



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E
DE COMPUTAÇÃO



Análise de Modelos de Predição de Perdas de Propagação em Redes de Comunicações LTE e LTE-Advanced usando Técnicas de Inteligência Artificial

Autor: Bruno Jácome Cavalcanti

Orientador: Prof Dr. Laércio Martins de Mendonça

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da UFRN (área de concentração: Engenharia Elétrica) como parte dos requisitos para obtenção do título de Doutor em Ciências.

Número de ordem do PPgEEC: D207

Natal, RN, outubro de 2017

Universidade Federal do Rio Grande do Norte - UFRN
Sistema de Bibliotecas - SISBI
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Cavalcanti, Bruno Jacome.

Análise de modelos de predição de perdas de propagação em redes de comunicações LTE e LTE-Advanced usando técnicas de inteligência artificial / Bruno Jacome Cavalcanti. - 2017.
111 f.: il.

Tese (doutorado) - Universidade Federal do Rio Grande do Norte, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica e de Computação. Natal, RN. 2018.

Orientador: Prof. Dr. Laércio Martins de Mendonça.

1. Redes neurais artificiais - Tese. 2. Algoritmos genéticos - Tese. 3. Long term evolution - Tese. 4. Modelos de perda de propagação - Tese. 5. Perda de percurso - Tese. I. Mendonça, Laércio Martins de. II. Título.

RN/UF/BCZM

CDU 004.032.26



Universidade Federal do Rio Grande do Norte

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E DE
COMPUTAÇÃO

ATA Nº 207

Aos vinte dias do mês de outubro do ano de dois mil e dezessete, foi realizada a 207ª sessão de defesa de tese de doutorado do Programa de Pós-Graduação em Engenharia Elétrica e de Computação da UFRN, na qual o doutorando Bruno Jácome Cavalcanti, apresentou o trabalho que tem como título: Estudo de Modelos de Predição de Perdas de Propagação em Sistemas de Comunicações LTE e LTE-Advanced Usando Técnicas de Inteligência Artificial. A sessão teve início às 09h30min, tendo a banca examinadora sido constituída pelos seguintes participantes: Laércio Martins de Mendonça (Dr. UFRN, Orientador), Adaildo Gomes DAssunção (Dr. UFRN, Examinador Interno ao Programa), José Patrocínio da Silva (Dr. UFRN, Examinador Interno ao Programa), Gervásio Protásio dos Santos Cavalcante (Dr. UFPA, Examinador Externo à Instituição) e Marcos Tavares De Melo (Dr. UFPE, Examinador Externo à Instituição). Após a apresentação do trabalho e o exame pela banca, o doutorando foi considerado APROVADO, tendo sido lavrada a presente ata, que vai assinada pelos examinadores e pelo doutorando. A versão final da tese deverá ser entregue ao programa, no prazo máximo de 60 dias, contendo as modificações sugeridas pela banca examinadora e constante na folha de correção anexa. Conforme o Artigo 49 da Resolução 197/2013 - CONSEPE, o candidato não terá o título se não cumprir as exigências acima.


Dr. GERVASIO PROTASIO DOS SANTOS CAVALCANTE, UFPA

Examinador Externo à Instituição


Dr. MARCOS TAVARES DE MELO, UFPE

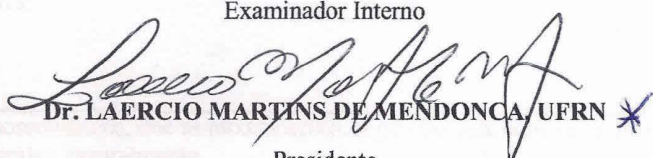
Examinador Externo à Instituição


Dr. ADAILDO GOMES D ASSUNCAO, UFRN

Examinador Interno


Dr. JOSE PATROCINIO DA SILVA, UFRN

Examinador Interno


Dr. LAERCIO MARTINS DE MENDONCA, UFRN *

Presidente


BRUNO JACOME CAVALCANTI

Doutorando

Campus Universitário - Lagoa Nova - Natal/RN - CEP: 59072-970 Telefax: (084) (84) 3215-3767 •

O título da tese foi modificado de ESTUDO PARA ANÁLISE.

*À minha mãe, **Waleska**,
por investir e me
apoiar nos meus
estudos.*

*À memória do meu pai,
Josias, por todo
conhecimento
repassado.*

*À memória do meu
amado irmão, **Gustavo**,
um exemplo de
dedicação e luta.*

Agradecimentos

Agradeço de maneira especial ao meu irmão **Gustavo** (*in memorian*), uma pessoa inspiradora, cuja luta serviu como exemplo de vida.

À minha mãe, **Waleska** e ao meu pai, **Josias** (*in memorian*), por sempre me incentivarem nos estudos.

Ao prof. **Laércio Martins**, pela orientação ao longo desses mais de quatro anos de preparação de tese de doutoramento.

Aos meus familiares, pelo carinho e apoio.

À minha namorada **Clarice**, pelo amor, companheirismo e dedicação.

Pelo apoio técnico, a **Marcelo Medeiros** e **Marcela Tassyany**, mas principalmente a **Gustavo Araújo** e **Gabriel Mocan**, cujo auxílio foi fundamental para a conclusão deste trabalho.

Ao **IFPB campus Campina Grande**, pelo apoio dado por meio de afastamento e redução na carga horária.

À **Universidade Federal do Rio Grande do Norte**, que me acolheu para minha vida de pós-graduação.

Aos meus amigos **Thyago, Ramon, Paulo, Marcelo Portela, Rhavy, Júnior, Leno, Danilo, Diego, Raoni, Valdez** e **Jannayna**, pelo apoio e amizade.

