linha de visada. [23]

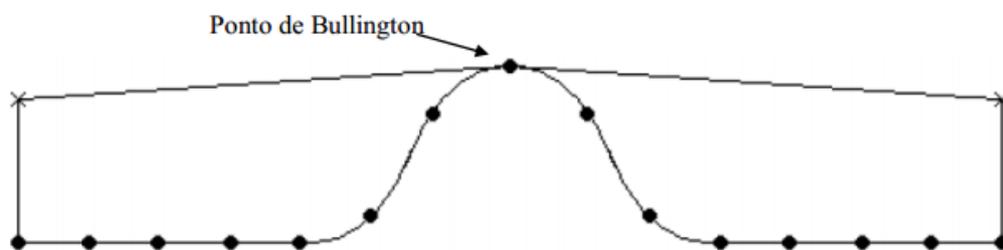


Figura 2-18 – Situação com apenas um obstáculo. [23]

i) Correção empírica e correção “taper”

A atenuação calculada pelo modelo de Bullington foi posteriormente aprimorada com a inclusão de duas correções [24].:

$$L_d = L_e + (10 + 0,02d) \cdot (1 - e^{\frac{L_e}{6,03}}) \quad 2-27$$

onde:

- L_d – atenuação em dB corrigida;
- d – distância total do enlace, em km;
- L_e – atenuação básica pelo modelo de Bullington.

O primeiro fator do segundo termo é uma correção empírica e o segundo fator é uma correção “taper” para reduzir a correção do primeiro fator suavemente até zero, quando L_e for zero.

ii) Correção C2

Com o objetivo de minimizar o erro deste modelo, a correção C2 apresentou melhores resultados e foi anexada no documento 3K/17 da UIT [24].

$$L_d = L_e + C2 \quad 2-28$$

onde:

- L_d – atenuação em dB corrigida;
- L_e – atenuação básica pelo modelo de Bullington;
- $C2$ – Fator de correção, em dB.

Para determinar a correção C2 é necessário verificar qual a condição da visada do enlace. Para o enlace que possui linha de visada livre, tem-se:

$$C2 = (L_{dst} + L_{dsr} + 0,02d) \cdot (1 - e^{\frac{-L_{dsm}}{6}}) \quad 2-29$$

Para o enlace que não possui linha de visada livre, tem-se:

$$C2 = L_{ds1} - L_{ds2} \quad 2-30$$

onde:

$$L_{ds1} = L_{dsm} + (L_{dst} + L_{dsr} + 10 + 0,02d) \cdot (1 - e^{\frac{-L_{dsm}}{6}}) \quad 2-31$$

$$L_{ds2} = L_{dsv} + (10 + 0,02d) \cdot (1 - e^{\frac{-L_{dsv}}{6}}) \quad 2-32$$

e,

- L_{dsm} – atenuação pelo modelo gume de faca para a posição da terra esférica com maior relação H/R, chamado de ponto principal;
- L_{dst} – atenuação pelo modelo gume de faca para a posição da terra esférica com maior relação H/R, entre o transmissor e ponto principal, chamado de ponto auxiliar do transmissor.
- L_{dsr} – atenuação pelo modelo gume de faca para a posição da terra esférica com maior relação H/R, entre o ponto principal da terra esférica e o receptor, chamado de ponto auxiliar do receptor.
- L_{dsv} – atenuação pelo modelo gume de faca para uma determinada posição da terra esférica, chamado de ponto virtual.

f) Modelo Delta-Bullington (UIT-R 526-12)

O método Delta-Bullington é composto pela unificação do método de Delta com o modelo de Bullington e está presente na versão da Recomendação UIT-R 526 [15].

O método de Delta foi desenvolvido para obter resultados satisfatórios em qualquer tipo de terreno, cobrindo desde os mais irregulares aos mais lisos. Pode ser utilizado com quaisquer dos modelos relacionados ao cálculo de difração, no entanto, em recentes estudos, se mostrou bem eficiente com os resultados apresentados utilizando o modelo de Bullington [17].

O método consiste no somatório de 3 condições do enlace:

- Perfil com relevo;
 - São considerados todos os parâmetros do enlace para um perfil de relevo não liso (características reais), frequência, altura das antenas, grau de irregularidade, etc, gerando uma atenuação chamada L_{da} .
- Perfil liso;
 - São considerados todos os parâmetros do enlace para um perfil liso de relevo, sem considerar as alturas de topografia e morfologia, mantendo os demais parâmetros iguais, gerando uma atenuação chamada L_{ds} .
- Terra esférica.

- São considerados os parâmetros relativos às características elétricas do solo para aplicação do modelo de terra esférica, gerando uma atenuação chamada de L_{sph} .

Temos, então, a seguinte equação:

$$L_d = L_{da} - L_{ds} + L_{sph} \quad 2-33$$

Vale ressaltar que, no caso do perfil real ser totalmente liso, os dois primeiros termos da equação 2-33 se cancelam e o resultado será baseado apenas na perda por terra esférica.

2.2.3 Conclusões sobre aplicação dos modelos

Como se pode perceber, os resultados diferirão, significativamente, dependendo da situação em que os modelos são aplicados, do cenário, da qualidade das informações que os alimentam, entre outros. Os modelos de propagação mais utilizados e consagrados foram determinados, empiricamente, a partir de medições em campo em algumas regiões de maior interesse e, para que funcionem, devem ser levantados e fornecidos vários parâmetros dos novos locais de interesse, garantindo, assim, que os valores estimados pelo modelo apresentem as mesmas variações em torno do valor real.

Ao longo dos anos vêm surgindo combinações e adaptações dos modelos existentes, bem como têm sido utilizadas diferentes abordagens em macro e micro células, o que acaba produzindo melhores resultados do que qualquer modelo único. Vários modelos utilizados para o cálculo da perda por difração vêm sendo desenvolvidos com base nos modelos anteriores, ou seja, uma combinação de métodos com o objetivo de reduzir o erro médio das predições do sinal recebido, no entanto, independentemente de ser empírico ou não, é necessário o fornecimento de parâmetros levantados na região a ser estudada.

3 MEDIÇÕES EM CAMPO

3.1 LOCAL DAS MEDIÇÕES

Com o objetivo de continuar os trabalhos realizados durante o período de graduação [1] [2], o local de Campo Grande foi escolhido tentando manter as principais características anteriores. Uma região suburbana com relevos suaves e construções baixas e de fácil logística de transporte dos equipamentos.

Para evitar o pedido de autorização à ANATEL para utilização de uma frequência específica, foi decidido trabalhar com uma frequência já licenciada e que operasse em caráter primário e que não causasse interferência em outros sistemas em funcionamento contínuo. Para isso foi realizada uma verificação prévia da ocupação do espectro no local. Com base nas premissas anteriores, as medições foram realizadas em um trecho da Avenida Brasil e na vizinhança de Campo Grande, conforme mostrado na Figura 3-1, onde é possível verificar a existência de uma topografia com terreno acidentado na região suburbana de Campo Grande.



Figura 3-1 – Região de Campo Grande – RJ. (Fonte: Google Earth)

Após a definição da região em questão, foi possível verificar a topografia e morfologia do local a ser estudado, conforme ilustrado pela Figura 3-2 e pela Figura 3-3, que foram colhidas da base de dados da ferramenta de predição *Celplanner* [26]. Na Figura 3-2 verifica-se a predominância de uma região urbana de baixa densidade, em um bairro residencial, com construções de 2 a 3 andares, no máximo.

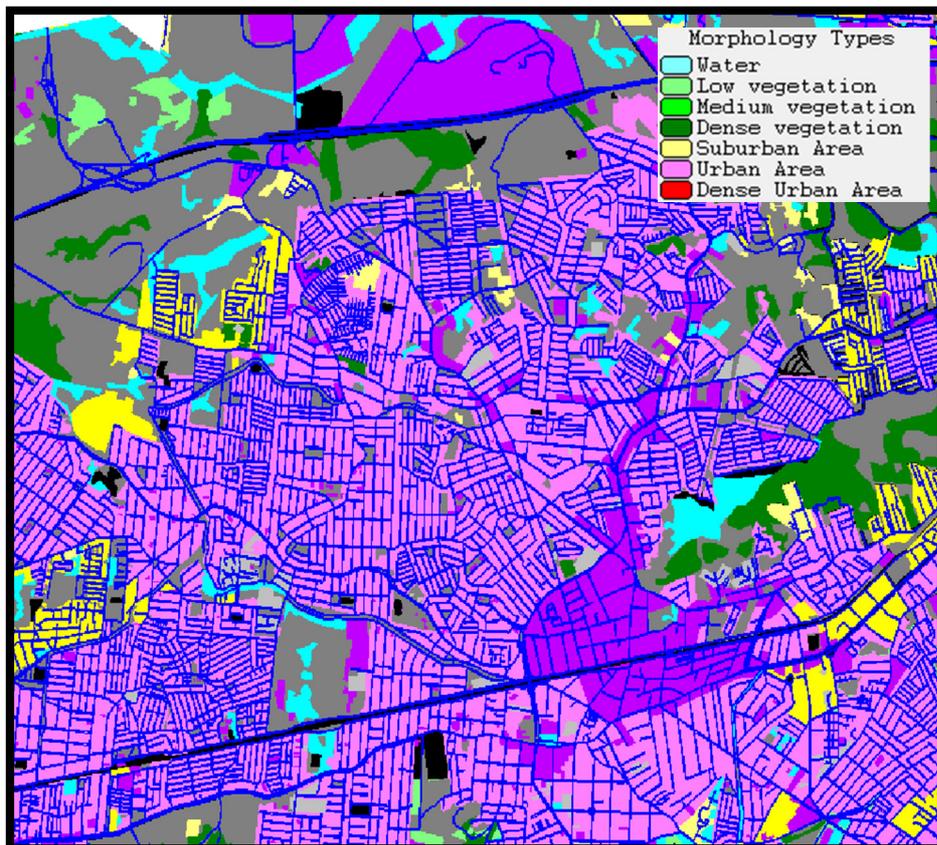


Figura 3-2 – Morfologia do terreno de Campo Grande – RJ. [26]

Na Figura 3-3 tem-se uma visão 2D, da região a ser estudada, onde é possível quantificar, através de sua altitude, as dimensões das elevações presentes.

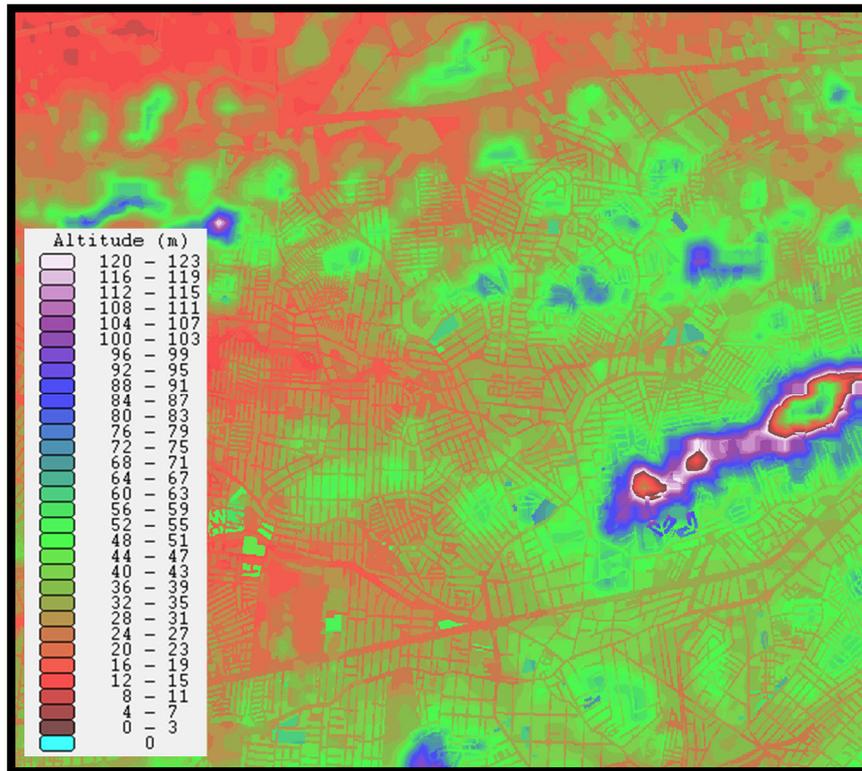


Figura 3-3 – Topografia do terreno de Campo Grande – RJ. [26]

Para facilitar esta análise, foi gerada, também, uma vista 3D do local, onde é possível perceber a existência de relevos suaves, propícios à ocorrência de propagação por difração, conforme se observa na Figura 3-4.

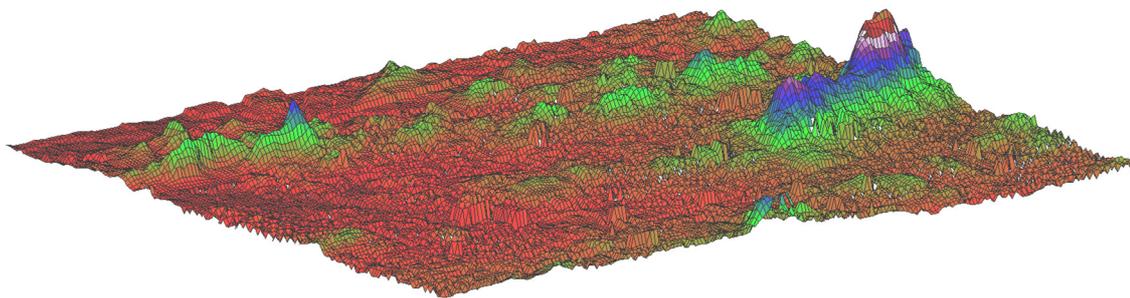


Figura 3-4 – Visão 3D do terreno de Campo Grande – RJ. [26]

3.2 SETUP DE MEDIÇÕES

Para a realização das medições, foram utilizados equipamentos do laboratório de propagação da UFF e outros equipamentos cedidos por instituições parceiras, listados a seguir.

3.2.1 Fonte de Alimentação

Foi utilizada a fonte ICEL Manaus PS-5000, conforme Figura 3-5, para alimentar o amplificador de potência (PA) empregado na transmissão.



Figura 3-5 – Fonte de alimentação para alimentar o PA.

Esta fonte foi utilizada na bancada do sistema de transmissão, que será detalhado no item 3.3.

3.2.2 Gerador de RF

Foi utilizado o gerador vetorial de sinal de bancada da Rohde & Schwarz SM300, conforme Figura 3-6, para gerar o sinal banda estreita na faixa de UHF.

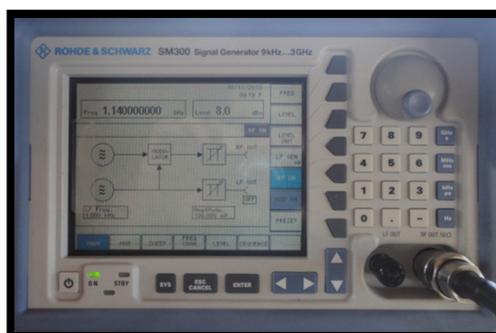


Figura 3-6 - Transmissor R&S.

Sua faixa de operação é de 9 kHz até 3 GHz, com resolução de 0,1 Hz, e potência entre -127 dBm e 13 dBm.

3.2.3 Amplificador de Potência

Foi utilizado o amplificador de Alta Potência ZHL-16W-43+, com alimentação de 28V (típico) e 4.6A de corrente máxima, conforme mostra a Figura 3-7.



Figura 3-7 – Amplificador de Alta Potência.

Este amplificador foi utilizado para garantir uma ERP típica da faixa utilizada pelas empresas operadoras de telefonia móvel.

3.2.4 Antenas de Transmissão e Recepção

Foi utilizada a antena Discônica MFJ-1866, conforme Figura 3-8, para transmissão. Seu ganho não é informado pelo fabricante, no entanto, foi considerado ganho médio de 1 dBi, na faixa utilizada de 1140 MHz, apresentando SWR máximo de 1,5 e suportando potência de até 200 W.



Figura 3-8 - Antena Discônica utilizada para transmissão.

O fabricante não disponibiliza seu diagrama de irradiação, mas devido à sua construção e ao seu baixo ganho, pode-se concluir que apresenta propagação omnidirecional, importante para o *drive test* realizado.

Foi utilizada a antena omnidirecional Aquário CM907, conforme Figura 3-9, na recepção do sistema. Sua faixa de operação é *quadriband* celular, ou seja, opera em 800 MHz, 900 MHz, 1800 MHz e 1900 MHz.



Figura 3-9 – Antena Monopolo para Recepção.

Na faixa utilizada, esta antena apresenta ganho médio de 3 dBi com SWR máximo de 1,5 e suporta potência máxima de 10 W. Por ser uma antena leve e compacta, seu transporte é facilitado e de fácil fixação em veículos, pois apresenta uma base imantada.

3.2.5 Low Noise Amplifier - LNA

Foi utilizado o LNA ZL-812, conforme Figura 3-10, operando na faixa de 800 MHz a 1200 MHz.



Figura 3-10 – Low Noise Amplifier.

Apresenta figura de ruído máximo de 1,5 dB e seu ganho médio é de 20 dB com desvio de 1 dB. É limitado em 8 dBm de saída máxima, no ponto de compressão de 1 dB e foi instalado no sistema de recepção para remover o ruído fora de banda e garantir uma melhor relação sinal ruído.

3.2.6 Analisador de Espectro

Para a recepção e processamento dos sinais medidos, foi utilizado o analisador Anritsu *Signature* MS2781B, conforme Figura 3-11, cedido pela PUC/RJ.

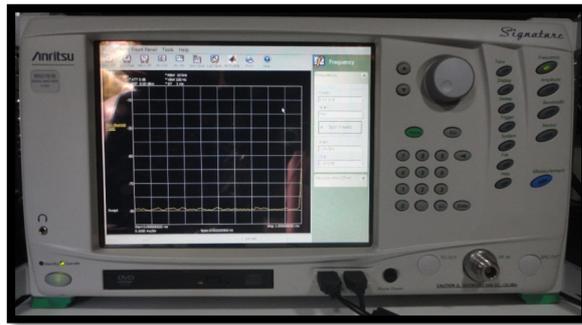


Figura 3-11 - Analisador de Epectro utilizado na recepção.

Este equipamento possui uma faixa de operação de 100 Hz a 8 GHz, com resolução de 1 Hz. O RBW utilizado foi ajustado conforme o sistema de transmissão de faixa estreita, considerando apenas a portadora recebida. Na faixa de interesse, sua sensibilidade é de -166 dBm, com incerteza de 0,1 dB, e VSWR menor que 1,3.

3.2.7 Receptor de GPS

Para coleta de dados de posicionamento foi utilizado um GPS Garmin GPSmap 62, conforme Figura 3-12.