*E se o mundo não corresponde
em todos os aspectos a nossos
desejos, é culpa da ciência ou
dos que querem impor seus
desejos ao mundo?*

(Carl Sagan)

Resumo

A perfeita funcionalidade dos sistemas de comunicações de 3^a. e 4^a. gerações requerem, entre outras coisas, do conhecimento dos valores numéricos da predição das perdas de propagação dos sinais propagantes nos ambientes urbano, suburbano e rural. Portanto, o estudo das condições de propagação em um ambiente qualquer sempre será uma preocupação dos engenheiros projetistas. A análise e desenvolvimento de modelos robustos de predição de perdas de propagação em redes de comunicações Long Term Evolution (LTE) e Long Term Evolution Advanced (LTE-A) usando técnicas de Inteligência Artificial são realizadas neste trabalho. Os procedimentos metodológicos empregados foram aplicados no melhoramento da predição dos modelos de perda de propagação empíricos SUI, ECC-33, Ericsson 9999, TR 36.942 e o modelo do Espaço Livre, aplicados em redes LTE e LTE-A nas frequências de 800 MHz, 1800 MHz e 2600 MHz, para ambientes suburbanos em cidades de porte médio do nordeste do Brasil. Assim, nesta tese propõem-se dois modelos de Redes Neurais Artificiais (RNA): (i) o modelo de rede neural com entradas baseadas em erro (RNBE), utilizando como principal alimentador da rede o erro entre dados medidos e simulados, e, (ii) o modelo de rede neural com entradas baseadas no terreno (RNBT). O desempenho desses modelos foram comparados com os modelos de propagação considerados no trabalho e também as versões otimizadas utilizando Algoritmos Genéticos (AG) e o Método dos Mínimos Quadrados (LMS). Também foram realizadas comparações com valores medidos, obtidos a partir de uma campanha de medição realizada na cidade de Natal, Estado do Rio Grande do Norte. Os resultados finais obtidos através de simulações e medições apresentaram boas concordâncias métricas, com destaque para a performance do modelo RNBE. A principal contribuição dessa tese é que, ao utilizar essas técnicas que fazem uso de maneira mais eficiente dos modelos de propagação empíricos, pode-se estimar sinais propagantes realistas, evitando erros no planejamento e implementações de redes sem fio LTE e LTE-A em áreas suburbanas.

Palavras-chave: Redes Neurais Artificiais - RNA, Genetic Algorithms - GA; Least Mean Square - LMS; Long Term Evolution - LTE; Long Term Evolution Advanced - LTE-A; modelos de propagação.

Abstract

The perfect functionality of the 3rd and 4th generation of wireless systems requires, among other parameters, knowledge of the numerical values of the prediction of loss of propagation of propagation signals in urban, suburban and rural environments. Therefore, the study of propagation conditions in any environment will always be a concern of design engineers. The analysis and development of robust propagation loss prediction models in Long Term Evolution (LTE) and Long Term Evolution Advanced (LTE-A) communications networks using Artificial Intelligence techniques is performed in this work. The methodologies used were applied to improve the prediction of loss of empirical propagation SUI, ECC-33, Ericsson 9999, TR 36.942 models and the Free Space model applied in LTE and LTE-A networks in the frequencies of 800 MHz, 1800 MHz and 2600 MHz, for suburban environments in mid-sized cities in northeastern Brazil. Thus, in these thesis two models of Artificial Neural Networks (RNA) are proposed: (i) the neural network model with inputs based on error (RNBE) using as main feeder of the network the error between measured and simulated data, and (ii) the neural network model with land-based inputs (RNBT). The performance of these models was compared with the models of propagation considered in the work and also the versions optimized using Genetic Algorithms (AG) and the Least Square Method (LMS). Comparisons were also made with measured values, obtained from a measurement campaign carried out in the city of Natal, state of Rio Grande do Norte. The final results obtained through simulations and measurements presented good metric concordances, with emphasis on the performance of the RNBE model. Thus, the main contribution of this thesis is that, by using these techniques that make more efficient use of empirical propagation models, we can estimate realistic propagation signals, avoiding errors in the planning and implementations of LTE and LTE- A wireless networks in suburban areas.

Keywords: Artificial Neural Networks – ANN, Genetic Algorithm – GA; Least Mean Square – LMS; Long Term Evolution – LTE; Long Term Evolution Advanced – LTE-A; propagation models.

Sumário

Lista de Figuras	ix
Lista de Tabelas	x
Lista de Símbolos e Abreviaturas	xi
Capítulo 1 – Introdução	1
1.1 Motivação – Estado da Arte	1
1.2 Proposta de Trabalho – Metodologia.....	5
1.3 Objetivos Geral e Específicos.....	7
1.4 Organização do trabalho	8
1.5 Publicações	8
Capítulo 2 – Modelos de Predição de Perda de Propagação	9
2.1 O canal de Radiopropagação	9
2.2 Classificações.....	11
2.2.1 Classificação dos Modelos	11
2.2.2 Classificação dos Ambientes	11
2.3 Modelos Utilizados	12
2.3.1 Stanford University Interim Model (SUI)	12
2.3.2 ECC-33	13
2.3.3 Ericsson 9999	14
2.3.4 Espaço Livre	15
2.3.5 TR 36.942	16
Capítulo 3 – Campanha de Medições	17
Capítulo 4 – Técnicas de Otimização	21
4.1 Algoritmos Genéticos	21
4.1.1 Representação Cromossomial	23
4.1.2 Inicialização.....	26
4.1.3 Avaliação	26
4.1.4 Operadores Genéticos.....	27
4.1.5 Aplicação na Otimização de Modelos de Perda de Propagação.....	33
4.2 Método dos Mínimos Quadrados.....	34
Capítulo 5 – Redes Neurais Artificiais	36
5.1 Propriedades.....	37
5.2 Modelo de um Neurônio	38
5.3 Tipos de Função de Ativação.....	42

5.4	Arquiteturas de Redes Neurais	43
5.4.1	Redes <i>Feedforward</i> de Camada Única.....	44
5.4.2	Redes <i>Feedforward</i> de Múltiplas Camadas	44
5.4.3	Redes Recorrentes	46
5.5	Paradigmas de Aprendizagem	46
5.5.1	Aprendizagem Supervisionada.....	47
5.5.2	Aprendizagem Não-Supervisionada.....	47
5.6	Redes Neurais Empregadas na Predição de Perda de Propagação	48
5.6.1	Rede Neural com entrada Baseada em Erro	48
5.6.2	Rede Neural com Entradas Baseadas no Terreno.....	51
Capítulo 6 – Análise de Resultados		52
6.1	Técnicas de Otimização	52
6.2	Modelos de Rede Neural RNBE e RNBT	55
6.3	Resultados.....	57
Capítulo 7 – Considerações Finais		72
Referências Bibliográficas.....		74
Apêndice A.....		79
Apêndice B		85
Apêndice C		88
Apêndice D.....		92
Apêndice E		94
Apêndice F.....		96
Apêndice G.....		98