Figura 3-12 - GPS utilizado nas medições.

Possui modo rastreamento onde os dados são armazenados a cada segundo, ideal para geração de trilhas e rotas.

3.2.8 Interface de aquisição de dados

Foi utilizada a interface de aquisição de dados da NI, modelo USB-6212 BNC, conforme Figura 3-13, para recepção dos dados do analisador de espectro e geração do arquivo de medidas.



Figura 3-13 – Interface utilizada na recepção dos dados.

Apresenta 8 entradas analógicas do tipo BNC de 16-bit, com taxa máxima de 400 kS/s e saída USB digital. Foi utilizada para fazer a interface entre o GPS, analisador de espectro através da saída de vídeo *output* e o notebook utilizado.

3.3 PARÂMETROS BÁSICOS DAS MEDIÇÕES

Os principais parâmetros usados nos equipamentos são listados na Tabela 3-1.

Tabela 3-1 - Parâmetros básicos do sistema.

Frequência Central	1140 MHz
Banda Ocupada	Apenas Portadora
Potência de RF do Transmissor	8 dBm ou 6,3 mW
Altura da Antena de Transmissão/Recepção	5 m / 3 m
Ganho da Antena de Transmissão/Recepção	1 dBi / 3 dBi
Ganho na Transmissão / Recepção	40 dB / 20 dB
Perda Estimada nos cabos Tx/Rx	3 dB / 3 dB
EiRP	46 dBm

3.4 PROCEDIMENTOS PARA REALIZAÇÃO DAS MEDIÇÕES

As medições foram feitas com transmissão contínua, em um local fixo, e a captação móvel de forma automática do sinal de RF, juntamente com a posição lida do GPS em tempo real. A velocidade foi mantida próxima a 20 km/h.

A topologia da recepção é constituída da antena de recepção acoplada ao carro, com o LNA fazendo interface entre a antena e o analisador de espectro. Este, por sua vez, foi ligado à interface de aquisição, que capturava os dados e salvava em arquivo no computador. O computador recebia os dados medidos, juntamente com os dados de posicionamento do GPS, conforme ilustrações da Figura 3-14, Figura 3-15 e Figura 3-16.



Figura 3-14 – Bancada de transmissão.

A bancada de transmissão foi composta pelo gerador de RF, com saída para o amplificador, que conduz o sinal amplificado até a antena de transmissão. A fonte polariza o amplificador. A antena de transmissão foi instalada no segundo andar de uma casa na região, com uma altura aproximada de 5 metros em relação ao nível da rua. Por se tratar de um terraço, não foi possível instalar a antena acima do nível do telhado, introduzindo os obstáculos próximos à antena.



Figura 3-15 – Viatura utilizada para recepção.

O veículo utilizado foi cedido pela PUC/RJ e, em seu interior, estava instalada toda a bancada de recepção, como se vê na Figura 3-16.



Figura 3-16 – Bancada de recepção.

O sistema de recepção foi formado pela antena acoplada na parte externa superior do veículo, que era interligada ao analisador através do LNA. O analisador e o GPS eram interconectados ao computador através da interface de dados. O esquemático geral do sistema de geração e recepção dos sinais está ilustrado na Figura 3-17.

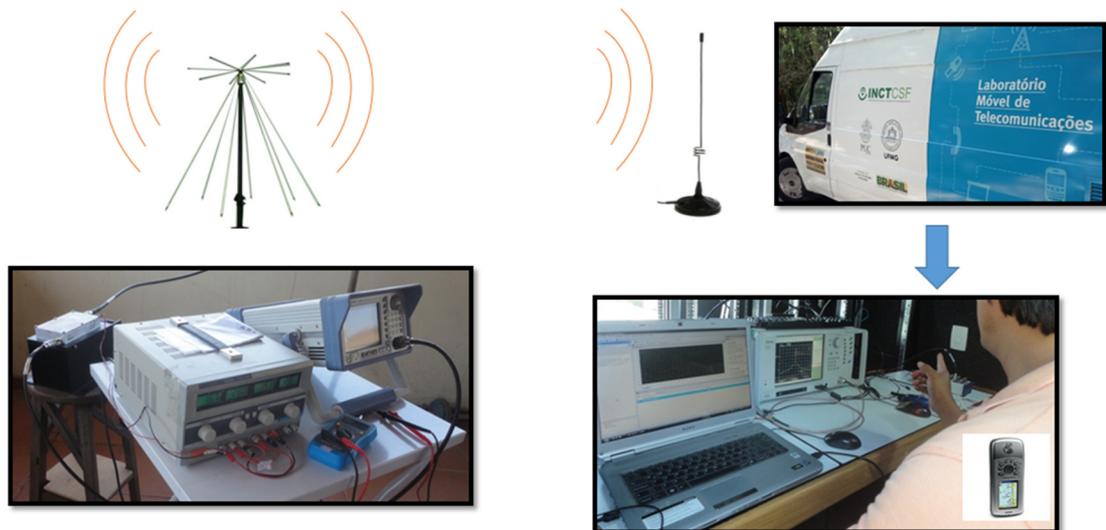


Figura 3-17 – Esquemático do sistema de medição.

Antes do início das medições, foi medido o nível de ruído presente no ambiente, e realizada a verificação da ocupação da faixa por terceiros. Como esperado, só havia ocupação na faixa quando o transmissor era ligado, o que é ilustrado na Figura 3-18.

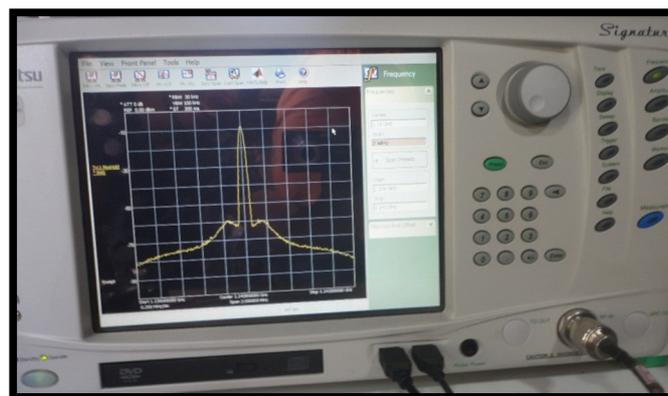


Figura 3-18 – Portadora do sinal transmitido vista no analisador de espectro MS2034A.

4 COMPARAÇÃO DAS MEDIÇÕES COM AS PREDIÇÕES

4.1 PROCESSAMENTO DOS DADOS OBTIDOS

As medições foram realizadas em 11 de outubro de 2012 em duas etapas, sendo geradas duas rotas. Uma rota no entorno do ponto de transmissão, vista na Figura 4-1, e uma segunda rota com um deslocamento mais linear, mostrada na Figura 4-2. Cada ponto medido foi importado para o Google Earth para uma melhor visão da região de interesse. No item 9.4 do apêndice as duas figuras são reunidas, numa forma ampliada.



Figura 4-1 - Pontos medidos da Rota 1. (Fonte: *Google Earth*)

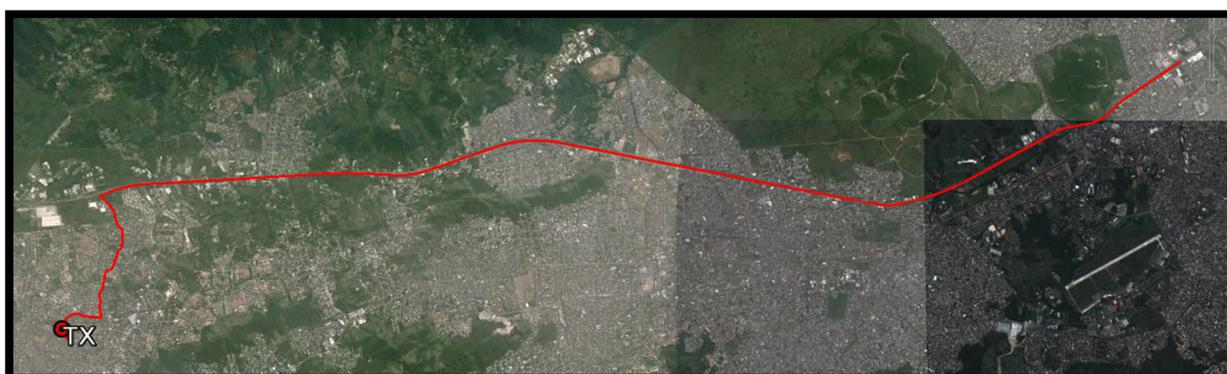


Figura 4-2 - Pontos medidos da Rota 2. (Fonte: *Google Earth*)

Apesar das medições ocorrerem de forma automatizada, ou seja, sem a necessidade de realizar uma parada em cada local para coleta dos dados, fez-se necessário unificar os dados coletados pelo GPS e pelo analisador de espectro. Estes equipamentos apresentam taxas diferentes de aquisição de dados e foi necessário realizar a sincronização para a correta leitura das informações. A placa de interface da NI salva seus dados em formato utilizado pelo programa *Labview* [28]. O primeiro passo para a sincronização foi identificar as taxas de amostragem de cada um dos equipamentos:

- ▶ Taxa de Aquisição de dados:
 - Analisador – 20 mil amostras/s;
 - GPS – 1 amostra/s.

Foi necessário realizar a subamostragem dos dados medidos pelo analisador para que ficasse compatível com os dados do GPS, de modo que, a distância entre os pontos medidos fosse de uma ordem de grandeza aceitável. Para isto, foram levantados os dados das medições:

- ▶ Duração – Aproximadamente 30 minutos por rota;
- ▶ Velocidade média do veículo - 20 km/h;
- ▶ Totalizando:
 - GPS – ROTA 1 – 1553 amostras;
 - GPS – ROTA 2 – 1711 amostras;
 - Analisador – Aproximadamente 36 milhões de amostras por rota.

Como a interpolação das amostras do GPS seria inviável neste caso, pois geraria precisão das medidas em centímetros, foi realizada uma subamostragem realizando uma média a cada 4 mil amostras detectadas do sinal medido, garantindo a contribuição de todas as amostras coletadas, considerando possíveis *fadings* no percurso. Após o primeiro pós-processamento, foi gerado um novo cenário de 5 amostras do analisador por segundo. Com isto, foi possível interpolar os dados do GPS, chegando aos seguintes valores:

- ▶ Pós-Processamento:
 - Média a cada 4k amostras – 5 amostras/s;
 - Interpolando dados do GPS – 1 amostra/0,2s;

- $V = 20 \text{ km/h} = 5,6 \text{ m/s}$;
- Aproximadamente 1 amostra/metro;
- Totalizando: 16077 medidas.

A próxima etapa de pós-processamento, foi avaliar a qualidade do material gerado para que fosse feita uma filtragem dos dados, com o objetivo de descartar possíveis pontos inválidos. Para isto, foi necessário não só sincronizar as medidas com os dados do GPS, mas também, avaliar o nível do sinal recebido e ruído ambiente.

Foi realizada a interpolação das amostras do GPS, conforme informado anteriormente, e o descarte dos pontos em que não houve amostragem das coordenadas, por erro do equipamento ou falha na captura dos dados, o que ocorreu poucas vezes.

Por último, com o intuito de facilitar a manipulação dos dados, foi realizada uma conversão dos valores coletados de volt para dBm. A interface de captura salvou as informações elétricas da saída do analisador de espectro, o que não é linearmente relacionado às informações do *display*, utilizado em dBm. Para isto, foi necessário mapear a curva de calibração do analisador utilizado, para extrair o valor medido do sinal RF corretamente. Para que fosse levantado o valor em *dBm* correspondente ao sinal de entrada em *volt*, foi realizada engenharia reversa, em laboratório. Com um gerador de sinais, foram gerados sinais de referência com potências em dBm conhecidas, e o gerador foi interligado diretamente ao analisador de espectro utilizado. Removendo a perda no cabo, foi possível gerar a relação entre as duas unidades, ou seja, para cada valor de entrada em dBm era possível medir o valor em volt da saída do analisador. Essas medições foram realizadas no laboratório do INMETRO, no RJ, e o material utilizado está ilustrado na Figura 4-3, Figura 4-4 e Figura 4-5.



Figura 4-3 – Gerador de sinais reconfigurado.

Na mesma portadora utilizada, foram configuradas as potências em dBm, realizando uma escala de 5 em 5 dBm. A potência inicial foi de -100 dBm e a última 0 dBm.

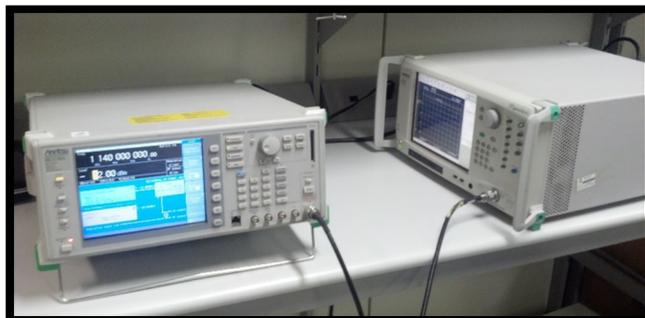


Figura 4-4 – Interface entre gerador e o analisador.

Para cada potência configurada foi realizada a medição na saída *Video Output*, localizada na traseira do analisador de espectro, em volts, saída esta utilizada para conectar a placa de interface. A medição foi realizada utilizando um multímetro da Figura 4-5.

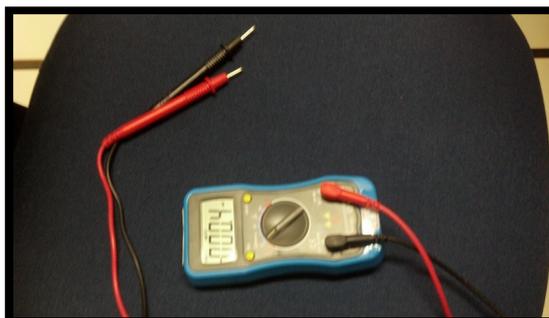


Figura 4-5 – Multímetro utilizado na medição da saída do analisador.

De posse dos valores medidos, foi possível chegar à curva de calibração do equipamento, conforme se verifica na Figura 4-6.

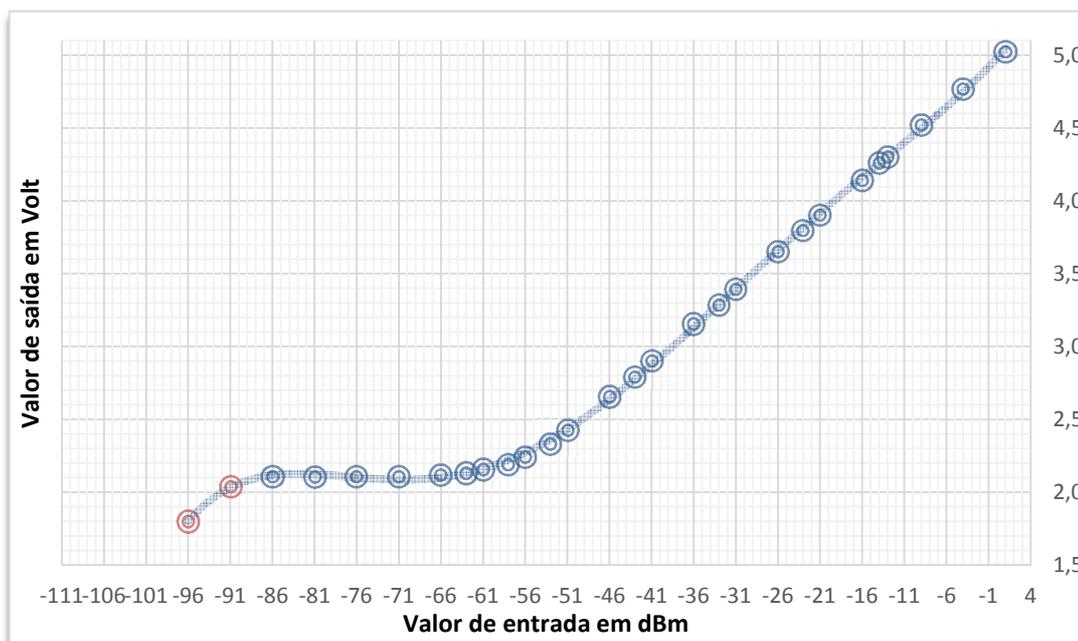


Figura 4-6 – Curva de Calibração do Analisador Anritsu MS2781B.

Com a esta curva foi possível converter todos os valores de volt para dBm e, desta forma, prosseguir com as análises restantes. Após a conversão, foi possível identificar quais pontos estavam no limiar de recepção do equipamento, bem como as medidas que estavam no piso de ruído do ambiente, sendo possível descartar estes valores, e restando, assim, a seguinte quantidade de medidas:

- Rota 1 – 2662 medidas úteis;
- Rota 2 – 1409 medidas úteis;
- Totalizando 4071 pontos medidos.

Para cada rota foi criada uma planilha, consolidando todas as informações das medições, gerando um banco de dados com todos os dados necessários para reprodução do ambiente de medições. A Tabela 4-1 e a Tabela 4-2 apresentam os primeiros 10 valores de cada rota.

Tabela 4-1 - Tabela com os primeiros pontos medidos da Rota 1.

Índice	Hora (pm)	Latitude	Longitude	Distância (m)	Pot. Medida (dBm)
1	01:22:21,0	-22,885998	-43,569795	8,45	-22
2	01:22:21,2	-22,885996	-43,569796	8,54	-21
3	01:22:21,4	-22,885994	-43,569797	8,63	-25
4	01:22:21,6	-22,885992	-43,569798	8,73	-21

5	01:22:21,8	-22,885990	-43,569799	8,84	-20
6	01:22:22,2	-22,885985	-43,569801	9,15	-24
7	01:22:22,4	-22,885983	-43,569801	9,35	-22
8	01:22:22,6	-22,885980	-43,569802	9,55	-26
9	01:22:22,8	-22,885978	-43,569802	9,76	-28
10	01:22:23,0	-22,885975	-43,569803	9,98	-24

Tabela 4-2 - Tabela com os primeiros pontos medidos da Rota 2.

Índice	Hora (pm)	Latitude	Longitude	Distância (m)	Pot. Medida (dBm)
1	06:02:36,0	-22,886090	-43,569676	18,62	-17
2	06:02:36,2	-22,886091	-43,569676	18,67	-16
3	06:02:36,6	-22,886094	-43,569675	18,77	-16
4	06:02:37,0	-22,886096	-43,569675	18,88	-16
5	06:02:37,6	-22,886100	-43,569675	18,99	-19
6	06:02:38,0	-22,886102	-43,569675	19,06	-21
7	06:02:38,4	-22,886105	-43,569675	19,16	-23
8	06:02:38,8	-22,886108	-43,569675	19,25	-28
9	06:02:39,2	-22,886112	-43,569675	19,38	-27
10	06:02:39,4	-22,886114	-43,569675	19,46	-25

4.2 ANÁLISE DAS MEDIDAS

A partir das tabelas, foram gerados dois gráficos, com as informações de distância de cada ponto (eixo horizontal em metros), e a intensidade do sinal (eixo vertical em dBm) com os valores medidos e a inclusão da curva da perda apenas por espaço livre para referência. É importante ressaltar que os valores medidos apresentados estão acrescidos do ganho do LNA utilizado na recepção do sistema de medição e, por isso, daqui em diante todos os cálculos levam em consideração este fator.

Como pode ser visto na Figura 4-7, ocorreram variações ao longo do percurso realizado de forma radial. Todos os valores medidos estão abaixo da curva da atenuação causada apenas pelo espaço livre, o que leva a concluir que existem atenuações complementares, neste caso, ocasionadas em sua maior parte pela difração.

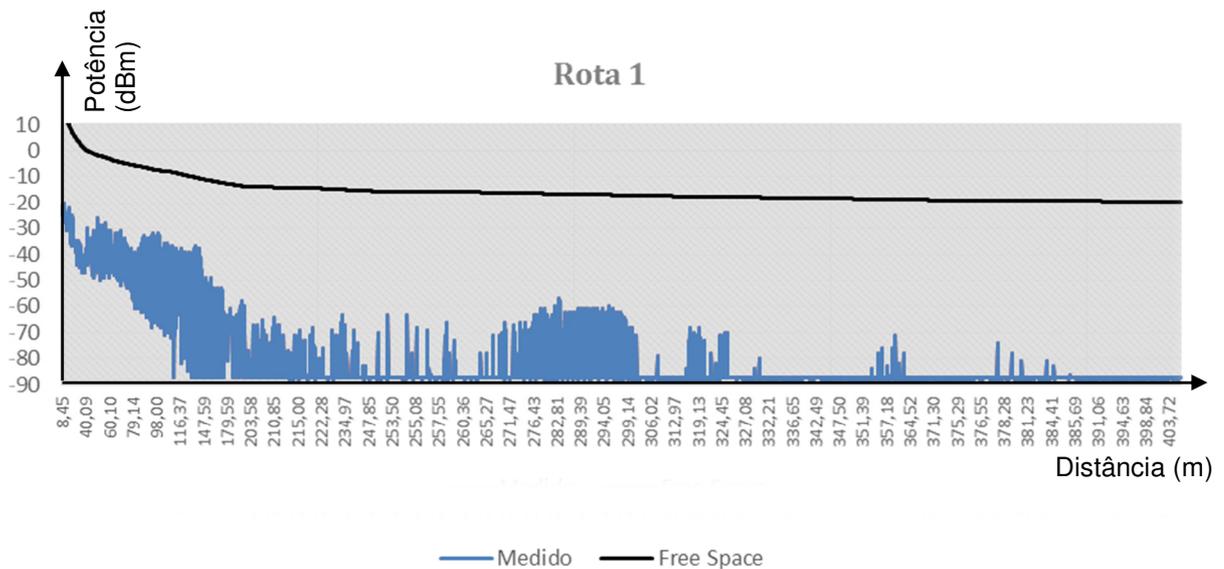


Figura 4-7 - Gráfico da rota 1 nas ruas de Campo Grande.

Já na Figura 4-8 se vê um comportamento mais similar à curva da perda ocasionada apenas pelo espaço livre, no entanto, as oscilações também estão presentes.

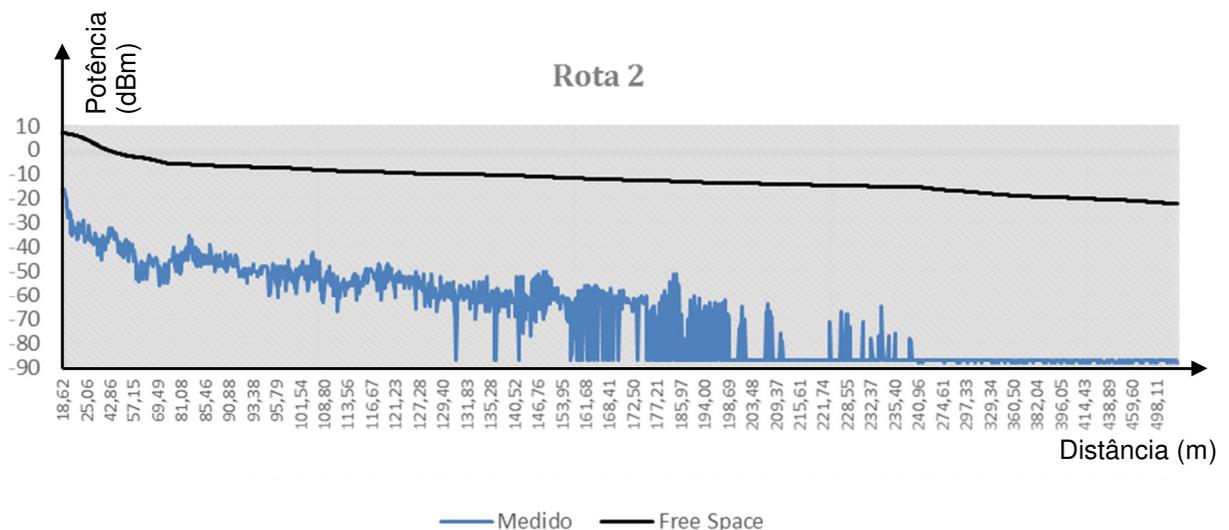


Figura 4-8 - Gráfico da rota 2 seguindo pela Av. Brasil.

4.3 COMPARAÇÃO COM VALORES TEÓRICOS

A fim de verificar qual método da UIT-R possui maior aderência aos valores medidos, foram realizadas predições para cada ponto medido, em campo, utilizando os métodos Gume de Faca em Cascata e Delta-Bullington. Apesar das medidas terem ocorrido com o veículo em movimento, foram utilizados os métodos ponto a ponto

supracitados, pois a velocidade do veículo era reduzida e o estudo contempla, apenas, a análise faixa estreita do sinal, ou seja, apenas a intensidade da portadora recebida, sem verificar os demais parâmetros como *doppler*, multipercursos, etc. Esta predição foi realizada utilizando as ferramentas *Celplanner* [26] e *Pathloss* [29], criando um enlace ponto a ponto para cada ponto medido, totalizando 8142 predições realizadas individualmente. Foi configurado, na ferramenta, o local de transmissão e, para cada um dos 4071 pontos de recepção, foi necessário inserir os dados de altura de recepção, ganho da antena de recepção, ganho do LNA, perda de interface e demais parâmetros já mencionados. Como base de dados, foram utilizadas a topografia e a morfologia do ambiente, pois em estudo realizado anteriormente [1] [2] estes apresentaram melhor aproximação com os valores medidos.

Com o término das predições teóricas, foram inseridos 16284 dados na tabela existente para iniciar o processo comparação dos modelos testados com os valores medidos em campo. A Tabela 4-3 mostra os primeiros resultados dos dois métodos utilizados com as respectivas medidas de campo.

Tabela 4-3 – Tabela comparativa com os métodos da UIT-R para a Rota 1.

Índice	Hora (pm)	Latitude	Longitude	Distância (m)	Pot. Medida [dBm]	Perda por Difração Cascade Knife Edge [dB]	Potência Recebida Predita [dBm]	Perda por Difração Delta-Bullington [dB]	Potência Recebida Predita [dBm]
1	01:22:21,0	-22,885998	-43,569795	8,45	-22	44,58	-35,78	44,58	-30,55
2	01:22:21,2	-22,885996	-43,569796	8,54	-21	44,68	-35,82	44,68	-30,45
3	01:22:21,4	-22,885994	-43,569797	8,63	-25	44,56	-35,77	44,56	-30,57
4	01:22:21,6	-22,885992	-43,569798	8,73	-21	44,44	-35,73	44,44	-30,68
5	01:22:21,8	-22,885990	-43,569799	8,84	-20	44,41	-35,71	44,41	-30,71
6	01:22:22,2	-22,885985	-43,569801	9,15	-24	44,29	-35,67	44,29	-30,83
7	01:22:22,4	-22,885983	-43,569801	9,35	-22	44,17	-35,63	44,17	-30,95
8	01:22:22,6	-22,885980	-43,569802	9,55	-26	44,13	-35,62	44,13	-30,99
9	01:22:22,8	-22,885978	-43,569802	9,76	-28	44,01	-35,59	44,01	-31,11
10	01:22:23,0	-22,885975	-43,569803	9,98	-24	43,89	-35,55	43,89	-31,22
11	01:22:23,2	-22,885971	-43,569803	10,38	-28	43,66	-35,50	43,66	-31,45
12	01:22:23,4	-22,885967	-43,569803	10,79	-31	43,55	-35,48	43,55	-31,56
13	01:22:23,6	-22,885962	-43,569803	11,20	-26	43,34	-35,45	43,34	-31,77
14	01:22:23,8	-22,885958	-43,569803	11,62	-29	43,23	-35,43	43,23	-20,87
15	01:22:24,0	-22,885954	-43,569803	12,04	-28	43,03	-35,41	43,03	-32,07
16	01:22:24,2	-22,885949	-43,569800	12,62	-25	42,88	-35,41	42,88	-32,21
17	01:22:24,4	-22,885945	-43,569798	13,19	-24	42,65	-35,40	42,88	-32,21
18	01:22:24,6	-22,885940	-43,569795	13,77	-22	42,44	-35,41	42,65	-32,43
19	01:22:24,8	-22,885936	-43,569793	14,35	-24	42,31	-35,42	42,43	-32,65

Para melhor visualização, foram gerados dois gráficos, ilustrados nas Figuras Figura 4-9 e Figura 4-10, onde se tem melhor detalhamento dos valores medidos e calculados e, novamente, com as informações de distância de cada ponto e o nível do sinal.

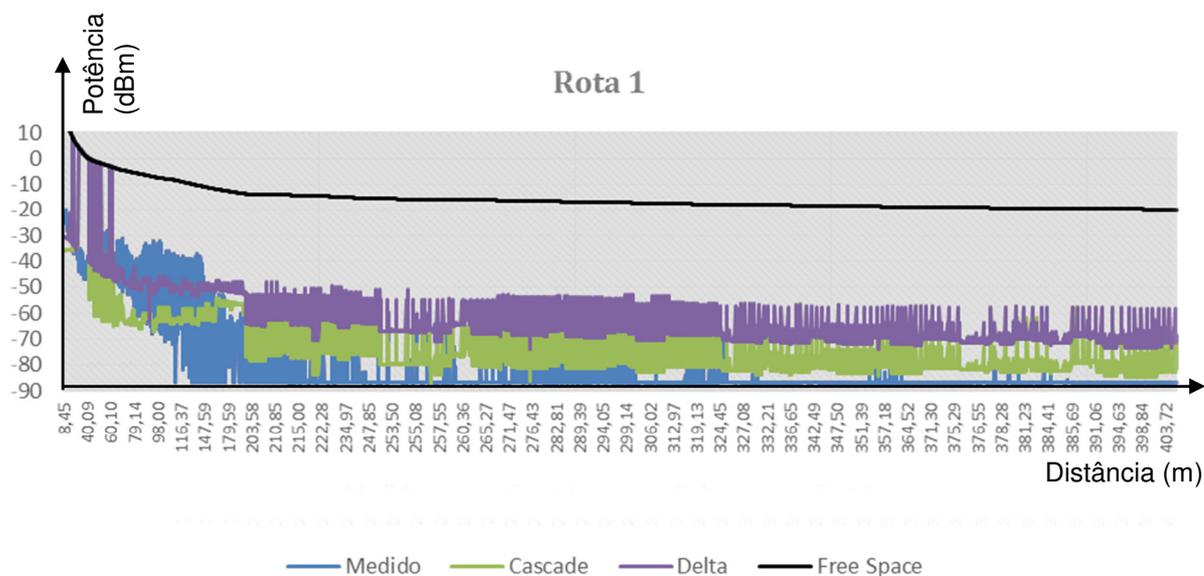


Figura 4-9 – Gráfico comparativo da Rota 1.

Como se pode observar na Figura 4-9, ambos os métodos se aproximam dos valores medidos e possuem variações do nível de recepção similares aos valores medidos, com maior diferença nas maiores distâncias. Para melhorar a visualização foi realizada uma interpolação de pontos, considerando apenas 50% dos pontos medidos.

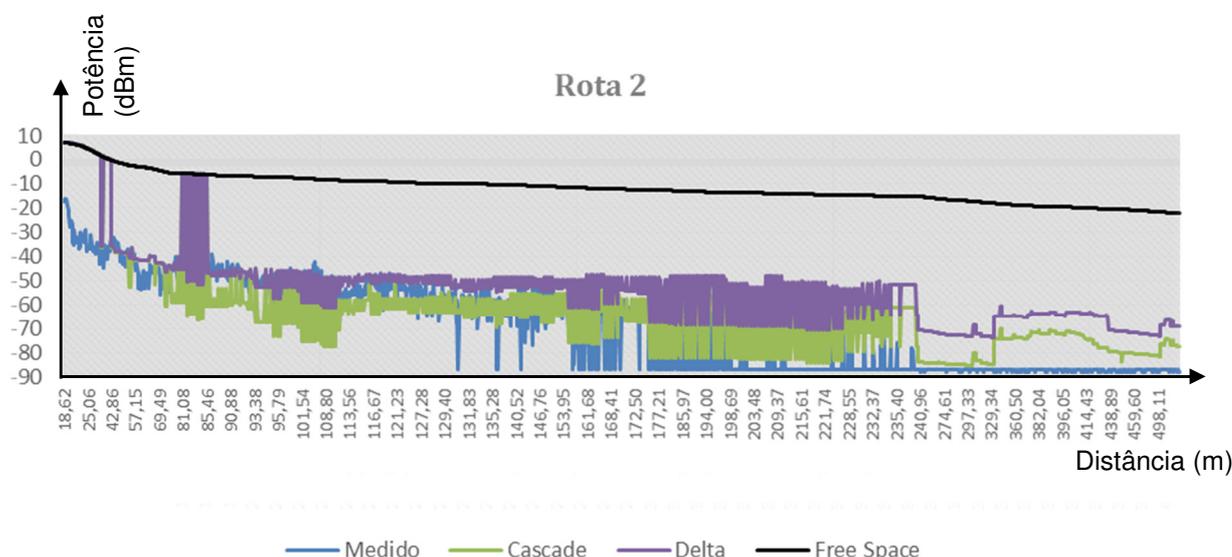


Figura 4-10 - Gráfico comparativo da Rota 2.

Na Figura 4-10, existe uma variação inicial onde os valores preditos se igualam a curva do espaço livre, no entanto, houve alguma perda complementar que não foi considerada teoricamente pelo perfil do enlace, mas na maioria dos casos o perfil do enlace é semelhante ao da Figura 4-11, com uma morfologia presente, ocasionando propagação por difração.

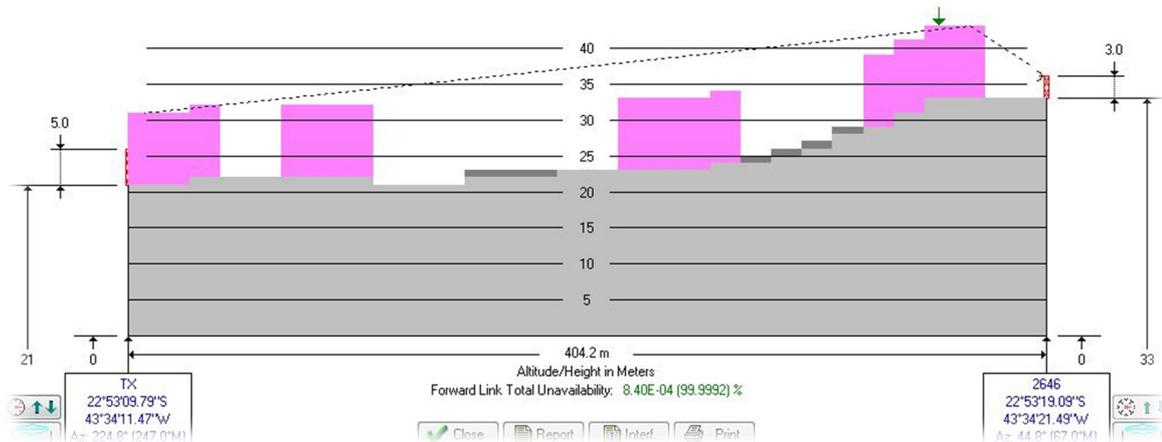


Figura 4-11 – Exemplo de um perfil de enlace com morfologia. [26]

Nas duas rotas, pode-se perceber que o método Delta-Bullington ficou ligeiramente acima do Gume de Faca em Cascata, sendo mais otimista em relação aos valores medidos. Para verificar numericamente esta aderência, é necessário realizar uma análise estatística destes dados.

4.4 ANÁLISE ESTATÍSTICA DOS DADOS

Buscando-se verificar qual dos dois métodos obteve melhor desempenho, foi utilizada a métrica D [29], que representa a diferença entre as áreas de duas curvas quaisquer, conforme descrito pela equação 4-1.

$$D = \int |f(x) - g(x)| dx \quad 4-1$$

Ao fazer o cálculo da diferença para cada ponto, através de D, é necessário somar essas diferenças ($D_1 + D_2 + \dots + D_n$), para obter L^1 , que representa o somatório das diferenças de cada ponto medido. A curva que melhor se aproxima da curva de referência será aquela que obtiver o menor valor de L^1 que, neste caso, por se tratar de valores discretos, é representada pela equação 4-2.

$$L^1 = \sum_{i=1}^{i=n} D(i) \quad 4-2$$

Aplicando-se a equação 4-2, obtêm-se os seguintes valores para cada método utilizado até o momento, em cada uma das rotas:

Tabela 4-4 – Métrica D aplicada nas Rota 1 e Rota 2.

	Free Space	Delta Bullington	Cascade Knife Edge
Rota 1	171969	53723	32305
Rota 2	79587	22576	16756

Com base nos valores apresentados na Tabela 4-4, o método que melhor se aproximou da curva dos valores medido, nas duas rotas, foi o método Gume de Faca em Cascata, pois apresentou o menor valor da métrica D.

Para melhor visualizar a representação destes valores, foram organizados de forma decrescente os desvios de cada valor predito com o valor medido, de maneira que é possível observar, graficamente, através da Figura 4-12 e da Figura 4-13, a variação dos desvios e sua média.