Lista de Figuras

Figura 1: Os três mecanismos básicos da propagação.....	10
Figura 2: Uma das ruas do bairro de Lagoa Nova, com destaque para a antena em painel, utilizada para receber o sinal	17
Figura 3: Transmissor de ondas de rádio e amplificador de banda larga.	18
Figura 4: Analisador de espectro, utilizado na recepção.	19
Figura 5: O laboratório móvel, destacando o prédio da CTEC ao fundo.	19
Figura 6: Rotas cobertas pela campanha	20
Figura 7: Esquema do algoritmo genético	23
Figura 8: Distribuição de cada indivíduo na roleta.	29
Figura 9: Método do Torneio para $n=3$	30
Figura 10: Cruzamento Uniforme.	31
Figura 11: Cruzamento com 1 ponto.	32
Figura 12: Operador de mutação.	32
Figura 13: Esquema do AG implementado.	33
Figura 14: O neurônio biológico.	39
Figura 15: Modelo de um neurônio artificial, segundo McCulloch-Pitts.....	39
Figura 16: Transformação afim produzida pela presença do bias.	41
Figura 17: Outro modelo não linear de um neurônio artificial.....	41
Figura 18: Principais funções de ativação	43
Figura 19: Rede <i>Feedforward</i> de camada única.	44
Figura 20: Rede <i>Feedforward</i> de múltiplas camadas.....	45
Figura 21: Redes Recorrentes.....	46
Figura 22: Fluxograma do processo de treinamento.	49
Figura 23: Arquitetura da RNA implementada.	50
Figura 24: Uma das execuções com os parâmetros de treinamento, validação e teste...	56
Figura 25: Curvas de perda de propagação em relação ao modelo do Espaço Livre, rota 1, em 800 MHz.	59
Figura 26: Resultados em relação ao modelo TR 36.942 em 800 MHz na rota 2.....	59
Figura 27: Perda de propagação em relação ao modelo Ericsson em 800 MHz na rota 3.	60
Figura 28: Elementos do diagrama de caixa.....	61
Figura 29: Diagrama de caixa para os resultados do modelo Espaço Livre na rota 1 em 800 MHz.	62
Figura 30: Curvas das perdas em relação ao TR 36.942 para a rota 1 em 1800 MHz. ..	64
Figura 31: Perdas de propagação em relação ao modelo SUI, 1800 MHz na rota 2.	64
Figura 32: Perdas em relação ao modelo ECC para 1800 MHz na rota 3.	65
Figura 33: Diagrama de caixa para os resultados do modelo SUI, 1800 MHz na rota 2.	66
Figura 34: Curvas das perdas de propagação em relação ao modelo SUI, rota 1, em 2600 MHz.	68
Figura 35: Perdas em relação ao modelo Ericsson em 2600 MHz na rota 2.	68
Figura 36: Curvas das perdas em relação ao modelo ECC, 2600 MHz na rota 3.	69
Figura 37 : Diagrama de caixa para os resultados do modelo ECC em 2600 MHz, rota 3.	69

Lista de Tabelas

Tabela 1 – Modelos de propagação empregados neste trabalho.	12
Tabela 2 – Tipos de terrenos.....	13
Tabela 3 – Terminologia dos AGs.....	22
Tabela 4– Exemplo de codificação binária.....	24
Tabela 5 – Exemplo de codificação real.....	25
Tabela 6– Comparação entre as codificações decimal, binária e Gray.	25
Tabela 7 – Representação do método da Roleta.....	28
Tabela 8 – Valores dos parâmetros da configuração básica dos AGs.	34
Tabela 9–Parâmetros básicos da RNBE.	50
Tabela 10 – Expoentes de Perda de Percorso.	52
Tabela 11 –Versões Originais das Equações.....	53
Tabela 12–Equações Modificadas para 800 MHz.....	54
Tabela 13 - Equações Modificadas para 1800 MHz.....	54
Tabela 14 - Equações Modificadas para 2600 MHz.....	55
Tabela 15 –MSE do arranjo de dados de validação em relação ao número de neurônios na camada oculta para 800 MHz.	56
Tabela 16 –MSE do arranjo de dados de validação em relação ao número de neurônios na camada oculta para 1800 MHz.	56
Tabela 17 - MSE do arranjo de dados de validação em relação ao número de neurônios na camada oculta para 2600 MHz.	57
Tabela 18– RMSE e valor de p para todas as técnicas em 800 MHz.	58
Tabela 19 – RMSE e valor de p para todas as técnicas em 1800 MHz.	63
Tabela 20 – RMSE e valor de p para todas as técnicas em 2600 MHz.	66

Lista de Símbolos e Abreviaturas

3G - Redes de Terceira Geração

3GPP - *Third Generation Partnership Project*

4G - Redes de Quarta Geração

AE - Algoritmos Evolucionários

CWI - COST231-Walfisch-Ikegami

ECC - *Electronic Communication Committee*

GA - *Genetic Algorithms* (Algoritmos Genéticos)

GPS- *Global Positioning System*

GRNN - *General Regression Neural Network*

IA - Inteligência Artificial

IEEE - Instituto de Engenheiros Eletricistas e Eletrônicos

LMS - *Least Mean Square* (Método dos Mínimos Quadrados)

LTE - *Long Term Evolution*

LTE-A - *Long Term Evolution Advanced*

MLP-NN - *Multilayer Perceptron Neural Network* (Rede Neural Perceptron de Multicamadas)

MSE - *Mean Square Error* (Erro Quadrático Médio)

RBFN - *Radial Base Function Network* (Rede Neural com Função de Ativação de Base Radial)

RMSE - *Root Mean Square Error* (Raiz do Erro Quadrático Médio)

RNA - Redes Neurais Artificiais

RNBE - Rede Neural Baseada em Erro

RNBT - Rede Neural Baseada no Terreno

SUI - Stanford University Interim Model

WMAN - *Wireless Metropolitan Area Networks*

Capítulo 1

Introdução

1.1 Motivação – Estado da Arte

O paradigma de acesso à Internet vem sofrendo modificações, onde o modelo de acesso centralizado está sendo substituído por um cenário em que as novas tecnologias permitem que os usuários tenham acesso aos mais diversos tipos de informações em tempo real, em quase todos os lugares.

As redes de telefonia móvel de quarta geração (4G) chegaram para satisfazer as demandas criadas por esse novo cenário de comunicação (principalmente em locais carentes de pontos de acesso *WiFi*), onde os usuários, por meio de dispositivos como *smartphones* ou *tablets*, usam cada vez mais uma grande quantidade de aplicações *on-line*, o que exige melhorias na qualidade e cobertura de redes celulares, além do uso de taxas de dados mais elevadas, o que requer mais largura de banda.

Neste contexto, *Long Term Evolution* (LTE) e *LTE Advanced* (LTE-A) representam o último passo das redes de terceira geração (3G) para a quarta geração. Ambas as tecnologias funcionam na mesma banda de frequência (SHABBIR et al., 2011). A taxa de dados de pico do padrão LTE para *downlink* e *uplink* pode chegar a 326,4 e 86,4 Mbps, respectivamente (RUMNEY, 2013), enquanto o LTE-A aumenta consideravelmente essas especificações: ele eleva as taxas de dados de pico, alcançando 3 Gbps para *downlink* e 1,5 Gbps para *uplink*; para tal, requer uma largura de banda de até 100 MHz (AHMED, 2013).

Para atingir as condições para satisfazer os requisitos exigidos pelo LTE e LTE-A, é necessário um planejamento de rede eficiente e preciso durante a implantação preliminar do sistema, onde devem ser conhecidas as características de propagação do ambiente.

Os modelos de perda de propagação são importantes na predição de área de cobertura, análise de interferência, alocações de frequência e parâmetros de célula –

sendo esses componentes básicos no processo de planejamento de rede dentro do projeto de um sistema de comunicações móveis (NKORDEH et al., 2014). Entender o canal de rádio para a implantação da rede é vital, sendo a modelagem do canal de radiopropagação usando modelo de perda de propagação mais apropriado, um fator essencial e que traz uma maior economia de tempo e recursos.

Os modelos de propagação podem ser classificados como: determinísticos, empíricos e físico-estatísticos (AHMAD et al., 2012; PALLARDÓ, 2008). Os primeiros podem ser considerados o método mais preciso, baseiam-se no comportamento das ondas de rádio propagadas no espaço, calculando matematicamente as perdas de propagação, com base na formulação teórica. Para tal, é necessária uma quantidade robusta e precisa de informação, não apenas sobre edifícios e terrenos, mas também sobre coeficientes de reflexão e difração das superfícies que estão no trajeto de propagação.

A teoria de propagação de ondas eletromagnéticas não prevê com precisão os modelos empíricos. Demonstra-se que esses modelos dependem mais das medições de intensidade de campo no ambiente específico. Por fim, os modelos físico-estatísticos combinam informações empíricas e estatísticas sobre o ambiente com o objetivo de reduzir o custo computacional.

Visando tornar os sistemas de comunicação mais precisos - buscando um planejamento mais eficiente, muitos esforços foram feitos para o desenvolvimento de métodos de simulação de predição de cobertura capazes de estimar com precisão os dados medidos. Nesse sentido, algumas técnicas podem ajudar a fornecer métodos de simulação mais eficientes, reduzindo erros e fornecendo resultados mais confiáveis.

Em relação às técnicas de Inteligência Artificial (IA), as Redes Neurais Artificiais (RNA) estão experimentando um grande desenvolvimento nos últimos anos, onde um grande número de aplicações podem ser elencadas: processamento de sinais, previsão, mineração de dados, agrupamento de dados, classificação de padrões, reconhecimento de padrões e controle de processos, entre outras características (WU et al., 2010; ASGARI et al., 2013; HINTON et al., 2012).

Para a engenharia de telecomunicações, o problema na predição da perda de propagação (ou perda de percurso) entre dois pontos pode ser interpretado como uma solução na obtenção de uma função de várias entradas e uma única saída, onde as

entradas contêm informações sobre as localizações do transmissor e do receptor, a frequência, os edifícios próximos, etc.

Assim, a predição pode ser descrita como a transformação de um vetor de entrada contendo informações topográficas e morfológicas sobre o ambiente para o valor de saída desejado (POPESCU et al., 2005). Uma vez que as redes neurais artificiais podem ser empregadas na resolução de problemas de aproximação de funções não-lineares, elas são adequadas para o problema da estimativa da perda de propagação.

Muitos trabalhos envolvendo abordagens de RNAs para a predição de perda de percurso podem ser encontrados na literatura. A maioria deles difere no tipo e arquitetura da RNA, mas principalmente nos parâmetros utilizados como entradas da rede neural. Essas informações podem variar de uma única entrada envolvendo a distância do transmissor ao receptor (WU et al., 2010), a dados sobre o ambiente e características de propagação, tais como alturas das construções, tipo de terreno (urbano, suburbano, rural) e larguras das ruas, entre outras.

Ostlin et al. (2004), utilizou medições realizadas na área rural da Austrália para treinar um modelo de rede neural artificial usado na predição de ondas de rádio. As entradas da rede foram a distância para a estação base, altura da antena transmissora e o ângulo de desobstrução (baseado na análise da elipsóide de Fresnel). O desempenho da rede foi comparado com o modelo ITU-R¹ P.1546. No final, a RNA apresentou, em geral, melhores previsões do que P.1546. Os autores descobriram que redes *feed-forward* maiores são mais sensíveis aos dados de treinamento e obtiveram previsões menos precisas quando alimentadas com entradas fora do espaço de parâmetros de treinamento. Eles também observaram que, quando são alimentados com dados semelhantes ao conjunto de treinamento, as previsões são mais precisas.

Anos mais tarde, o estudo foi continuado (OSTLIN et al., 2010), usando a mesma experiência para avaliar redes agora com números diferentes de camadas e neurônios ocultos, além de outros algoritmos de treinamento (gradiente descendente e Levenberg-Marquardt). Nesse caso, o objetivo foi obter estatísticas sobre o tempo de treinamento, precisão de predição e propriedades de generalização. Os parâmetros de entrada foram os mesmos de Ostlin et al. (2004)

Angeles e Dadios (2015), avaliaram a viabilidade de um modelo de propagação baseado em redes neurais como uma alternativa aos modelos físicos e empíricos. A rede

¹ International Telecommunication Union Recommendation

tem a particularidade de, ao invés de usar medidas de perda de propagação reais, empregam dados de simulação baseados no modelo Longley-Rice para o treinamento da RNA. Três entradas foram usadas: a distância para o transmissor, o azimute do transmissor para o receptor e a elevação acima do nível do mar no local do receptor. O desempenho foi comparado com o modelo de propagação no Espaço Livre e o modelo empírico de Egli. Os autores concluíram que o modelo baseado na RNA teve um desempenho bastante superior em comparação com os modelos de propagação comumente usados.