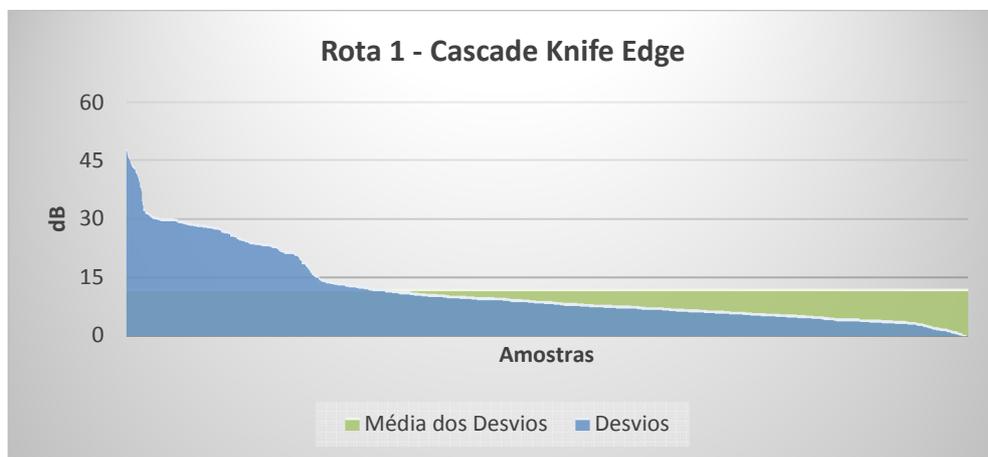


Figura 4-12 – Gráfico dos desvios da Rota 1.

Pode-se verificar na Figura 4-12, que o desvio médio dos valores na Rota 1 ficou em torno de 10 dB, com valor de desvio máximo próximo de 50 dB, mas em poucos casos.

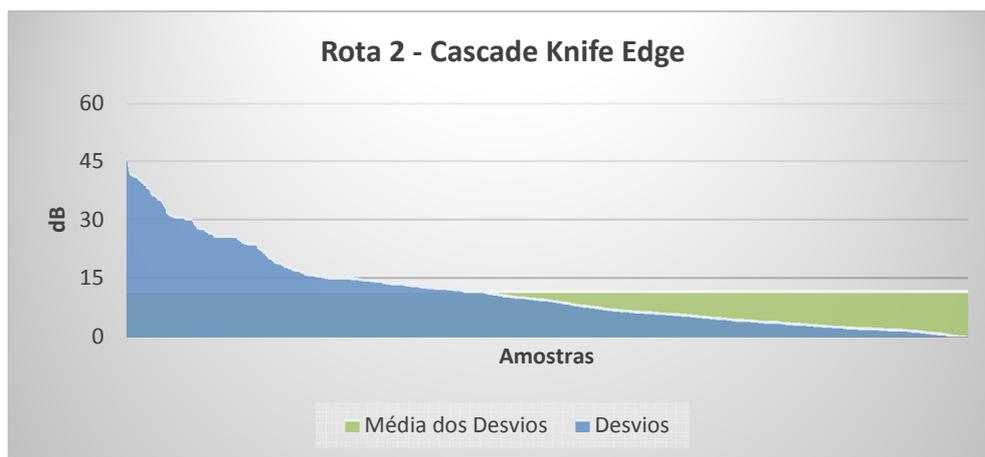


Figura 4-13 - Gráfico dos desvios da Rota 2.

Na segunda rota, Figura 4-13, tem-se comportamento parecido. Com base nos valores das médias dos desvios, para cada um dos métodos, é possível determinar o desvio padrão da média, conforme apresentado na Tabela 4-5:

Tabela 4-5 – Comparação estatística da Rota 1 e 2.

		Free Space	Delta Bullington	Cascade Knife Edge
ROTA 1	MÉDIA	64,6 dB	20,2 dB	12,1 dB
	DESVIO PADRÃO	11,2 dB	8,0 dB	9,3 dB
ROTA 2	MÉDIA	56,5 dB	16,0 dB	11,9 dB
	DESVIO PADRÃO	13,4 dB	11,5 dB	9,8 dB

Com o objetivo de facilitar a comparação do desempenho dos dois métodos em cada rota, foi gerada a Figura 4-14.

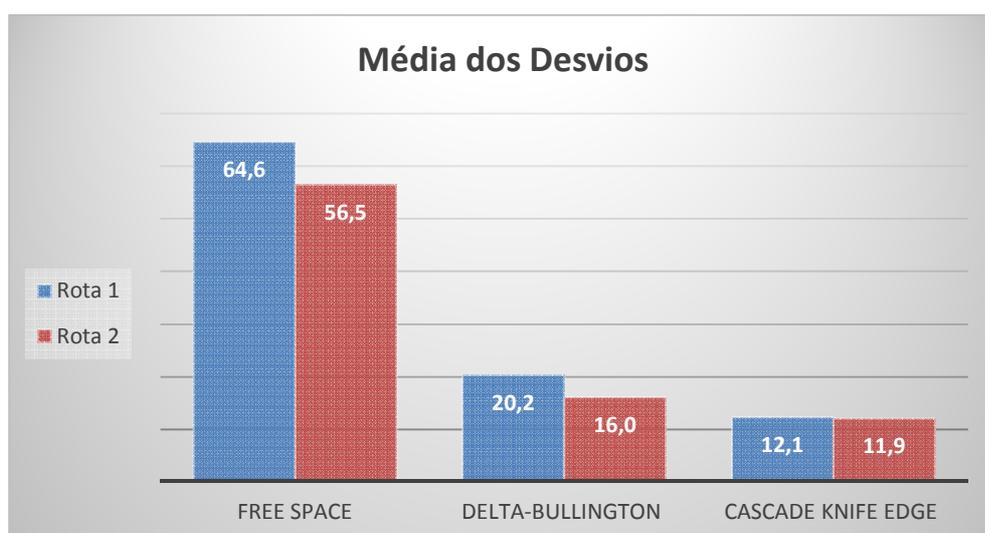


Figura 4-14 - Gráfico comparativo da média dos desvios nas duas rotas.

Pode-se verificar, nitidamente, que na região sondada o método Gume de Faca em Cascata apresenta menor desvio comparado aos outros 2 métodos, apresentando valor próximo de 12 dB, nas duas rotas. Este método será utilizado, portanto, no treinamento das RNAs, posteriormente, para verificar se será possível reduzir seu desvio médio.

5 IMPLEMENTAÇÃO DAS REDES NEURAIS ARTIFICIAIS

5.1 OBJETIVO DAS REDES NEURAIS NO TRABALHO PROPOSTO

Neste trabalho, serão utilizadas as redes neurais artificiais para modelar um cenário de propagação, utilizando parte dos valores teóricos calculados como base da informação de entrada para o treinamento da RNA. Os fenômenos associados à propagação, que estão considerados neste estudo, são as atenuações causadas, principalmente, pela difração e atenuação pelo espaço livre.

Após a aplicação da RNA será possível verificar se há possibilidade de reduzir os desvios médios dos modelos de predição utilizados, amplamente aplicados para o cálculo dos enlaces sob os mecanismos supracitados.

5.1.1 Utilização de RNAs para Predição de Cobertura

As RNAs são baseadas nas redes neurais humanas, constituídas de vários neurônios ou camadas de neurônios, que são interconectados através das *sinapses*, que são os sinais repassados de um neurônio a outro, transportando as informações e gerando resposta ao estímulo de entrada.

O emprego de redes neurais artificiais vem crescendo, ao longo dos anos, nas mais diversas áreas do conhecimento. O problema de predição de cobertura do sinal rádio via rede neural vem sendo empregado com resultados bastante interessantes [30] [31], inclusive na faixa de VHF [32] e de UHF [33], em terreno acidentado. Recentemente sua aplicação está voltada para ambientes *indoor* em sistemas WLAN [34] [35] [36] [37], onde não existem modelos que satisfaçam os cenários mais complexos de um ambiente interno. Como as RNAs têm se mostrado bem eficientes na melhoria da predição de cobertura, novos estudos [38] [39] [40] estão se aprofundando nos tipos de RNAs utilizadas, com o objetivo de buscar melhores resultados dentre os modelos existentes, alterando algoritmos de treinamento e convergência.

Partindo do estudo de RNAs, as mesmas foram empregadas com o fim de modelar a predição do canal rádio sujeito à difração. Uma das características marcantes do uso das RNAs é, exatamente, a não necessidade da existência de um modelo matemático pré-existente. Para que seja eficiente, a RNA deve ser treinada de maneira adequada com vetores de entrada reais, de forma que a mesma adquira experiência. Quanto melhor a qualidade desses vetores e com um treinamento

adequado, a RNA tende a ficar cada vez mais funcional, até que comece a ter capacidade de tomar decisões com altas taxas de acerto, baseadas nos padrões reconhecidos em seu treinamento [41].

5.1.2 Vantagens e Desvantagens na utilização das RNAs

Como toda ferramenta, as RNAs possuem vantagens e desvantagens na sua utilização.

- Vantagens:
 - Aprendizado;
 - Generalização;
 - Robustez;
 - Não necessidade da existência de um modelo matemático pré-existente.
- Desvantagens:
 - Instabilidade nas redes com realimentação;
 - Diversos mínimos locais;
 - Correlação entre características nos dados de entrada;
 - Ruído não correlacionado.

Baseando-se nessas características, será feito uso das RNAs para se tentar alcançar o máximo do seu desempenho.

5.2 TREINAMENTO DA REDE

Uma das etapas que necessitam de atenção especial na hora de criar uma RNA é escolher como será o seu aprendizado. Atualmente, existem diversas pesquisas com as mais variadas abordagens relacionadas às redes biológicas e neurais. É importante citar que o aprendizado não é um processo único e, dependendo do tipo de aplicação, deve-se buscar o método mais apropriado. Existem diferentes processos de aprendizado, cada um mais adequado para cada tipo de rede.

Neste trabalho, será abordado o treinamento do tipo supervisionado, mantendo as mesmas características do anterior [1] [2]. Neste tipo de treinamento, é necessário que se forneça para a rede um conjunto de informações, ou seja, é necessário que exista um vetor entrada e saída para que a rede correlacione o valor fornecido com o valor esperado, de alguma forma.

A base de dados disponibilizada para o uso da RNA é dividida em dois grupos chamados de conjunto de treinamento e o conjunto de validação. A rede deve ser treinada através do conjunto de treinamento e depois testada através do segundo conjunto e ajustar o peso das *sinapses*. Os pesos são ajustados sempre que houver um novo treinamento da rede, deve-se realizar a validação do treinamento até que sua eficiência alcance o patamar desejado. [42]

5.2.1 Base de Dados

Para implementação das RNAs, serão utilizados os dados medidos em campo e os valores calculados pelo método Gume de Faca em Cascata, por ter apresentado menor desvio médio. Na prática, as distâncias de cada ponto medido ao transmissor serão utilizadas como vetores de entrada, juntamente com a perda causada por difração e a predição teórica do método da UIT-R. O vetor de saída da RNA será a intensidade do campo elétrico em cada ponto medido, em dBm.

Outros dados poderiam ser fornecidos para o treinamento das RNAs, como a quantidade e altura dos obstáculos presentes na linha de visada, quantidade de pontos de reflexão na trajetória, no entanto, são informações que possuem maior influência no estudo do desvanecimento em pequena escala do sinal, não sendo utilizado para este estudo de predição de cobertura de faixa estreita [8], que trabalha com a informação de grande escala do sinal. As informações de frequência, potência de transmissão e altura da antena de transmissão e do móvel não serão fornecidas durante o treinamento, pois são valores estáticos durante toda a bateria de testes. A inclusão destes dados no treinamento seria relevante caso houvessem mais medições com variações destes parâmetros. Este item será abordado em trabalhos futuros.

5.2.2 Ambiente de Simulação

De maneira geral, foi utilizada uma rede de múltiplas camadas *Multilayer Perceptron* (MLP) com algoritmo de treinamento *Backpropagation* [43] e de convergência *Levenberg-Marquardt* [44] [45], já implementado no *Matlab*. O algoritmo de aprendizado usado no ajuste dos pesos da rede MLP é um fator relevante para o seu desempenho.

O *Matlab* disponibiliza um pequeno *toolbox* para o treinamento da rede e, depois que a rede é treinada, é possível utilizá-la para realizar a predição de cobertura, bastando fornecer os parâmetros de entrada. Deste modo, a rede funcionará conforme

o esquemático da Figura 5-1, onde será necessário fornecer, neste estudo, 2 ou 3 dados de entrada, dependendo da RNA que for utilizada, para que ela possa realizar a predição de cobertura. Os programas, em *Matlab*, estão detalhados no capítulo 9 desta dissertação.

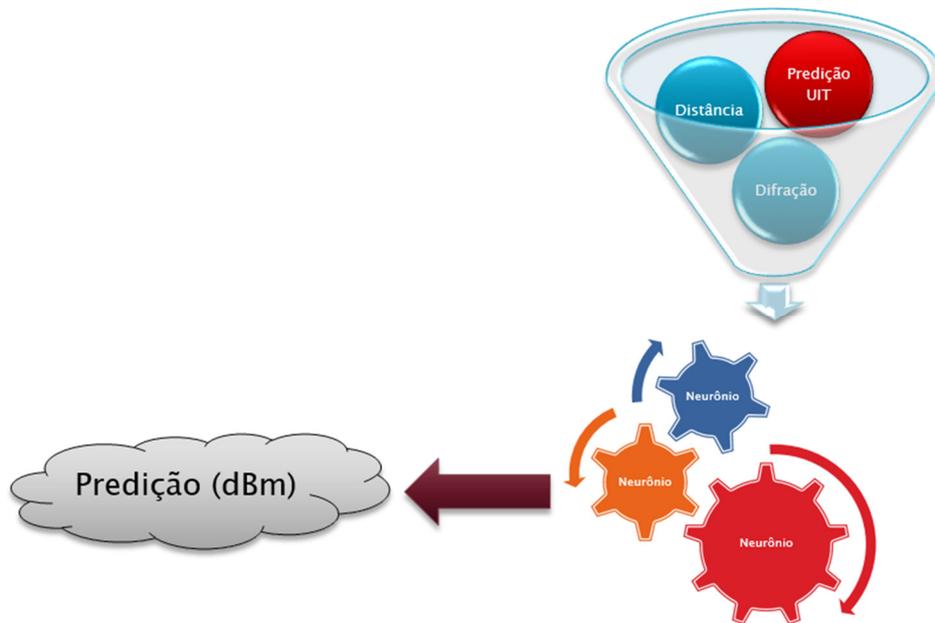


Figura 5-1 – Esquemático do funcionamento da RNA.

5.3 RESUMO DOS PARÂMETROS DAS RNAS

Foram criadas várias RNAs, com configurações distintas, para verificação do grau de acerto de cada uma delas posteriormente.

Seguem os parâmetros que foram utilizados para criação das redes criadas para este estudo:

- Tipo de Rede:
 - *Feedforward* MLP;
- Quantidade de neurônios na camada escondida:
 - 10 neurônios;
 - 30 neurônios;
- Divisão do Treinamento:
 - 1/3 de todos os dados para o treinamento;
 - 1/4 de todos os dados para o treinamento;
- Dados de entrada (*input*):
 - Distância e perda por difração;

- Distância, perda por difração e valor predito;
- Dado de saída (*output*):
 - Predição com a unidade de potência em dBm.

Com base nessas premissas foram criados 2 grupos de 8 RNAs cada, onde cada uma das RNAs de um mesmo grupo possuirá diferentes estruturas. As RNAs de 1 a 8 utilizarão como base de dados de treinamento as medidas da rota 1 (Grupo 1) e as RNAs de 9 a 16 utilizarão como base de dados de treinamento as medidas da rota 2 (Grupo 2), totalizando 16 RNAs. No grupo 1 a configuração das RNAs ocorrerá de acordo com o esquemático ilustrado na Figura 5-2:

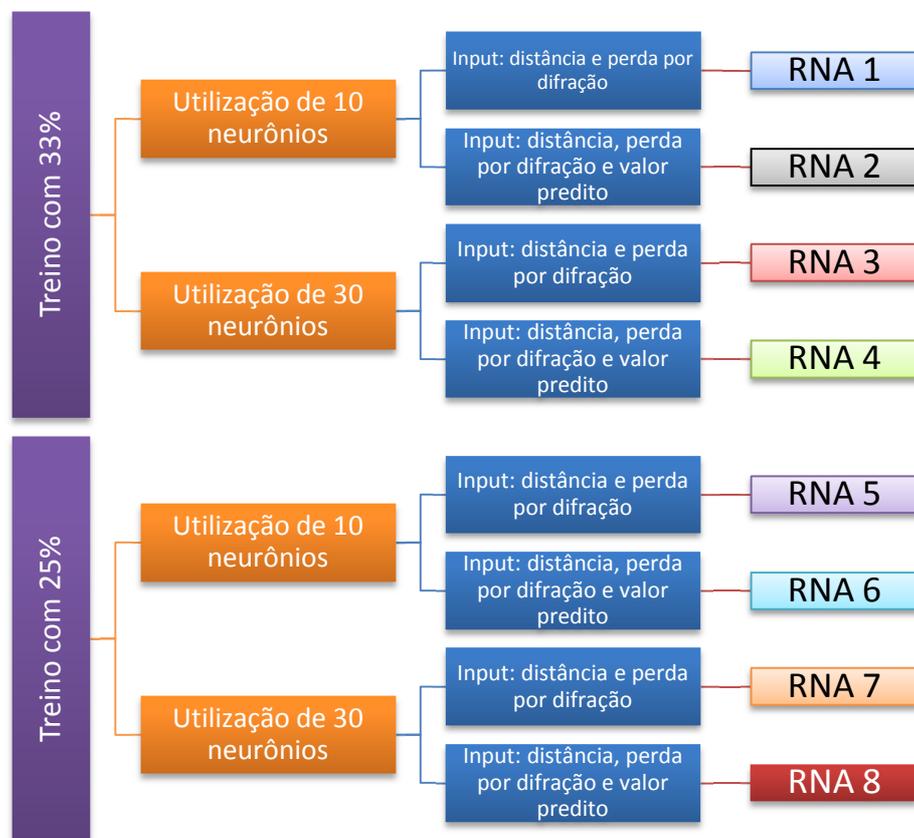


Figura 5-2 - Organização das RNAs da Rota 1.

5.4 FUNCIONAMENTO DAS RNAS

A configuração das redes do Grupo 1 ocorreu da seguinte forma:

- RNA 1 – Foi treinada utilizando apenas 33% da base de dados da Rota 1; possui em sua camada escondida 10 neurônios e, para seu funcionamento, foi necessário fornecer a distância do enlace e a perda

por difração calculada pelo método da UIT-R, que na região sondada mostrou ser o Gume de Faca em Cascata o de melhor ajuste;

- RNA 2 – Foi treinada utilizando apenas 33% da base de dados; possui em sua camada escondida 10 neurônios e, para seu funcionamento, foi necessário fornecer a distância do enlace, a perda por difração calculada pelo método Gume de Faca em Cascata e o valor predito final.
- RNA 3 – Foi treinada utilizando apenas 33% da base de dados, possui em sua camada escondida 30 neurônios e, para seu funcionamento, foi necessário fornecer a distância do enlace e a perda por difração calculada pelo método Gume de Faca em Cascata.
- RNA 4 – Foi treinada utilizando apenas 33% da base de dados; possui em sua camada escondida 30 neurônios e, para seu funcionamento, foi necessário fornecer a distância do enlace, a perda por difração calculada pelo método Gume de Faca em Cascata e o valor predito final.
- RNA 5 – Foi treinada utilizando apenas 25% da base de dados; possui em sua camada escondida 10 neurônios e, para seu funcionamento, foi necessário fornecer a distância do enlace e a perda por difração calculada pelo método Gume de Faca em Cascata.
- RNA 6 – Foi treinada utilizando apenas 25% da base de dados; possui em sua camada escondida 10 neurônios e, para seu funcionamento, foi necessário fornecer a distância do enlace, a perda por difração calculada pelo método Gume de Faca em Cascata e o valor predito final.
- RNA 7 – Foi treinada utilizando apenas 25% da base de dados; possui em sua camada escondida 30 neurônios e, para seu funcionamento, foi necessário fornecer a distância do enlace e a perda por difração calculada pelo método Gume de Faca em Cascata.
- RNA 8 – Foi treinada utilizando apenas 25% da base de dados; possui em sua camada escondida 30 neurônios e, para seu funcionamento, foi necessário fornecer a distância do enlace, a perda por difração calculada pelo método Gume de Faca em Cascata e o valor predito final.

O mesmo padrão de construção e funcionamento ocorreu para o Grupo 2, no entanto, sua base de dados de treinamento foi da Rota 2, que possui seu esquemático ilustrado na Figura 5-3.

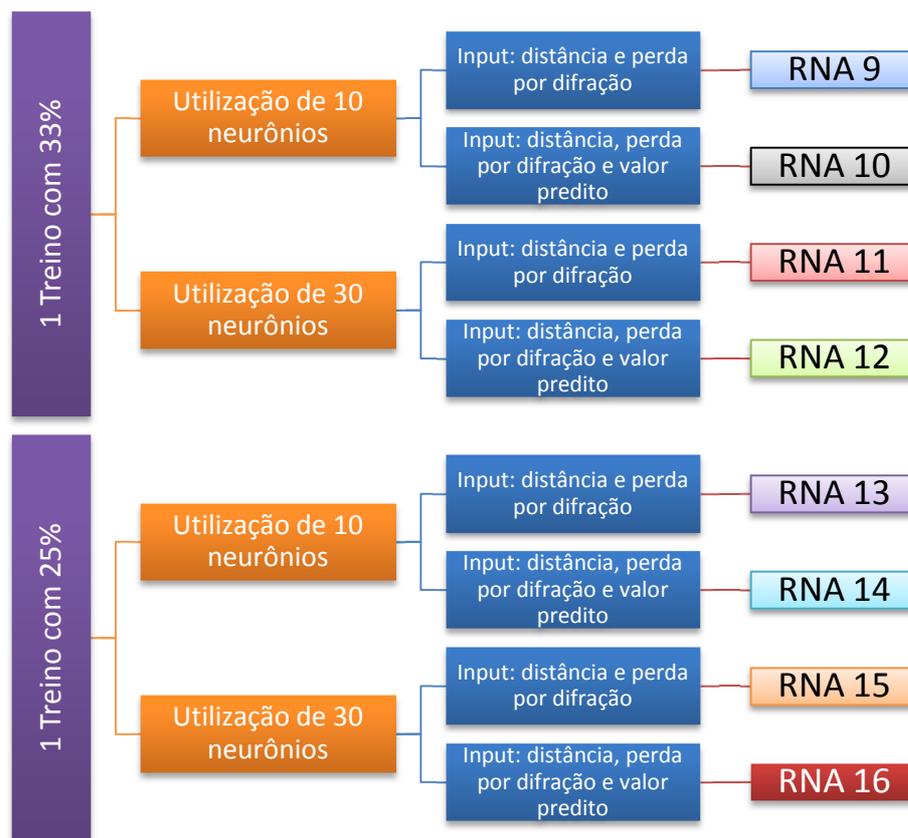


Figura 5-3 - Organização das RNAs da Rota 2.

O treinamento de cada uma das 16 redes foi realizado apenas em uma única rodada, sendo dividido em 3 etapas: treinamento, validação e teste, onde essas 3 etapas ocorrem dentro da quantidade pré-determinada da base de dados cedida, que neste estudo foi de 1/3 ou 1/4. Em seguida, realizada a predição dos demais pontos não utilizados em seu treinamento (2/3 ou 3/4).

A seguir, na Figura 5-4, um exemplo de construção de uma RNA, baseado nos parâmetros informados anteriormente.

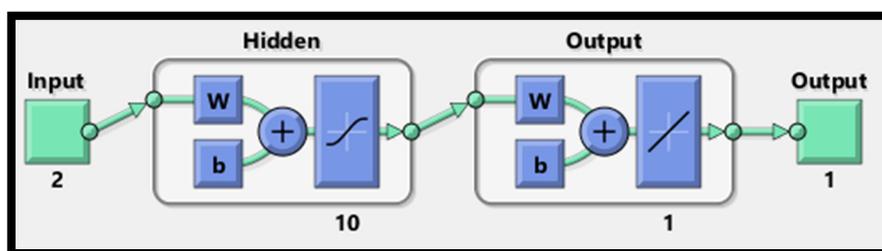


Figura 5-4 - Configuração com 2 entradas e 10 neurônios. (Fonte: Matlab)

As RNAs 1, 5, 9 e 13 possuem esta mesma configuração, ou seja, são necessários dois dados de entrada para seu funcionamento (distância em metros e perda por difração em dB), onde serão “processados” pelos 10

neurônios de sua camada escondida, que fornecerá uma única saída, a predição de cobertura em dBm.

O esquemático ilustrado na Figura 5-5 mostra o princípio de funcionamento do treinamento de cada uma das RNAs propostas.

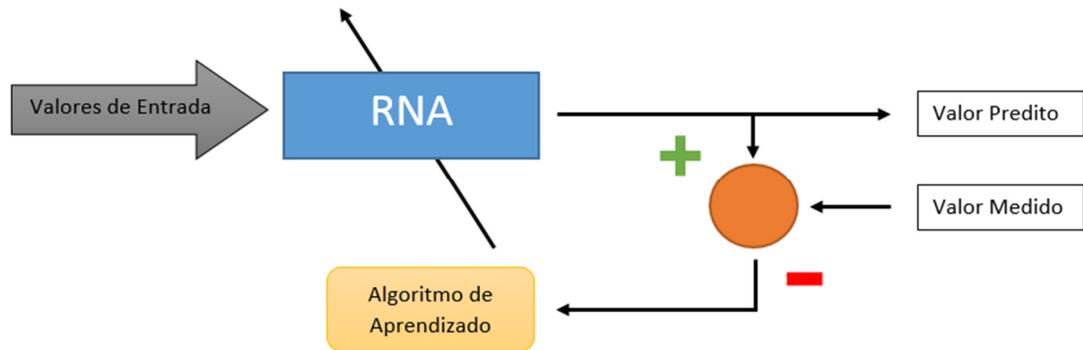


Figura 5-5 – Esquemático do treinamento de cada RNA.

Com as informações de entrada, distância em metros, perda por difração em dB, e, quando aplicado, o valor predito pela UIT em dBm, a RNA em treinamento ajusta os pesos de seus neurônios associando o seu valor predito ao valor medido. Este algoritmo de aprendizado se ajusta enquanto durar o treinamento e utiliza parte de sua base de dados de treinamento para validar sua taxa de acerto.

6 RESULTADOS

6.1 UNIFICAÇÃO DOS DADOS

Com base nos valores medidos, calculados e preditos pelas RNAs, foram criadas a Tabela 6-1 e a Tabela 6-2, com as primeiras 10 linhas, unificando todas as informações de cada rota medida e os valores medidos em campo, ambos em dBm.

Tabela 6-1 – Tabela comparativa unificada da Rota 1.

Índice	RNA1	RNA2	RNA3	RNA4	RNA5	RNA6	RNA7	RNA8	Medido (dBm)
01	-25,15	-23,45	-19,74	-19,58	-26,85	-25,35	-22,44	-18,96	-22
02	-25,14	-23,33	-19,06	-19,17	-26,87	-25,54	-22,14	-18,48	-21
03	-25,23	-23,48	-19,69	-19,73	-26,90	-25,50	-22,46	-19,11	-25
04	-25,33	-23,65	-20,33	-20,27	-26,92	-25,45	-22,78	-19,73	-21
05	-25,39	-23,66	-20,41	-20,44	-26,95	-25,54	-22,84	-19,92	-20
06	-25,56	-23,84	-20,86	-21,02	-27,03	-25,69	-23,12	-20,57	-24
07	-25,70	-24,01	-21,41	-21,55	-27,09	-25,73	-23,42	-21,19	-22
08	-25,80	-24,08	-21,46	-21,76	-27,14	-25,87	-23,49	-21,43	-26
09	-25,94	-24,27	-22,00	-22,26	-27,20	-25,90	-23,79	-22,03	-28
10	-26,08	-24,43	-22,53	-22,76	-27,26	-25,96	-24,09	-22,62	-24

Tabela 6-2 – Tabela comparativa unificada da Rota 2.

Índice	RNA9	RNA10	RNA11	RNA12	RNA13	RNA14	RNA15	RNA16	Medido (dBm)
01	-31,31	-23,54	-22,89	-25,50	-33,36	-27,85	-33,45	-28,25	-17
02	-31,31	-23,63	-22,96	-25,58	-33,38	-27,89	-33,47	-28,32	-16
03	-31,32	-23,74	-23,11	-25,63	-33,42	-27,94	-33,50	-28,37	-16
04	-31,33	-23,88	-23,26	-25,72	-33,46	-27,99	-33,54	-28,45	-16
05	-31,34	-23,99	-23,41	-25,78	-33,50	-28,04	-33,57	-28,50	-19
06	-31,35	-24,12	-23,51	-25,88	-33,53	-28,09	-33,60	-28,59	-21
07	-31,36	-24,25	-23,64	-25,98	-33,57	-28,14	-33,63	-28,68	-23
08	-31,37	-24,42	-23,78	-26,11	-33,61	-28,20	-33,66	-28,79	-28
09	-31,38	-24,56	-23,95	-26,18	-33,66	-28,26	-33,70	-28,86	-27
10	-31,39	-24,72	-24,07	-26,32	-33,69	-28,32	-33,73	-28,98	-25

A partir dos dados expostos nas tabelas, foram gerados gráficos individuais para melhor visualização das curvas dos valores medidos e dos valores preditos pelas RNAs. Segue, na Figura 6-1, um exemplo de uma curva dos dados medidos em dBm, ao longo do percurso, com a utilização de uma RNA para verificar se houve uma redução do desvio médio.

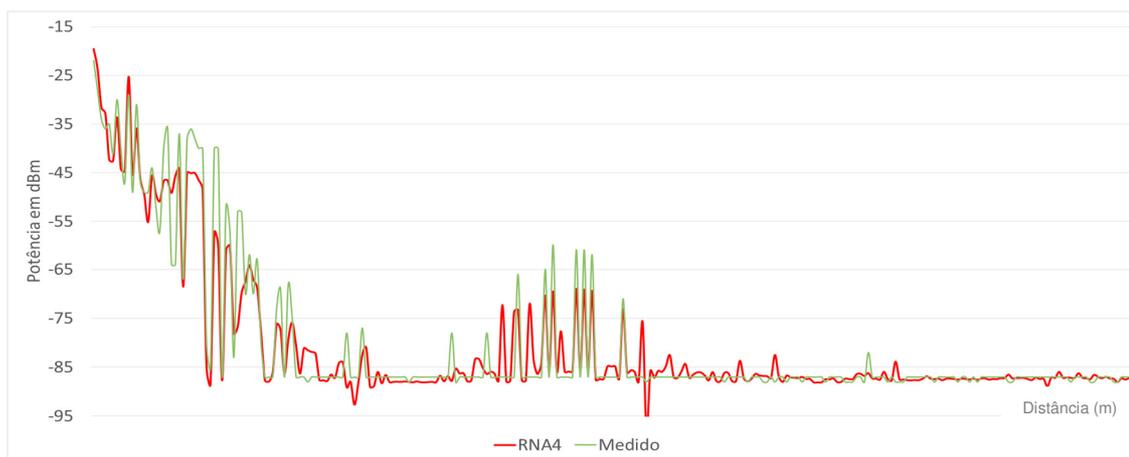


Figura 6-1 - Comparativo entre a RNA 4 e os valores medidos.

Na Figura 6-1 pode-se verificar o comparativo dos valores previstos pela RNA 4, em vermelho, com os dados medidos da Rota 1, em verde. Para não poluir o gráfico foram utilizados apenas 10% de todos os pontos medidos. Como pode-se observar, a RNA 4 apresentou uma boa aderência aos valores medidos, no entanto, faz-se necessário realizar a análise estatística para verificar numericamente se a RNA 4 conseguiu reduzir o desvio médio.

6.2 ANÁLISE ESTATÍSTICA DOS DADOS

Com os dados organizados, foi possível aplicar a métrica D e calcular o desvio médio de cada RNA utilizada, conforme apresentado na Tabela 6-3 e na Tabela 6-4.

Tabela 6-3 – Métrica D das RNAs do Grupo 1 aplicadas na Rota 1.

Rota 1								
	RNA1	RNA2	RNA3	RNA4	RNA5	RNA6	RNA7	RNA8
Média dos Desvios [dB]	3,39	3,58	2,88	2,86	3,70	3,77	3,50	3,53
Métrica D - L1	9029,71	9540,34	7668,85	7614,02	9839,20	10031,64	9322,01	9409,36
Desvio Padrão	4,87	5,24	5,56	4,55	5,32	5,36	4,99	4,61

O menor desvio apresentado foi da RNA4 com 2,86 dB e a o maior desvio apresentado foi da RNA6 com 3,77 dB. Não ocorreu uma variação muito grande dos desvios neste grupo, ficando em torno de 3,5 dB.

Tabela 6-4 – Métrica D das RNAs do Grupo 2 aplicadas na Rota 2.

Rota 2								
	RNA9	RNA10	RNA11	RNA12	RNA13	RNA14	RNA15	RNA16
Média dos Desvios [dB]	4,01	3,95	4,05	4,20	3,81	4,04	4,06	3,86
Métrica D - L1	5650,70	5569,40	5707,49	5916,85	5366,69	5695,45	5726,33	5443,36
Desvio Padrão	4,58	4,52	4,62	5,29	4,83	4,74	5,06	5,05

O menor desvio apresentado foi da RNA13 com 3,81 dB e a o maior desvio apresentado foi da RNA12 com 4,20 dB. Também não ocorreu uma variação muito grande dos desvios neste grupo, ficando em torno de 4 dB.

É possível verificar que o pior desempenho de aperfeiçoamento das RNAs (RNA 12 - 4,2 dB) foi, aproximadamente, 3 vezes menor que o melhor desempenho dos métodos da UIT-R (Gume de Faca em Cascata – 11,9 dB), aplicados individualmente na região sondada, conforme já visto na Figura 4-14. Pode-se afirmar que as RNAs, neste teste direto, conseguiu aperfeiçoar a predição de cobertura consideravelmente, no entanto, é necessário explorar novos cenários para verificarmos sua capacidade de manter alto grau de acerto e generalizar para novas bases de dados.

6.3 COMPARAÇÃO DO DESEMPENHO COM TESTE CRUZADO

Com o objetivo de ampliar a quantidade de cenários para verificar o desempenho das RNAs, foram realizados testes cruzados, ou seja, as RNAs do grupo 1 (RNA 1 a RNA 8) foram utilizadas para realização da predição de cobertura da rota 2, e as RNAs do grupo 2 (RNA 9 a RNA 16) foram utilizadas para realização da predição de cobertura da rota 1.

Foi realizada a mesma análise estatística para o teste cruzado e os dados foram consolidados na Tabela 6-5 e na Tabela 6-6. O menor desvio apresentado foi da RNA6 com 5,04 dB e a o maior desvio apresentado foi da RNA4 com 16,14 dB. No teste realizado em seu próprio grupo de treinamento essas duas redes tiveram desempenho oposto, sendo a RNA4 com menor desvio e a RNA6 o maior desvio. No próximo capítulo é avaliado qual parâmetro ou parâmetros podem ter contribuído para esta alteração.

Tabela 6-5 – Métrica D das RNAs do Grupo 1 aplicadas na Rota 2

Rota 2								
	RNA1	RNA2	RNA3	RNA4	RNA5	RNA6	RNA7	RNA8
Média dos Desvios [dB]	7,16	10,21	13,89	16,14	8,80	5,04	10,82	12,16
Métrica D - L1	10085,65	14382,66	19565,78	22736,51	12405,96	7099,12	15243,19	17139,13
Desvio Padrão	7,08	9,49	15,29	20,41	9,28	5,38	13,09	15,45

O menor desvio apresentado foi da RNA6 com 5,04 dB e a o maior desvio apresentado foi da RNA4 com 16,14 dB. No teste realizado em seu próprio grupo de treinamento essas duas redes tiveram desempenho oposto, sendo a RNA4 com menor desvio e a RNA6 o maior desvio. No próximo capítulo foi avaliado qual parâmetro ou parâmetros podem ter contribuído para esta alteração.

Tabela 6-6 – Métrica D das RNAs do Grupo 2 aplicadas na Rota 1

Rota 1								
	RNA9	RNA10	RNA11	RNA12	RNA13	RNA14	RNA15	RNA16
Média dos Desvios [dB]	4,29	4,43	9,03	4,12	3,56	4,21	7,23	4,25
Métrica D - L1	11425,30	11782,86	24024,93	10957,12	9474,09	11218,87	19233,48	11314,40
Desvio Padrão	6,27	6,47	17,19	5,92	6,06	6,70	7,51	6,35

O menor desvio apresentado também foi da RNA13 com 3,56 dB e a o maior desvio apresentado foi da RNA11 com 9,03 dB. Neste caso, a RNA13 permaneceu como sendo a rede com menor desvio apresentado, em ambos os testes, direto e cruzado. No geral a média dos desvios ficou em torno de 4 dB, onde apenas 2 redes fugiram do padrão.

6.4 CONSOLIDAÇÃO DOS TESTES

A partir dos dados expostos nas seções anteriores, foi possível consolidar todas as informações das tabelas apresentadas em capítulos anteriores, para avaliação do desempenho individual das redes. Na Tabela 6-7 são apresentados os dados estatísticos gerais de cada RNA em cada rota, e os métodos utilizados recomendados pela UIT-R.