No trabalho desenvolvido por Popescu et al. (2002), são apresentados os resultados da aplicação de uma Rede Neural de Regressão Geral (*General Regression Neural Network* - GRNN) na modelagem da perda de percurso em áreas urbanas e suburbanas. Diversos modelos de redes neurais foram testados para ambos os ambientes, diferindo apenas nos parâmetros de entrada. As principais entradas consideradas foram as seguintes: distâncias entre transmissor e receptor, largura das ruas, separação de edifícios e altura dos edifícios. Os dados medidos recolhidos na cidade de Kavala e na Ilha de Santorini, na Grécia, foram utilizados para o treinamento.

O modelo baseado em GRNN foi comparado com Walfisch-Bertoni (WB) e uma versão modificada de COST231-Walfisch-Ikegami (CWI). O modelo de rede neural empregado obteve melhora significativa na predição devido à sua propriedade de generalização. Os resultados, em termos da Raiz do Erro Quadrático Médio (REQM, do inglês, *Root Mean Square Error* - RMSE), variaram de 5,35 dB a 8,66 dB e de 3,68 dB a 5,23 dB nos cenários urbano e suburbano, respectivamente. O artigo também apresentou um modelo híbrido de correção de erros, baseado na combinação do modelo determinístico CWI e uma rede neural. Esta abordagem foi posteriormente expandida (POPESCU et al., 2005).

O modelo baseado em GRNN, assim como uma Rede Neural Perceptron de Multicamadas (RNPMC, ou *Multilayer Perceptron Neural Network* - MLP-NN) e uma Rede Neural com Função de Ativação de Base Radial (RN-RBF ou *Radial Base Function Network*, RBFN), construída sobre dois tipos de redes: um modelo de RNA simples, com cinco entradas: distâncias entre transmissor e receptor, largura das ruas, altura dos edifícios, separação de edifícios e orientação de rua, juntamente com um modelo de RNA híbrido baseado em correção de erros, utilizando o modelo COST-Walfisch-Ikegami.

O CWI é considerado um modelo físico/estatístico (ou semi-empírico), exigindo informações sobre o perfil do terreno, como as distâncias entre transmissor e receptor, alturas do nível mais alto do edifício e espaço entre edifícios.

No final, não houve diferença significativa entre a predição feita pelas versões analisadas. Para ambientes urbanos, os modelos simples RBFN e MLP obtiveram um valor de RMSE de 5,35 dB e 6,55 dB, respectivamente, enquanto um RMSE de 5,30 dB e 6,07 dB foi calculado para os modelos híbridos RBFN e MLP. Em relação às áreas suburbanas, o RBF e o MLP híbridos obtiveram um RMSE de 3,71 dB e 3,77 dB, enquanto que os RBF e MLP simples obtiveram um valor de RMSE de 3,68 dB e 3,74 dB, respectivamente.

O trabalho realizado por Sanches e Cavalcante (2004) simplifica essa abordagem, desenvolvendo também um modelo híbrido baseado em erro, mas usando modelos empíricos de propagação. Isto exige que apenas os elementos básicos, tais como a frequência atribuída e as distâncias entre o transmissor e o receptor, sejam necessários para alimentar a rede. O trabalho abrangeu as frequências de 800 MHz e 1800 MHz, e utilizou os modelos Okumura-Hata, Walfisch-Bertoni, Ibrahim-Parsons, Ericson, COST231-Hata e Walfisch-Ikegami.

1.2 Proposta de Trabalho – Metodologia

Este trabalho se propõe analisar, implementar e aplicar dois tipos de Redes Neurais Artificiais (RNAs), com arquitetura semelhante, mas com tipos diferentes de entradas. Nos procedimentos metodológicos empregados, é realizado o estudo analítico da predição de perda de propagação de ondas eletromagnéticas para sistemas LTE e LTE-A, para regiões suburbanas de cidades de porte médio no nordeste brasileiro.

O primeiro modelo proposto consiste no arranjo de uma rede neural com entradas baseadas em erro, utilizando como principal alimentador da rede o erro entre dados medidos e simulados. Neste caso, a RNA se inspira no modelo de propagação híbrido, baseado em erro, desenvolvido por Popescu et al. (2002), cuja abordagem utilizando modelos empíricos foi realizada por Sanches e Cavalcante (2004). A rede neural implementada para este trabalho utiliza os mesmos tipos de entradas empregadas na RNA utilizada nos estudos citados: a distância entre transmissor e receptor e o erro entre dados medidos e valores preditos por modelos empíricos (além do modelo

determinístico do Espaço Livre). Esta abordagem é referenciada neste trabalho como Rede Neural com entrada Baseada em Erro (RNBE).

O segundo modelo proposto utiliza entradas baseadas em características do terreno e do *setup* de medições. Assim, as características utilizadas como entrada, são: distância do transmissor ao receptor, altitude do receptor, nível médio do terreno e azimute entre transmissor e receptor. Esta abordagem é referenciada, neste trabalho como Rede Neural com entradas Baseadas no Terreno (RNBT).

Para os modelos propostos nesse trabalho são realizadas comparações para os mesmos dados usando duas técnicas de otimização: o Método dos Mínimos Quadrados (MMQ, do inglês, *Least Mean Square* - LMS) e Algoritmos Genéticos (AG, do inglês, *Genetic Algorithm* - GA). A otimização é obtida por meio do ajuste de determinados valores do grupo padrão de constantes, a maioria deles em termos de distância e frequência, com base na diferença entre os valores preditos pelos modelos de propagação e os coletados em medições.

A predição é calculada pelos modelos Ericsson 9999, Espaço Livre, SUI, ECC-33 e TR 36. 942. O experimento foi realizado para áreas suburbanas, nas frequências de 800 MHz, 1800 MHz e 2600 MHz. Os modelos SUI e ECC-33 foram aplicados em 1800 e 2600 MHz, enquanto o modelo de propagação do Espaço Livre foi empregado na frequência de 800 MHz; Ericsson e TR 36.942 abrangem as três bandas.

A faixa de 800 MHz está presente nas bandas 20 (791 MHz - 821 MHz), 28 (758 MHz - 823 MHz) e 44 (703 MHz - 803 MHz) para as redes LTE e LTE-A, sendo implantado em países como França, Alemanha, Itália, Marrocos e Tunísia. No que se refere a 2600 MHz, esta frequência está presente nas faixas 7 (2620 MHz - 2690 MHz), 38 (2570 MHz - 2620 MHz) e 69 (2570 MHz - 2620 MHz) adotadas por, entre outros países, Gana, Canadá, Colômbia, Chile e Brasil. Por fim, a faixa de 1800 MHz está inserida na banda 3 (1805 - 1880), com presença em países como Marrocos, África do Sul, Brasil, Israel e Nova Zelândia.

Na metodologia aplicada nesse trabalho, também foram realizadas comparações das técnicas citadas, procurando encontrar qual delas alcançam resultados de simulação mais próximos dos dados obtidos a partir das medições. Para tanto, uma campanha de medições foi realizada compreendendo três rotas diferentes no distrito de Lagoa Nova, na cidade de Natal, Brasil.

O software MATLAB (R2011a, versão 7.12, The Mathworks) foi usado para executar a implementação dos métodos computacionais. Já os dados referentes às

distâncias, nível médio de terreno e altitude foram obtidos por meio do software Sistema de Informações Geográficas da Anatel (SIGANATEL).

Para avaliar o desempenho de cada técnica, são aplicadas duas métricas: o RMSE, que estima o erro de diferença, em dB, entre os conjuntos de dados; enquanto o teste *Wilcoxon rank-sum* fornece um teste de similaridade entre os conjuntos de dados de distribuição.

Esta tese de doutorado utilizou todos os procedimentos descritos anteriormente, além de empregar também o método da pesquisa experimental. Esse tipo de pesquisa é caracterizada pelo fato do pesquisador analisar o problema, construir suas hipóteses e manipular as variáveis relativas ao fenômeno observado, analisando o resultado e tirando conclusões dessas relações.

1.3 Objetivos Geral e Específicos

Em seguida serão listados os objetivos deste trabalho.

OBJETIVO GERAL:

- Analisar e implementar diferentes técnicas computacionais de otimização e baseadas em RNAs, utilizando modelos empíricos e do Espaço Livre, para predição de perda de propagação para três frequências de interesse dos sistemas LTE e LTE-A: 800 MHz, 1,8 GHz e 2,6 GHz.

OBJETIVOS ESPECÍFICOS:

- Implementar um modelo de RNA contendo dois tipos de entradas: as distâncias entre transmissor e receptor e o erro entre dados experimentais e dados preditos;
- Implementar uma RNA com quatro entradas, utilizando dados relativos à características do *set up* de medições e do terreno;
- Implementar um algoritmo genético capaz de otimizar constantes presentes em modelos de perda de propagação;
- Implementar o método dos mínimos quadrados para otimizar constantes presentes nos modelos de propagação;
- Realizar uma campanha de medição para coleta de dados experimentais²;
- Comparar os valores obtidos pelos métodos computacionais com os dados medidos;
- Analisar os resultados, usando como métrica o RMSE e o método do *Wilcoxon rank-sum*.

² Maiores detalhes sobre as medições são apresentados no Capítulo 3: Campanha de Medições

1.4 Organização do trabalho

Este trabalho está organizado em seis capítulos. No capítulo 2, é feita uma revisão teórica dos modelos de propagação empregados. São abordados os modelos SUI, ECC-33, TR 36.942, Espaço Livre e Ericsson. Por sua vez, no capítulo 3 são apresentados detalhes sobre a campanha de medição conduzida nas proximidades do campus da UFRN. Já no capítulo 4, detalhes sobre as duas técnicas de otimização, AG e LMS, são descritos. No capítulo 5, mais informações sobre os dois métodos baseados em RNAs, os modelos RNBE e RNBT, são fornecidas. Um teste comparativo, bem como uma análise de resultados, envolvendo os métodos empregados e os dados experimentais coletados na campanha são mostrados no capítulo 6. Finalmente, o capítulo 7 apresenta as considerações finais, abordando as conclusões e as propostas de continuidade.

1.5 Publicações

Eventos Científicos:

2015, Bruno J. Cavalcante, Priscila Alves, Adaildo G. d'Assunção e Laércio M. de Mendonça, **Study of Propagation Models for LTE and LTEA Networks Using Genetic Algorithms at 850 MHz in Suburban Areas**, ICEAA IEEE APWC 2015, Resumo Expandido.

2016, Bruno J. Cavalcanti, Adaildo G. d'Assunção e Laércio M. de Mendonça, **Técnica de Otimização usando Algoritmo Genético em Modelos de Propagação para Redes LTE e LTEA para Áreas Urbanas e Suburbanas**, MOMAG 2016, Trabalho Completo.

2017, Bruno J. Cavalcanti Adaildo G. d'Assunção e Laércio M. de Mendonça , **Optimizing Empirical Propagation Models for LTE and LTEA Using Genetic Algorithms at 879 MHz**, IEEE-APS Topical Conference on Antennas and Propagation in Wireless Communications 2017, Trabalho Completo.

Periódicos:

2017, Bruno J. Cavalcanti, Gustavo A. Cavalcante, Laércio M. de Mendonça, Gabriel M. Cantanhede, Marcelo M.M.de Oliveira and Adaildo G. D'Assunção , **A Hybrid Path Loss Prediction Model based on Artificial Neural Networks using Empirical Models for LTE And LTE-A at 800 MHz and 2600 MHz**, JOURNAL OF MICROWAVES, OPTOELECTRONICS AND ELECTROMAGNETIC APPLICATIONS (JMoe)³: ISSN: 2179-1074.

³ <http://www.jmoe.org/index.php/jmoe/article/view/925>

Capítulo 2

Modelos de Predição de Perda de Propagação

2.1 O Canal de Radiopropagação

O canal móvel impõe limitações fundamentais para o desempenho dos sistemas de comunicação sem fio. O percurso do sinal entre o transmissor e o receptor pode variar desde uma linha de visada até obstruções ocasionados por prédios ou montanhas (RAPPAPORT, 2009).