Tabela 6-7 – Desvios médios de todos os métodos nas duas rotas.

	Rota 1 (dB)	Rota 2 (dB)
RNA 1	3,39	7,16
RNA 2	3,58	10,21
RNA 3	2,88	13,89
RNA 4	2,91	16,14
RNA 5	3,70	8,80
RNA 6	3,77	5,04
RNA 7	3,50	10,82
RNA 8	3,53	12,16
RNA 9	4,29	4,01
RNA 10	4,43	3,95
RNA 11	9,03	4,05
RNA 12	4,12	4,20
RNA 13	3,56	3,81
RNA 14	4,21	4,04
RNA 15	7,23	4,06
RNA 16	4,25	3,86
C.K.E	12,10	11,90
Delta B.	20,20	16,00

Para se ter uma visualização macro do desempenho de todas as RNAs e dos dois métodos da UIT-R, aplicados na região em questão, foram gerados dois gráficos comparativos do desempenho de cada RNA em seus dois testes, rota 1 e rota 2, expressos na Figura 6-2 e Figura 6-3.

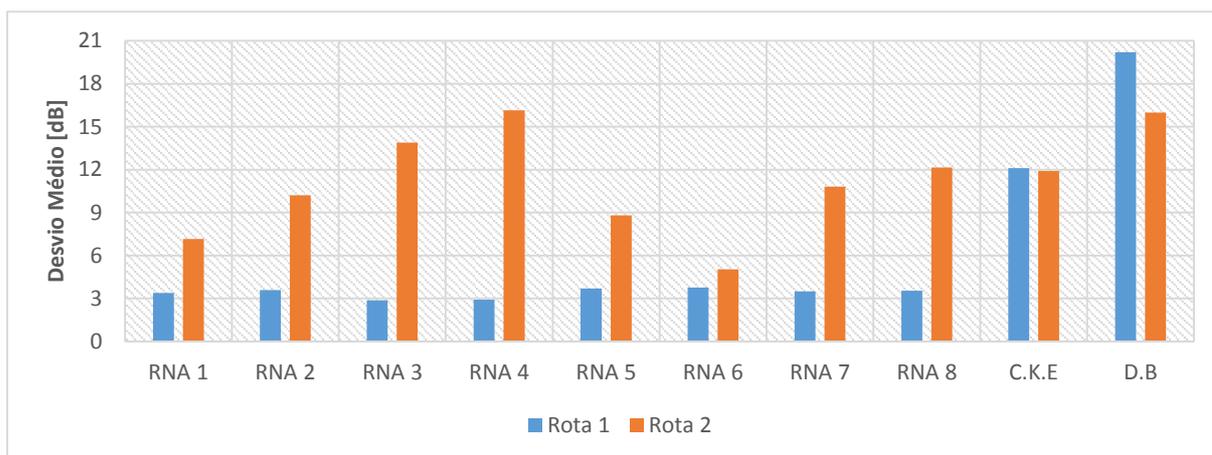


Figura 6-2 - Comparativo de desempenho do grupo 1.

Pode-se perceber pela Figura 6-2, que as RNAs do Grupo 1 conseguiram aperfeiçoar bem os desvios quando foram aplicadas em sua própria base de dados, no entanto, quando foram aplicadas na Rota 2, apresentaram desvios maiores.

Apenas 2 de 8 RNAs (25%) não conseguiram aperfeiçoar os desvios do método Gume de Faca em Cascata, que foram justamente as 2 RNAs que apresentaram melhores resultados quando foram aplicadas na Rota 1 (RNA 3 e RNA 4).

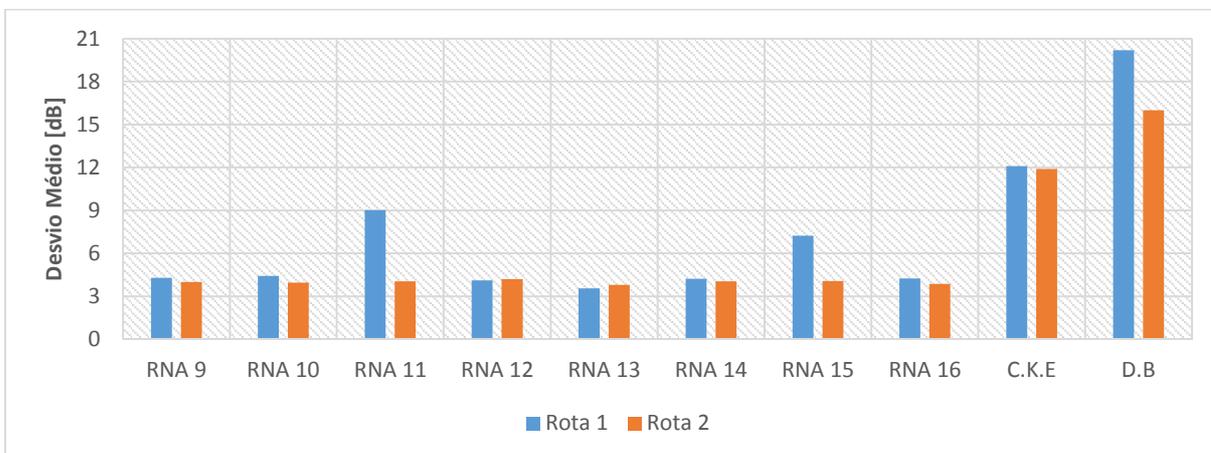


Figura 6-3 - Comparativo de desempenho do grupo 2.

Já na Figura 6-3, houve uma maior homogeneidade das RNAs do Grupo 2 nas duas rotas. Em todos os casos, as RNAs conseguiram aperfeiçoar a predição de cobertura do método Gume de Faca em Cascata e, em alguns casos, tiveram melhor desempenho quando aplicadas no grupo em que não foi utilizada a base de dados em seu treinamento, como por exemplo, RNA 12 e RNA 13.

No próximo capítulo foi realizada uma avaliação para tentar identificar se existe algum ou alguns parâmetros fundamentais para o processo de otimização da predição de cobertura.

6.5 AVALIAÇÃO INDIVIDUAL DE DESEMPENHO

Como visto anteriormente, foi utilizado um padrão na criação das RNAs para que, além da avaliação individual do seu desempenho, fosse possível comparar o seu desempenho com as demais RNAs, verificando qual parâmetro em sua construção poderia influenciar diretamente em seu desempenho.

Analisando a estrutura exposta na Figura 5-2, pode-se comparar o desempenho das RNAs que diferem apenas em alguns pontos específicos, como o tamanho da base de dados utilizada em seu treinamento, a quantidade de neurônios utilizado e a quantidade de *inputs* fornecidos. A mesma avaliação pode ser feita com o grupo 2, Figura 5-3.

6.5.1 Diferença da Base de Dados (BD)

Para verificar se o tamanho da base de dados fornecida em seu treinamento influenciou no desempenho final, é necessário comparar as RNAs que possuem as mesmas características treinadas na mesma base de dados, diferindo apenas no tamanho da base de dados utilizada em seu treinamento. Estão ilustrados, na Figura 6-4 e Figura 6-5, os desvios agrupados pelas RNAs de mesma configuração.

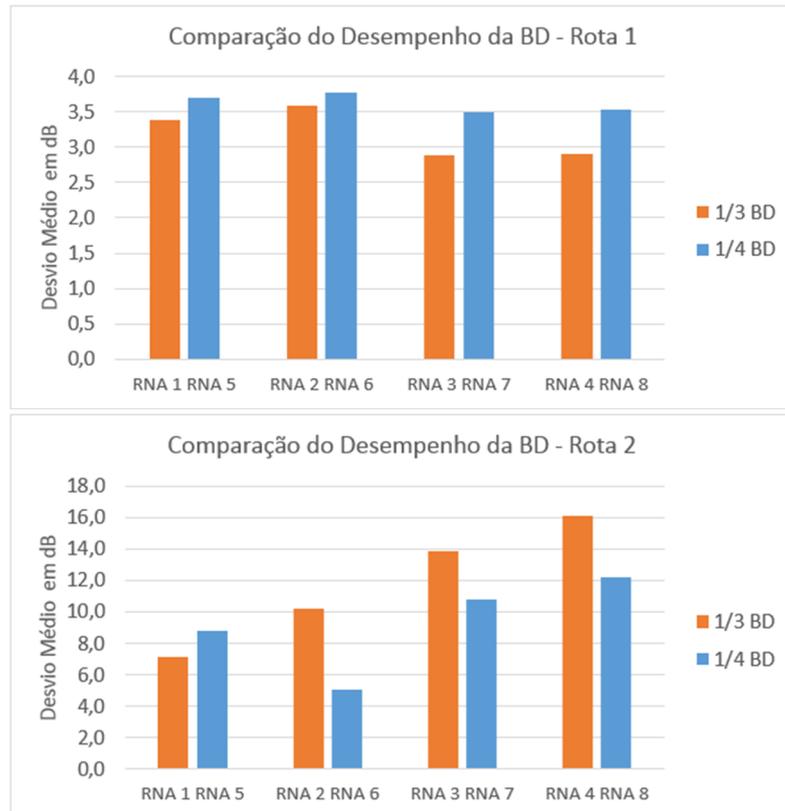


Figura 6-4 - Comparativo de desempenho da BD das RNAs do Grupo 1.

Para o Grupo 1, as RNAs que diferem apenas no tamanho da base de dados em seu treinamento, mas mantendo as demais características são: RNA 1 com a RNA 5, RNA 2 com a RNA 6, RNA 3 com RNA 7 e RNA 4 com RNA 8.

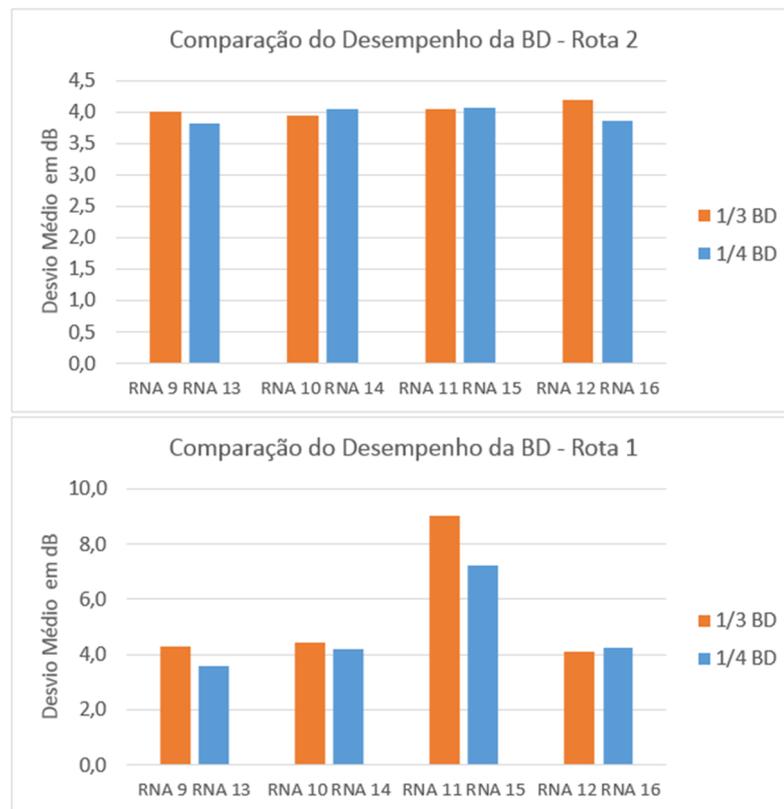


Figura 6-5 - Comparativo de desempenho da BD das RNAs do Grupo 2.

Para o Grupo 2, as RNAs que diferem apenas no tamanho da base de dados em seu treinamento, mas mantendo as demais características são: RNA 9 com a RNA 13, RNA 10 com a RNA 14, RNA 11 com RNA 15 e RNA 12 com RNA 16.

Comparando os valores apresentados na Figura 6-4 e Figura 6-5, pode-se afirmar, inicialmente, que para esta aplicação, a utilização de uma base maior de dados no treinamento não influenciou significativamente na melhoria da predição de cobertura. Este fato foi, provavelmente, ocasionado pela proximidade entre os dados utilizados, ou seja, como as medições foram realizadas automaticamente com uma taxa de amostragem de 5 amostras/s, ocasionou em uma proximidade dos pontos medidos, diferindo muito pouco o perfil do enlace na maioria dos casos. Não se pode descartar que a diferença de 8% (33% - 25%) pode não ser significativa para esta aplicação.

De qualquer forma, ao analisar em pequena escala o desempenho das RNAs que realizaram a predição na própria base de dados em que foi treinada, é possível verificar que as redes que foram treinadas com 1/4 da base de dados apresentaram desvio médio ligeiramente maior na maioria dos casos, o que era esperado, pois com menos valores para comparar, a rede pode não alcançar um nível suficiente de

associações, apresentando desvios maiores que as redes que foram treinadas utilizando 1/3 da base de dados.

Quando foi realizada a predição no teste cruzado, as redes que foram treinadas com 1/4 da base de dados apresentaram desvios ligeiramente menores. Este fato pode ser explicado considerando que os dados fornecidos para o treinamento, apesar de serem menores que 1/3 da base de dados total, eles foram suficientes para que a rede tivesse capacidade de generalizar ou de não se especializar em sua própria base, realizando a predição de cobertura com alto grau de acerto em novas bases de testes.

6.5.2 Diferença de Neurônios

Com o objetivo de comparar o desempenho de RNAs que diferem apenas na quantidade de neurônios, foram agrupadas na Figura 6-6 e Figura 6-7, as RNAs com as mesmas características.

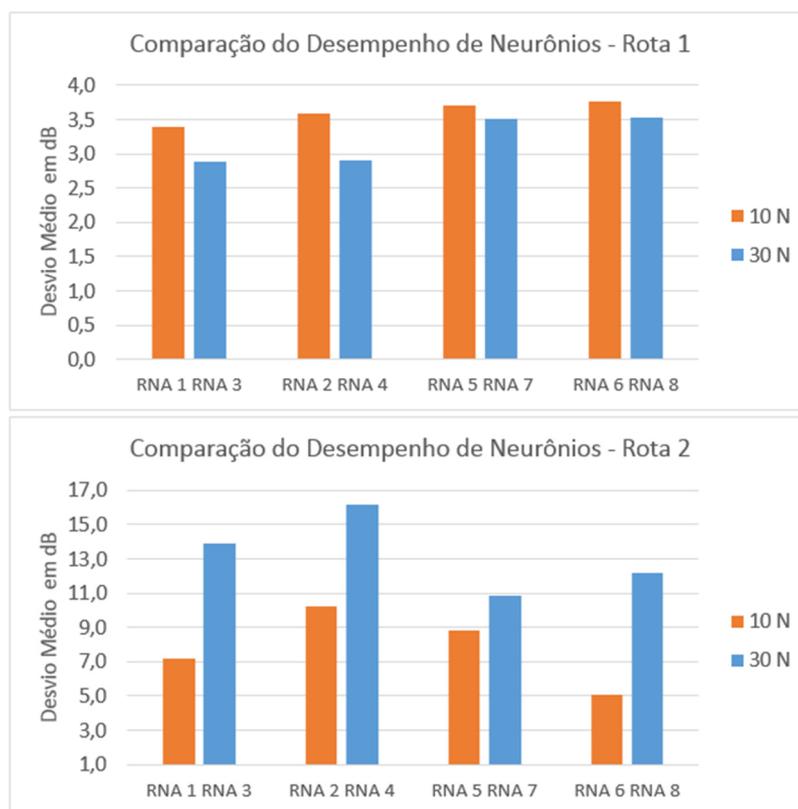


Figura 6-6 - Comparativo de desempenho de Neurônios das RNAs do Grupo 1.

Para o Grupo 1, as RNAs que diferem apenas no número de neurônios, mas mantendo as demais características são: RNA 1 com a RNA 3, RNA 2 com a RNA 4, RNA 5 com RNA 7 e RNA 6 com RNA 8.

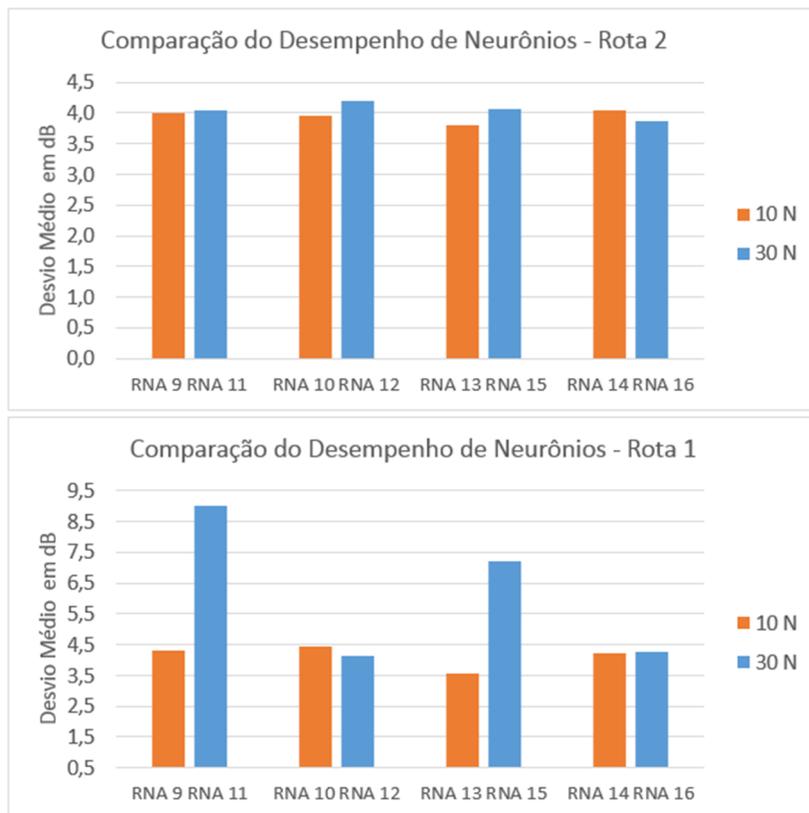


Figura 6-7 - Comparativo de desempenho de Neurônios das RNAs do Grupo 2.

Para o Grupo 2, as RNAs que diferem apenas no número de neurônios, mas mantendo as demais características são: RNA 9 com a RNA 11, RNA 10 com a RNA 12, RNA 13 com RNA 15 e RNA 14 com RNA 16.

Pode-se perceber que houve uma pequena variação dos valores dos desvios no teste aplicado na própria base de dados em que foi treinada, não sendo possível afirmar que redes com 30 neurônios apresentaram melhor desempenho do que as redes com 10 neurônios, no entanto, ao comparar o desempenho no teste cruzado, foi possível perceber que as redes que possuem 30 neurônios tiveram um desempenho expressivamente pior em quase todos os testes cruzados. Possivelmente, as redes com mais neurônios se especializaram e, com isso, perderam a capacidade de generalizar e, em alguns casos, chegando a ter o desempenho similar ou pior que os 2 métodos da UIT-R.