A modelagem do canal de rádio representa um dos parâmetros mais difíceis de analisar nos sistemas de comunicação sem fio. A existência de ruídos aleatórios que se adicionam aos sinais desejados, tornam os canais com características aleatórias. Dessa forma, a modelagem deve ser realizada estatisticamente.

Os mecanismos relacionados à propagação de ondas eletromagnéticas são diversos, mas são geralmente atribuídos a três fatores principais, chamados de três mecanismos básicos da propagação (RAPPAPORT, 2009): reflexão, difração e espalhamento (Figura 1).

- Reflexão: Ocorre quando a onda eletromagnética propagada colide com objetos de dimensões bem maiores que o comprimento de onda da onda propagada (superfície da terra, edifícios e paredes, por exemplo). Uma parte da energia da onda é refletida, enquanto a outra é transmitida, penetrando no outro meio. As parcelas correspondentes às energias transmitidas e refletidas podem ser calculadas usando os coeficientes de transmissão, sendo dependentes de fatores como: permissividade elétrica, permeabilidade magnética, condutividade dos meios, ângulo de incidência e a frequência (CAVALCANTE, 2010).
- Difração: Esse fenômeno ocorre quando o percurso entre o transmissor e o receptor é obstruído por uma superfície áspera. As ondas secundárias resultantes da superfície do obstáculo estão presentes em todo o espaço inclusive atrás do

obstáculo, causando a curvatura da onda, fazendo com que ela apareça em pontos fora da linha de visada (RAPPAPORT, 2009).

- Espalhamento: Ocorre quando a onda se depara com objetos cujas dimensões são pequenas em comparação com o comprimento de onda da onda incidente e onde o número de obstáculos por volume unitário é grande. Essa situação geralmente ocorre quando o meio é constituído por pequenos objetos ou com superfícies ásperas ou rugosas, como folhagens e fios.

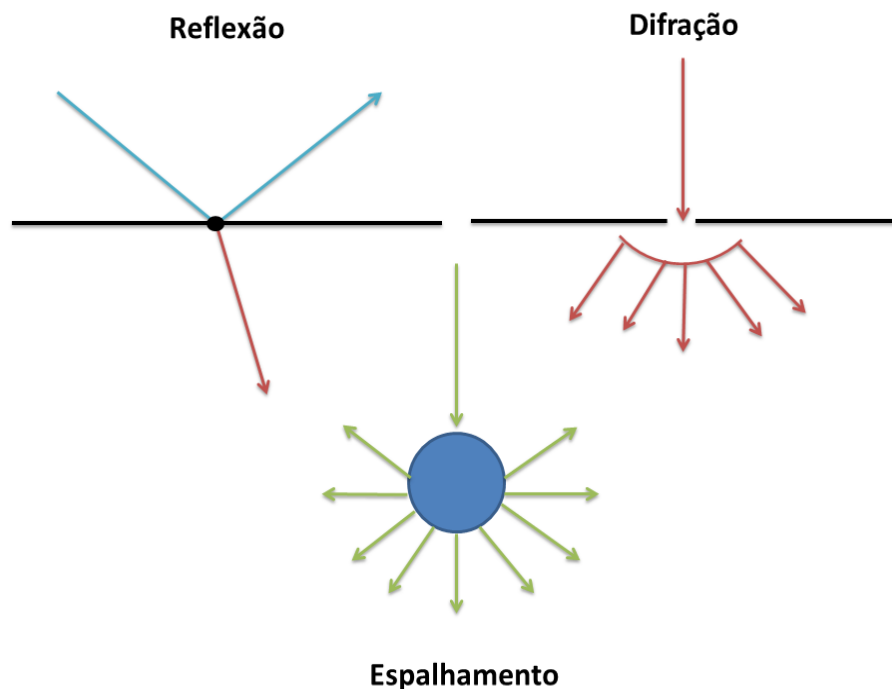


Figura 1: Os três mecanismos básicos da propagação. Fonte: o autor.

Ao longo do percurso entre o transmissor e receptor, o sinal de rádio sofre múltiplas reflexões, o que faz com que a onda percorra diferentes caminhos com diferentes distâncias (RAMOS, 2001). Ao chegar no receptor, quando essas ondas se combinam, ocorre um fenômeno chamado de desvanecimento de multipercurso, além de uma atenuação do nível do sinal em função da distância entre o transmissor e receptor.

É possível distinguir dois tipos de desvanecimento. As flutuações rápidas do sinal são chamadas de desvanecimento em pequena escala, sendo associadas ao multipercurso. À variação mais suave e lenta, dá-se a denominação de desvanecimento em larga escala, associada ao sombreamento por obstáculos, como montanhas ou edifícios (RAMOS, 2001).

2.2 Classificações

2.2.1 Classificação dos Modelos

O cálculo da predição da perda de propagação é relativamente complexo, uma vez que as diferenças entre ambientes envolvem vários parâmetros que estão sujeitos a alterações. Existem três tipos de modelos de perda de propagação: determinísticos, empíricos e físico/estatísticos (AHMAD et al.,2012; PALLARDÓ, 2008).

- Determinístico: utilizado para analisar situações conhecidas. Baseiam-se em cálculos teóricos sobre uma geometria fixa. Para usar esses métodos, é necessário possuir um banco de dados com informações geográficas do terreno e conhecer os coeficientes de reflexão e difração das superfícies. Além disso, o uso dos modelos determinísticos envolvem um esforço computacional muito grande.
- Empíricos: se baseiam nos resultados das campanhas de medição em diferentes cenários. Eles não predizem o comportamento preciso do *link* de rádio, mas provém uma boa aproximação. Para obter um resultado mais preciso, é necessário realizar medições em em cada cenário, em todas as situações possíveis que podem acontecer.
- Físico-estatísticos: combinam modelos determinísticos com estatísticas sobre o ambiente, visando diminuir o custo computacional.

2.2.2 Classificação dos Ambientes

A classificação dos diferentes ambientes de propagação levam em consideração algumas características do ambiente em questão, tais como: densidade de vegetação, ondulação do terreno, altura e localização de edifícios e a existência de áreas abertas, ou de superfícies aquáticas, entre outras (CAVALCANTE, 2010).