6.5.3 Diferença de Entradas

Realizando a mesma análise das etapas anteriores, mas com o objetivo de verificar o desempenho das redes que utilizaram 2 dados de entrada e 3 dados de entrada, temos os seguintes resultados expressos na Figura 6-8 e Figura 6-9:

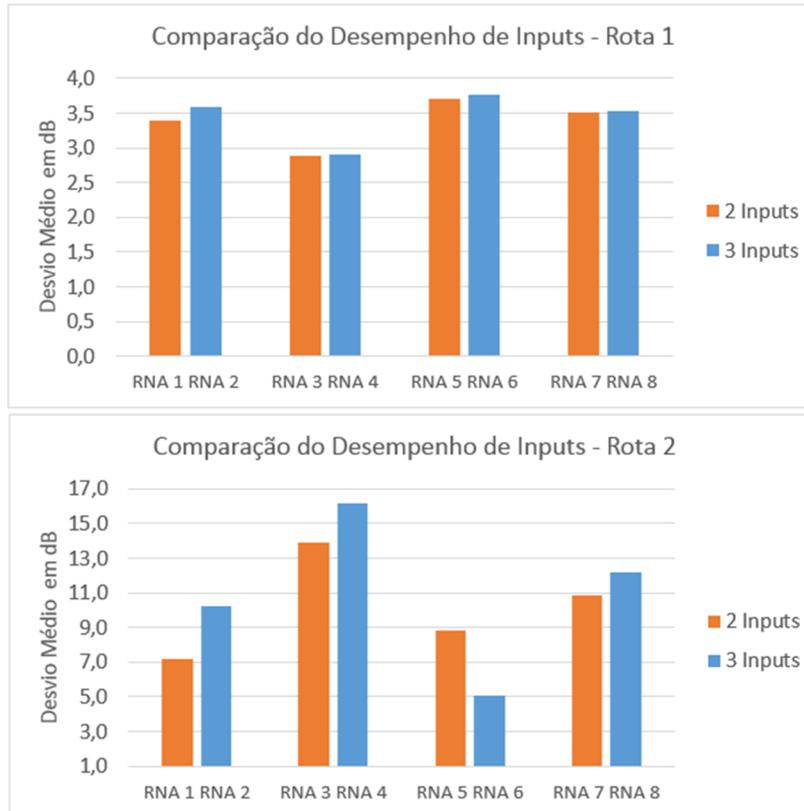


Figura 6-8 - Comparativo de desempenho de *Inputs* das RNAs do Grupo 1.

Para o Grupo 1, as RNAs que diferem apenas no número de entradas, mas mantendo as demais características são: RNA 1 com a RNA 2, RNA 3 com a RNA 4, RNA 5 com RNA 6 e RNA 7 com RNA 8.

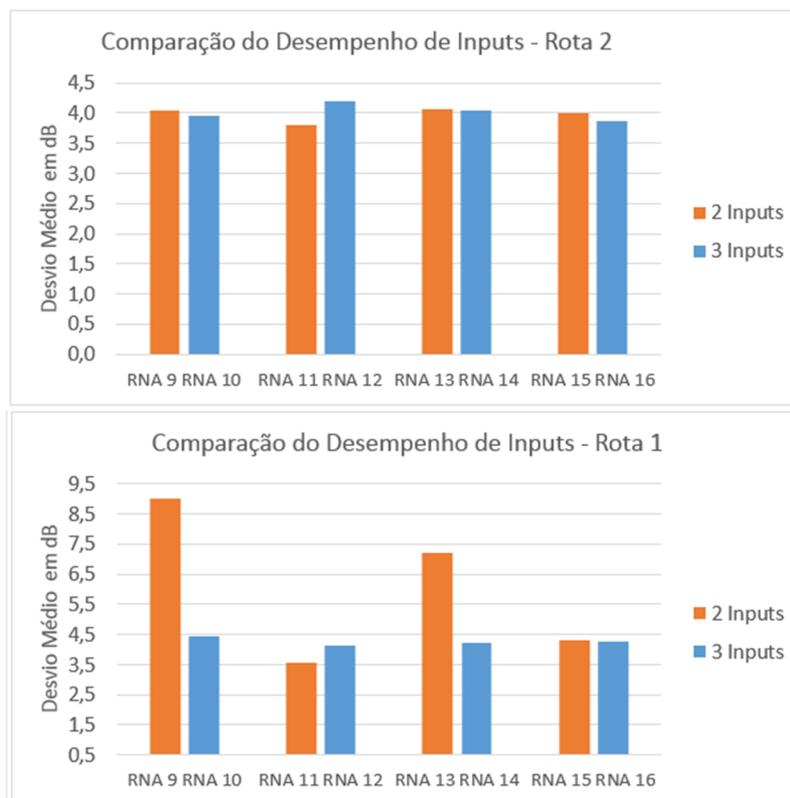


Figura 6-9 - Comparativo de desempenho de *Inputs* das RNAs do Grupo 2.

Para o Grupo 2, as RNAs que diferem apenas no n mero de entradas, mas mantendo as demais caracter sticas s o: RNA 9 com a RNA 10, RNA 11 com a RNA 12, RNA 13 com RNA 14 e RNA 15 com RNA 16.

Nos testes realizados, quando o grupo realiza a prediç o na rota em que elas foram treinadas, o desempenho se mostrou praticamente igual, diferindo apenas quando foi realizada a prediç o do teste cruzado. Em alguns casos, a utilizaç o de 3 dados de entrada apresentou desvios levemente superiores  s redes que foram alimentadas com dois dados de entrada, totalizando 4 de 8 casos – 50%, que foram as RNAs 1x2, 3x4, 7x8 e 11x12. No entanto, em 3 de 8 casos – 37%, que foram as RNAs 5x6, 9x10 e 13x14, as redes treinadas com 3 dados de entrada apresentaram desvios bem menores que as demais redes.

Podemos verificar que a inclus o da informaç o da prediç o da cobertura da ferramenta de prediç o   importante para garantir o poder de generalizaç o da rede, visto que dentro desta informaç o est o inseridos todos os c lculos do perfil do enlace, o que inclui topografia, morfologia, perda pelo espaço livre e todos os demais fatores que sejam inseridos na ferramenta de prediç o.

7 CONCLUSÃO E TRABALHOS FUTUROS

De acordo com os dados mostrados neste trabalho, pode-se concluir que o atual método disponível na Recomendação 526 de 2012 da UIT-R não se adequou bem à região estudada ou não apresentou os fatores de correção adequados ao tipo de topografia. Os desvios médios apresentados pelo método Delta-Bullington (D.B) foram superiores ao método *Gume de Faca em Cascata*, utilizado anteriormente na Recomendação 526 de 2011 da UIT-R. Ambos apresentaram desvios médios superiores a 10 dB nos 4071 valores medidos, sendo que o método *Gume de Faca* apresenta o desvio médio em torno de 12 dB e o método D.B., desvio médio em torno de 18 dB.

A aplicação das Redes Neurais Artificiais criadas mostraram resultados bastante positivos e satisfatórios em relação ao objetivo proposto, pois conseguiram reduzir, em mais de 90% dos testes, o desvio médio da predição de cobertura, com desvio médio em torno de 6 dB, e em alguns casos com valores inferiores a 3 dB. Ao compararmos com os métodos ponto área amplamente utilizados, que possuem desvios médios em torno de 8 dB, as RNAs se mostraram uma excelente opção a serem utilizadas no melhoramento da predição de cobertura. Da mesma forma que é necessário alimentar as RNAs para sua utilização, neste estudo com até 3 parâmetros, todos os outros métodos utilizados necessitam de uma quantidade considerável de parâmetros para que sejam efetivos e, muitas vezes, mais complexos.

A construção e o treinamento das RNAs se mostraram fatores importantes para um bom desempenho em predições realizadas em novas bases de dados, diferentes das quais foram treinadas. Este estudo abre novas possibilidades para construções de RNAs com diferentes parâmetros. Para trabalhos futuros, é sugerido que sejam feitas medições nos mais variados tipos de regiões semelhantes ou não à região estudada, de forma a obter novas predições de cobertura em uma nova base de dados. É importante que sejam feitos estudos alterando alguns parâmetros de propagação, como altura e ganho das antenas, potência transmitida e frequência de operação, pois estes novos dados serão inseridos indiretamente no processo de treinamento, o que poderá ampliar e direcionar o uso das RNAs para determinadas faixas e aumentar o seu desempenho. Além disto, é de grande importância que sejam realizados mais estudos aprofundando a teoria das RNAs, utilizando outros modelos de RNAs, com outros métodos de treinamento, alterando configurações de sua

estrutura, bem como os algoritmos de convergências e aprendizados para que possa ser comparado o desempenho entre as redes, de modo a identificar a rede que melhor pode se adaptar a este tipo de aplicação de predição de cobertura e reduzir, ainda mais, o desvio médio dos métodos recomendados.

8 REFERÊNCIAS

- [1] G. P. Ferreira, E. T. Bittencourt, L. J. Matos e J. M. M. Silva, *Redes Neurais Artificiais Aplicadas na Predição de Cobertura de Sinal Rádio VHF em Terreno Acidentado*, Niterói, RJ: UFF, 2011.
- [2] G. P. Ferreira, E. T. Bittencourt, A. A. Canavitsas, E. Costa, J. M. Silva e L. J. Matos, "Redes Neurais Artificiais Aplicadas na Predição de Cobertura de Sinal Rádio VHF em Terreno Acidentado," *XXX SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES – SBrT'12 - BRASÍLIA, DF*, 14 SETEMBRO 2012.
- [3] G. V. F. Silva, *Telecomunicações: Sistemas de Radiovisibilidade*, Rio de Janeiro: Livros Técnicos e Científicos Editora, 1978.
- [4] L. A. Mendonça, *Análise da Propagação de Ondas Eletromagnéticas em canais com Desvanecimento*, Dissertação de Mestrado - INATEL, 2002.
- [5] W. C. Y. Lee, *Wireless and cellular telecommunications – Third Edition*, McGRAW-HILL, 2006.
- [6] J. Parsons, *Mobile Radio Propagation Channel – 2nd Edition*, John Wiley & Sons, Inc, 2000.
- [7] J. S. Seybold, *Introduction to RF Propagation*, John Wily & Sons LTD, 2005.
- [8] T. S. Rappaport, *Wireless Communications Principles and Practice – 2nd Edition*, Prentice Hall PTR, 2002.
- [9] F. Ikegami, S. Yoshida, T. Takeuchi e M. Umehira, "Propagation factors controlling mean field strength on urban streets," *IEEE Transactions on Antennas and Propagation*, vol. 32, pp. 822-829, Dezembro 1984.
- [10] J. Walfisch e H. L. Bertoni, "A theoretical model of UHF propagation in urban enviroment," *IEEE Transactions on Antennas and Propagation*, vol. 36, pp. 1788-1796, dezembro 1988.
- [11] S. Faruke, *Cellular mobile systems engineering*, Norwood: Artech House Inc, 1996.
- [12] A. Mehrotra, *Cellular Radio Performance Engineering*, Norwood: Artech House Inc, 1994.
- [13] A. Ephremides, T. Itoh, R. Pickholtz, M. Iskander, L. Katehi, R. Rao, W. Stark e J. Winters, *Wireless Technologies and Information Networks*, International Technology Research Institute – WTEC Division, 2000.
- [14] UIT-R, "Recomendation - Propagation by Diffraction - 526," Genebra, 2011 e 2012.
- [15] W. C. Y. Lee, *Mobile Cellular Telecommunications: analog and digital systems*, New York: McGraw-Hill, 1995.
- [16] F. H. Dickson, J. J. Egli, J. W. Herbstreit e G. S. Wickizer, "Large Reductions of VHF Transmission and Fading by the Presence of a Mountain Obstacle in Beyond LOS Paths," *Proceedings of the IRE*, vol. 41, nº 8, pp. 967-969, 1953.
- [17] G. N. Watson, "The Diffraction of Electric Waves by the Earth," *Proc. of the Royal Society*, pp. 83-89; 546-563, Oct-Jul 1918-1919.
- [18] J. Deygout, "Multiple knife-edge diffraction of microwaves," *IEEE Transactions on Antennas and Propagation*, vol. 14, nº Jul, pp. 480-489, Jul 1966.
- [19] A. Picquenard, *Radiowave Propagation*, London: Macmillan, 1974.
- [20] S. R. Saunders e A.-Z. A., *Antennas and Propagation for wireless Communication Systems*, Second Edition, John Wiley & Sons, 2007.
- [21] UIT-R, "Prediction Procedure for the Evaluation of Interference between Stations on the Surface of the Earth at Frequencies above about 0.1 GHz," UIT, Genebra, 2009.

- [22] UIT-R, "A Path Specific Propagation Prediction Method for Point-to-Area Terrestrial Services in the VHF and UHF Bands," em *REC UIT-R P.1812-1*, Genebra, 2009.
- [23] K. A. Bullington, "Transmission loss in radio propagation," *IRE 41*, pp. 146-152, Jan 1953.
- [24] UIT-R, "Discussion Paper Concerning Recommendation ITU-R P.1812 - The Bullington Diffraction Model and its Correction," em *Document 3K/17-E*, Genebra, maio 2008.
- [25] UIT-R, "A New Approach to Diffraction Modelling for a General Path - The "Delta"," em *Document 3J/64*, Genebra, abril 2009.
- [26] C. T. d. Telecomunicações, Celplanner, Campinas.
- [27] N. Instruments, Labiview.
- [28] Pathloss, Pathloss - Microwave radio link design and planning.
- [29] E. L. Lima, Espaços Métricos 2ª. Ed., RJ: IMPA, 1983.
- [30] K. E. Stocker, B. E. Gschwendtner e F. M. Landstorfer, "Neural network approach to prediction of terrestrial wave propagation for mobile radio," *IEE proceedings-H*, vol. 140, nº No. 4, pp. 315-320, August 1993.
- [31] B. Milovanovic, Z. Stankovic e A. Stosic, "Prediction of The Electromagnetic Field Strength Level Using Neural Model," *International Conference on Telecommunication in Modern Satellite - TELSIKS*, vol. 2, nº 6, pp. 457-460, 2003.
- [32] T. Balandier, A. Caminada, V. Lemoine e F. Alexandre, "170 MHz Field Strength Prediction in Urban Environment Using Neural Nets," *IEEE International Symposium on Indoor and Mobile Radio Communications*, vol. 1, nº 6, pp. 120-124, 1995.
- [33] A. Neskovic, N. Neskovic e D. Paunovic, "Macrocell Electric Field Strenght Prediction Model Based Upon Artificial Neural Networks," *IEEE Journal on Selected Areas in Communications*, vol. 20, p. 6, August 2002..
- [34] J. Romo, I. Anitzine e F. Fontan, "Application of neural networks to field strength prediction for indoor environments," *Antennas and Propagation, EuCAP*, pp. 1 - 6, 2006.
- [35] W. Chen, Y. Lin e J. Yang, "Hybrid prediction model for field strength with ray tracing and artificial neural networks," *Communication Technology (ICCT) - IEEE 14th International Conference on* , pp. 301 - 305, 2012.
- [36] I. Vilovic, N. Brum e D. Milic, "Using Particle Swarm Optimization in Training Neural Network for Indoor Field Strenght Prediction," *51st International Symposium ELMAR*, pp. 275 - 278, 28-30 September 2009.
- [37] H. Zhou, F. Wang e C. Yang, "Application o artificial neural networks to the prediction of field strength in indoor environment for wireless LAN," *Wireless Communications, Networking and Mobile Computing*, pp. 1189 - 1192, 2005.
- [38] C. Fang e S. Huairong, "Field strength prediction based on wavelet neural network," *Education Technology and Computer (ICETC) - 2nd International Conference on* , pp. V2-255 - V2-258, 2010.
- [39] I. Vilovic e N. Burum, "A comparison of MLP and RBF neural networks architectures for electromagnetic field prediction in indoor environments," *Antennas and Propagation (EUCAP), Proceedings of the 5th European Conference on* , pp. 1719 - 1723, 2011.
- [40] D. Wu, G. Zhu e B. Ai, "Application of artificial neural networks for path loss prediction in railway environments," *Communications and Networking in China (CHINACOM), 5th International ICST Conference on* , pp. 1 - 5, 2010.
- [41] A. P. Braga, Redes Neurais Artificiais: Teoria e Aplicações, Rio de Janeiro: LTC, 2000.
- [42] S. O. Rezende, Sistemas Inteligentes: fundamentos e aplicações, Barueri - SP: Manole, 2003.
- [43] D. E. Rumelhart, G. E. Hinton e R. J. Williams, "Learning representations by backpropagating errors," *Nature*, vol. 323, p. 533-536, 1986.

- [44] K. Levenberg, "A method for the solution of certain non-linear problems in least squares," *Quarterly Journal of Applied Mathematics*, vol. II, p. 164–168, 1944.
- [45] M. T. Hagan e M. B. Menhaj, "Training feedforward networks with the mar-quardt algoritm," *IEEE Transactions on Neural Networks*, vol. 5(6), pp. 989-993, 1994.
- [46] UIT-R, "Terrain General Diffraction Model Testing the Delta-Bullington Method – Proposal for Effective Heights," em *Document 3J/112*, Genebra, outubro 2010.

9 APÊNDICE

9.1 Algoritmo *MATLAB* de criação e treinamento do grupo 01

```
% Universidade Federal Fluminense
% Mestrado em Engenharia de Telecomunicações
% Gilbert Ponciano Ferreira
% Estudo de otimização da predição da ROTA 01

%% RNA 1

% Rota 1
% Treinamento - 1/3 da base de dados
% Inputs - 2 (distância e perda por difração)

% Neurônios - 10

inputs = input132';
% 1 - Rota 1
% 3 - 1/3 da base de dados
% 2 - 2 Inputs
targets = resp13';

% Create a Fitting Network
hiddenLayerSize = 10;
net11 = fitnet(hiddenLayerSize);           %net11 = RNA 1 da ROTA 1

% Setup Division of Data for Training, Validation, Testing
net11.divideParam.trainRatio = 70/100;
net11.divideParam.valRatio = 15/100;
net11.divideParam.testRatio = 15/100;

% Train the Network
[net11,tr] = train(net11,inputs,targets);

% Test the Network
outputs = net11(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net11,targets,outputs)

% all inputs
outputs1 = net11(input12');                %input12 = todas as entradas
da rota 1 com 2 inputs                      %output1 = todas as saidas
outputs1 = outputs1';                       %resp1 = todos os valores
geradas pela RNA1
errors = gsubtract(resp1,outputs1);
medidos da Rota 1
performance = perform(net11,resp1,outputs1)

% View the Network
% view(net11)

% Plots
% Uncomment these lines to enable various plots.
%figure, plotperform(tr)
%figure, plottrainstate(tr)
```

```

%figure, plotfit(net,inputs,targets)
%figure, plotregression(targets,outputs)
%figure, ploterrhist(errors)

%% RNA 2

% Treinamento - 1/3
% Inputs - 3
% Neurônios - 10

inputs = input133';
targets = resp13';

% Create a Fitting Network
hiddenLayerSize = 10;
net21 = fitnet(hiddenLayerSize);           %net

% Setup Division of Data for Training, Validation, Testing
net21.divideParam.trainRatio = 70/100;
net21.divideParam.valRatio = 15/100;
net21.divideParam.testRatio = 15/100;

% Train the Network
[net21,tr] = train(net21,inputs,targets);

% Test the Network
outputs = net21(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net21,targets,outputs)

% all inputs
outputs2 = net21(input13');                %input
outputs2 = outputs2';                      %output
errors = gsubtract(resp1,outputs2);
performance = perform(net21,resp1,outputs2)

%% RNA 3

% Treinamento - 1/3
% Inputs - 2
% Neurônios - 30

inputs = input132';
targets = resp13';

% Create a Fitting Network
hiddenLayerSize = 30;
net31 = fitnet(hiddenLayerSize);          %net

% Setup Division of Data for Training, Validation, Testing
net31.divideParam.trainRatio = 70/100;
net31.divideParam.valRatio = 15/100;
net31.divideParam.testRatio = 15/100;

% Train the Network
[net31,tr] = train(net31,inputs,targets);

```

```

% Test the Network
outputs = net31(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net31,targets,outputs)

% all inputs
outputs3 = net31(input12');           %input
outputs3 = outputs3';                 %output
errors = gsubtract(resp1,outputs3);
performance = perform(net31,resp1,outputs3)

%% RNA 4

% Treinamento - 1/3
% Inputs - 3
% Neurônios - 30

inputs = input133';
targets = resp13';

% Create a Fitting Network
hiddenLayerSize = 30;
net41 = fitnet(hiddenLayerSize);      %net

% Setup Division of Data for Training, Validation, Testing
net41.divideParam.trainRatio = 70/100;
net41.divideParam.valRatio = 15/100;
net41.divideParam.testRatio = 15/100;

% Train the Network
[net41,tr] = train(net41,inputs,targets);

% Test the Network
outputs = net41(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net41,targets,outputs)

% all inputs
outputs4 = net41(input13');           %input
outputs4 = outputs4';                 %output
errors = gsubtract(resp1,outputs4);
performance = perform(net41,resp1,outputs4)

%% RNA 5

% Treinamento - 1/4 da base de dados
% Inputs - 2 (distância e perda por difração)
% Neurônios - 10

inputs = input142';
targets = resp14';

% Create a Fitting Network
hiddenLayerSize = 10;
net51 = fitnet(hiddenLayerSize);      %net

% Setup Division of Data for Training, Validation, Testing
net51.divideParam.trainRatio = 70/100;

```

```

net51.divideParam.valRatio = 15/100;
net51.divideParam.testRatio = 15/100;

% Train the Network
[net51,tr] = train(net51,inputs,targets);

% Test the Network
outputs = net51(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net51,targets,outputs)

% all inputs
outputs5 = net51(input12');           %input
outputs5 = outputs5';                 %output
errors = gsubtract(resp1,outputs5);
performance = perform(net51,resp1,outputs5)

%% RNA 6

% Treinamento - 1/4
% Inputs - 3
% Neurônios - 10

inputs = input143';
targets = resp14';

% Create a Fitting Network
hiddenLayerSize = 10;
net61 = fitnet(hiddenLayerSize);      %net

% Setup Division of Data for Training, Validation, Testing
net61.divideParam.trainRatio = 70/100;
net61.divideParam.valRatio = 15/100;
net61.divideParam.testRatio = 15/100;

% Train the Network
[net61,tr] = train(net61,inputs,targets);

% Test the Network
outputs = net61(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net61,targets,outputs)

% all inputs
outputs6 = net61(input13');           %input
outputs6 = outputs6';                 %output
errors = gsubtract(resp1,outputs6);
performance = perform(net61,resp1,outputs6)

%% RNA 7

% Treinamento - 1/4
% Inputs - 2
% Neurônios - 30

inputs = input142';
targets = resp14';

```

```

% Create a Fitting Network
hiddenLayerSize = 30;
net71 = fitnet(hiddenLayerSize);           %net

% Setup Division of Data for Training, Validation, Testing
net71.divideParam.trainRatio = 70/100;
net71.divideParam.valRatio = 15/100;
net71.divideParam.testRatio = 15/100;

% Train the Network
[net71,tr] = train(net71,inputs,targets);

% Test the Network
outputs = net71(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net71,targets,outputs)

% all inputs
outputs7 = net71(input12');               %input
outputs7 = outputs7';                     %output
errors = gsubtract(resp1,outputs7);
performance = perform(net71,resp1,outputs7)

%% RNA 8

% Treinamento - 1/4
% Inputs - 3
% Neurônios - 30

inputs = input143';
targets = resp14';

% Create a Fitting Network
hiddenLayerSize = 30;
net81 = fitnet(hiddenLayerSize);         %net

% Setup Division of Data for Training, Validation, Testing
net81.divideParam.trainRatio = 70/100;
net81.divideParam.valRatio = 15/100;
net81.divideParam.testRatio = 15/100;

% Train the Network
[net81,tr] = train(net81,inputs,targets);

% Test the Network
outputs = net81(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net81,targets,outputs)

% all inputs
outputs8 = net81(input13');               %input
outputs8 = outputs8';                     %output
errors = gsubtract(resp1,outputs8);
performance = perform(net81,resp1,outputs8)

%% Consolidando

```

```
predrnal = [outputs1 outputs2 outputs3 outputs4 outputs5 outputs6 outputs7
outputs8];
```

9.2 Algoritmo *MATLAB* de criação e treinamento do grupo 02

```
% Universidade Federal Fluminense
% Mestrado em Engenharia de Telecomunicações
% Gilbert Ponciano Ferreira
% Estudo de otimização da predicao da ROTA 02

%% RNA 9

% ROTA 2
% Treinamento - 1/3 da base de dados
% Inputs - 2 (distância e perda por difração)

% Neurônios - 10

inputs = input232';
% 2 - ROTA 2
% 3 - 1/3 da base de dados
% 2 - 2 Inputs
targets = resp23';

% Create a Fitting Network
hiddenLayerSize = 10;
net12 = fitnet(hiddenLayerSize);           %net12 = RNA 1 da ROTA 2

% Setup Division of Data for Training, Validation, Testing
net12.divideParam.trainRatio = 70/100;
net12.divideParam.valRatio = 15/100;
net12.divideParam.testRatio = 15/100;

% Train the Network
[net12,tr] = train(net12,inputs,targets);

% Test the Network
outputs = net12(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net12,targets,outputs)

% all inputs
outputs9 = net12(input22');                %input22 = todas as entradas
da ROTA 2 com 2 inputs                    %output1 = todas as saidas
outputs9 = outputs9';                     %resp2 = todos os valores
geradas pela RNA1
errors = gsubtract(resp2,outputs9);
medidos da ROTA 2
performance = perform(net12,resp2,outputs9)

% View the Network
% view(net11)

% Plots
% Uncomment these lines to enable various plots.
```

```

%figure, plotperform(tr)
%figure, plottrainstate(tr)
%figure, plotfit(net,inputs,targets)
%figure, plotregression(targets,outputs)
%figure, ploterrhist(errors)

%% RNA 10

% Treinamento - 1/3
% Inputs - 3
% Neurônios - 10

inputs = input233';
targets = resp23';

% Create a Fitting Network
hiddenLayerSize = 10;
net22 = fitnet(hiddenLayerSize);           %net

% Setup Division of Data for Training, Validation, Testing
net22.divideParam.trainRatio = 70/100;
net22.divideParam.valRatio = 15/100;
net22.divideParam.testRatio = 15/100;

% Train the Network
[net22,tr] = train(net22,inputs,targets);

% Test the Network
outputs = net22(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net22,targets,outputs)

% all inputs
outputs10 = net22(input23');               %input
outputs10 = outputs10';                   %output
errors = gsubtract(resp2,outputs10);
performance = perform(net22,resp2,outputs10)

%% RNA 11

% Treinamento - 1/3
% Inputs - 2
% Neurônios - 30

inputs = input232';
targets = resp23';

% Create a Fitting Network
hiddenLayerSize = 30;
net32 = fitnet(hiddenLayerSize);          %net

% Setup Division of Data for Training, Validation, Testing
net32.divideParam.trainRatio = 70/100;
net32.divideParam.valRatio = 15/100;
net32.divideParam.testRatio = 15/100;

% Train the Network

```

```

[net32,tr] = train(net32,inputs,targets);

% Test the Network
outputs = net32(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net32,targets,outputs)

% all inputs
outputs11 = net32(input22');           %input
outputs11 = outputs11';               %output
errors = gsubtract(resp2,outputs11);
performance = perform(net32,resp2,outputs11)

%% RNA 12

% Treinamento - 1/3
% Inputs - 3
% Neurônios - 30

inputs = input233';
targets = resp23';

% Create a Fitting Network
hiddenLayerSize = 30;
net42 = fitnet(hiddenLayerSize);      %net

% Setup Division of Data for Training, Validation, Testing
net42.divideParam.trainRatio = 70/100;
net42.divideParam.valRatio = 15/100;
net42.divideParam.testRatio = 15/100;

% Train the Network
[net42,tr] = train(net42,inputs,targets);

% Test the Network
outputs = net42(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net42,targets,outputs)

% all inputs
outputs12 = net42(input23');          %input
outputs12 = outputs12';              %output
errors = gsubtract(resp2,outputs12);
performance = perform(net42,resp2,outputs12)

%% RNA 13

% Treinamento - 1/4 da base de dados
% Inputs - 2 (distância e perda por difração)
% Neurônios - 10

inputs = input242';
targets = resp24';

% Create a Fitting Network
hiddenLayerSize = 10;
net52 = fitnet(hiddenLayerSize);     %net

```

```

% Setup Division of Data for Training, Validation, Testing
net52.divideParam.trainRatio = 70/100;
net52.divideParam.valRatio = 15/100;
net52.divideParam.testRatio = 15/100;

% Train the Network
[net52,tr] = train(net52,inputs,targets);

% Test the Network
outputs = net52(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net52,targets,outputs)

% all inputs
outputs13 = net52(input22');           %input
outputs13 = outputs13';               %output
errors = gsubtract(resp2,outputs13);
performance = perform(net52,resp2,outputs13)

%% RNA 14

% Treinamento - 1/4
% Inputs - 3
% Neurônios - 10

inputs = input243';
targets = resp24';

% Create a Fitting Network
hiddenLayerSize = 10;
net62 = fitnet(hiddenLayerSize);      %net

% Setup Division of Data for Training, Validation, Testing
net62.divideParam.trainRatio = 70/100;
net62.divideParam.valRatio = 15/100;
net62.divideParam.testRatio = 15/100;

% Train the Network
[net62,tr] = train(net62,inputs,targets);

% Test the Network
outputs = net62(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net62,targets,outputs)

% all inputs
outputs14 = net62(input23');          %input
outputs14 = outputs14';              %output
errors = gsubtract(resp2,outputs14);
performance = perform(net62,resp2,outputs14)

%% RNA 15

% Treinamento - 1/4
% Inputs - 2
% Neurônios - 30

```

```

inputs = input242';
targets = resp24';

% Create a Fitting Network
hiddenLayerSize = 30;
net72 = fitnet(hiddenLayerSize);           %net

% Setup Division of Data for Training, Validation, Testing
net72.divideParam.trainRatio = 70/100;
net72.divideParam.valRatio = 15/100;
net72.divideParam.testRatio = 15/100;

% Train the Network
[net72,tr] = train(net72,inputs,targets);

% Test the Network
outputs = net72(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net72,targets,outputs)

% all inputs
outputs15 = net72(input22');               %input
outputs15 = outputs15';                   %output
errors = gsubtract(resp2,outputs15);
performance = perform(net72,resp2,outputs15)

%% RNA 16

% Treinamento - 1/4
% Inputs - 3
% Neurônios - 30

inputs = input243';
targets = resp24';

% Create a Fitting Network
hiddenLayerSize = 30;
net82 = fitnet(hiddenLayerSize);           %net

% Setup Division of Data for Training, Validation, Testing
net82.divideParam.trainRatio = 70/100;
net82.divideParam.valRatio = 15/100;
net82.divideParam.testRatio = 15/100;

% Train the Network
[net82,tr] = train(net82,inputs,targets);

% Test the Network
outputs = net82(inputs);
errors = gsubtract(targets,outputs);
performance = perform(net82,targets,outputs)

% all inputs
outputs16 = net82(input23');               %input
outputs16 = outputs16';                   %output
errors = gsubtract(resp2,outputs16);
performance = perform(net82,resp2,outputs16)

```

```

%% Consolidando

predrna2 = [outputs9 outputs10 outputs11 outputs12 outputs13 outputs14
outputs15 outputs16];

```

9.3 Algoritmo *MATLAB* do teste cruzado

```

% Universidade Federal Fluminense
% Mestrado em Engenharia de Telecomunicações
% Gilbert Ponciano Ferreira
% Estudo de otimização Crosstest

%% RNA 1

% Rota 1
% Treinamento - 1/3 da base de dados
% Inputs - 2 (distância e perda por difração)

% Neurônios - 10

% all inputs
crossout1 = net11(input22'); %input22 = todas as entradas
da rota 1 com 2 inputs %crossout1 = todas as
crossout1 = crossout1'; saídas geradas pela RNA1
errors = gsubtract(resp2,crossout1); %resp2 = todos os valores
medidos da Rota 1
performance = perform(net11,resp2,crossout1)

%% RNA 2

% Treinamento - 1/3
% Inputs - 3
% Neurônios - 10

% all inputs
crossout2 = net21(input23'); %input
crossout2 = crossout2'; %crossout
errors = gsubtract(resp2,crossout2);
performance = perform(net21,resp2,crossout2)

%% RNA 3

% Treinamento - 1/3
% Inputs - 2
% Neurônios - 30

% all inputs
crossout3 = net31(input22'); %input
crossout3 = crossout3'; %crossout
errors = gsubtract(resp2,crossout3);
performance = perform(net31,resp2,crossout3)

%% RNA 4

% Treinamento - 1/3

```

```

% Inputs - 3
% Neurônios - 30

% all inputs
crossout4 = net41(input23');           %input
crossout4 = crossout4';               %crossout
errors = gsubtract(resp2,crossout4);
performance = perform(net41,resp2,crossout4)

%% RNA 5

% Treinamento - 1/4 da base de dados
% Inputs - 2 (distância e perda por difração)
% Neurônios - 10

% all inputs
crossout5 = net51(input22');           %input
crossout5 = crossout5';               %crossout
errors = gsubtract(resp2,crossout5);
performance = perform(net51,resp2,crossout5)

%% RNA 6

% Treinamento - 1/4
% Inputs - 3
% Neurônios - 10

% all inputs
crossout6 = net61(input23');           %input
crossout6 = crossout6';               %crossout
errors = gsubtract(resp2,crossout6);
performance = perform(net61,resp2,crossout6)

%% RNA 7

% Treinamento - 1/4
% Inputs - 2
% Neurônios - 30

% all inputs
crossout7 = net71(input22');           %input
crossout7 = crossout7';               %crossout
errors = gsubtract(resp2,crossout7);
performance = perform(net71,resp2,crossout7)

%% RNA 8

% Treinamento - 1/4
% Inputs - 3
% Neurônios - 30

% all inputs
crossout8 = net81(input23');           %input
crossout8 = crossout8';               %crossout
errors = gsubtract(resp2,crossout8);
performance = perform(net81,resp2,crossout8)

```

```

%% RNA 9

% ROTA 2
% Treinamento - 1/3 da base de dados
% Inputs - 2 (distância e perda por difração)

% all inputs
crossout9 = net12(input12');           %input12 = todas as entradas
da ROTA 2 com 2 inputs                 %crossout1 = todas as
crossout9 = crossout9';                %resp1 = todos os valores
saidas geradas pela RNA1
errors = gsubtract(respl,crossout9);
medidos da ROTA 2
performance = perform(net12,respl,crossout9)

%% RNA 10

% Treinamento - 1/3
% Inputs - 3
% Neurônios - 10

% all inputs
crossout10 = net22(input13');          %input
crossout10 = crossout10';             %crossout
errors = gsubtract(respl,crossout10);
performance = perform(net22,respl,crossout10)

%% RNA 11

% Treinamento - 1/3
% Inputs - 2
% Neurônios - 30

% all inputs
crossout11 = net32(input12');          %input
crossout11 = crossout11';             %crossout
errors = gsubtract(respl,crossout11);
performance = perform(net32,respl,crossout11)

%% RNA 12

% Treinamento - 1/3
% Inputs - 3
% Neurônios - 30

% all inputs
crossout12 = net42(input13');          %input
crossout12 = crossout12';             %crossout
errors = gsubtract(respl,crossout12);
performance = perform(net42,respl,crossout12)

%% RNA 13

% Treinamento - 1/4 da base de dados
% Inputs - 2 (distância e perda por difração)
% Neurônios - 10

```

```

% all inputs
crossout13 = net52(input12');           %input
crossout13 = crossout13';             %crossout
errors = gsubtract(respl,crossout13);
performance = perform(net52,respl,crossout13)

%% RNA 14

% Treinamento - 1/4
% Inputs - 3
% Neurônios - 10

% all inputs
crossout14 = net62(input13');           %input
crossout14 = crossout14';             %crossout
errors = gsubtract(respl,crossout14);
performance = perform(net62,respl,crossout14)

%% RNA 15

% Treinamento - 1/4
% Inputs - 2
% Neurônios - 30

% all inputs
crossout15 = net72(input12');           %input
crossout15 = crossout15';             %crossout
errors = gsubtract(respl,crossout15);
performance = perform(net72,respl,crossout15)

%% RNA 16

% Treinamento - 1/4
% Inputs - 3
% Neurônios - 30

% all inputs
crossout16 = net82(input13');           %input
crossout16 = crossout16';             %crossout
errors = gsubtract(respl,crossout16);
performance = perform(net82,respl,crossout16)

%% Consolidando

predcross1 = [crossout1 crossout2 crossout3 crossout4 crossout5 crossout6
crossout7 crossout8];
predcross2 = [crossout9 crossout10 crossout11 crossout12 crossout13
crossout14 crossout15 crossout16];

```

9.4 Local das medições com as 2 rotas plotadas.