A partir do estudo dessas características, os ambientes podem ser classificados como: densamente urbanos, urbanos, suburbanos e rurais (RAPPAPORT, 2000 apud CAVALCANTE, 2010). Ambientes densamente urbanos são aqueles em que há predomínio de conglomerados edifícios residenciais e comerciais com altura elevada,

além de uma elevada densidade demográfica. Já os ambientes urbanos são definidos como áreas que possuem edifícios de médio porte, distribuídos aleatoriamente, mas com elevada densidade demográfica.

As áreas suburbanas são compostas por casa residenciais a poucos prédios de média altura, contanto com uma densidade média de vegetação e população. Por fim, as áreas rurais são aquelas que contam com poucas construções e possuem uma alta densidade de vegetação.

2.3 Modelos Utilizados

Nesta pesquisa, foram analisados cinco diferentes modelos: SUI, ECC-33 e TR 36.942. A Tabela 1 relaciona os modelos com as frequências abrangidas no trabalho.

Tabela 1 – Modelos de propagação empregados neste trabalho.

Modelo/Faixa de Frequência	800 MHz	1800 MHz	2600 MHz
SUI		X	X
ECC-33		X	X
Ericsson 9999	X	X	X
Espaço Livre	X		
TR 36.942	X	X	X

Fonte : o autor.

2.3.1 Stanford University Interim Model (SUI)

MAHESH et al. (2014) considera os terrenos tipo A característicos de áreas densas urbanas, os terrenos tipo B como áreas suburbanas e os terrenos tipos C, característicos como ambientes rurais.

Uma versão estendida do modelo SUI, proposto pelo IEEE 802.16 (SENARATH, et al.,2007), superou esta limitação da faixa de frequência, extrapolando-o para frequências de até 11 GHz . A expressão de perda de percurso, PL_{SUI} é obtida por (BASU et al., 2016 ; CASTRO et al., 2011) :

$$PL_{SUI} = A + 10\gamma \log_{10} \left(\frac{d}{d_0} \right) + \Delta L_f + \Delta L_h + s \quad (1)$$

com $d > d_0$, onde:

$$A = 20 \log_{10} \left(\frac{4\pi d_0}{\lambda} \right) \quad (2)$$

$$\gamma = a - bh_b + \frac{c}{h_{Tx}} \quad (3)$$

$$\Delta L_f = 6 \log_{10} \left(\frac{f}{2000} \right) \quad (4)$$

$$\Delta L_h = -10,8 \log_{10} \left(\frac{h_{Rx}}{2} \right) \quad (5)$$

$$\Delta L_h = -20 \log_{10} \left(\frac{h_{Rx}}{2} \right) \quad (6)$$

$$s = 0,65 [\log_{10}(f)]^2 - 1,3 + \log_{10}(f) + \alpha \quad (7)$$

onde f é a frequência de operação (MHz), d_0 é a distância de referência (100 m), d é a distância entre a estação rádio base e o receptor (m), ΔL_f é o fator de correção de frequência, ΔL_h é o fator de correção da altura da antena do receptor, onde (5) vale para terrenos tipos A e B e (6) é utilizado para terrenos tipo C, h_{Tx} é a altura da antena da estação rádio base (m), h_{Rx} é a altura da antena do receptor (m), e λ é o comprimento de onda (m). O parâmetro s é o efeito de sombreamento, onde α vale 5,2 dB para ambientes urbanos e suburbanos (terrenos tipo A e B) e 6,6 dB para ambiente rural (terreno C). Por fim, γ é o expoente de perda de propagação para os diferentes tipos de terreno, definido pelos parâmetros a , b e c (Tabela 2).

Tabela 2 – Tipos de terrenos.

Parâmetro	Terreno A	Terreno B	Terreno C
a	4,6	4	3,6
b	0,0075	0,0065	0,005
c	12,6	17,1	20

Fonte : o autor.

2.3.2 ECC-33

A versão inicial do SUI foi aprovada pelo IEEE (Instituto de Engenheiros Eletricistas e Eletrônicos) para redes do tipo *Wireless Metropolitan Area Networks* (WMAN), sendo baseado no modelo Erceg (ERCEG et al.,1999), para frequências em torno de 2 GHz. Abrange três tipos de ambiente: o ambiente de tipo A está associado à perda de percurso máximo, utilizada em cenários com proeminências irregulares e densidade de vegetação moderada.

O modelo ECC-33, desenvolvido pelo *Electronic Communication Committee* (ECC), é uma extrapolação das medições originais obtidas por Okumura, em Tóquio. O

ECC-33 modificou os pressupostos de Okumura de forma a poder representar mais de perto um sistema de acesso sem fios fixo (*Fixed Wireless Access - FWA*), sendo aplicável a frequências de até 3,5 GHz (JADHAV e KALE, 2014). A formulação de perda de percurso do modelo ECC-33, PL_{ECC} , (em dB), pode ser expressa como (JADHAV e KALE, 2014; ALAM e KHAN,2013):

$$PL_{ECC} = A_{fs} + A_{bm} - G_b - G_r \quad (8)$$

onde:

$$A_{fs} = 92,45 + 20\log_{10}(d) + 20\log_{10}(f) \quad (9)$$

$$A_{bm} = 20,41 + 9,83\log_{10}(d) + 7,894\log_{10}(f) + 9,56[\log_{10}(f)]^2 \quad (10)$$

$$G_b = \log_{10}\left(\frac{h_{Tx}}{200}\right) \{13,958 + 5,8[\log_{10}(d)]^2\} \quad (11)$$

onde A_{fs} é a atenuação do espaço livre (dB), A_{bm} é a perda média de percurso (dB), que depende da distância (km) da antena da estação base para a antena do usuário e da frequência de operação f (GHz). Além disso, G_b é o ganho (dB) da antena da estação base, para uma certa altura (m), e G_r é o ganho da antena do usuário, considerando a altura (m).

Na equação (8), para cidades médias, G_r (dB) é dado por:

$$G_r = [42,57 + 13,7\log_{10}(f)][\log_{10}(h_{Rx}) - 0,585] \quad (12)$$

Para cidades grandes, G_r é obtido pela expressão:

$$G_r = 0,759(h_{Rx}) - 1,862 \quad (13)$$

2.3.3 Ericsson 9999

Houve várias sugestões para melhorar os modelos Okumura-Hata e Cost 231 - Hata, levando em consideração o ambiente de propagação. Um desses modelos é o Ericsson 9999, desenvolvido por engenheiros da própria companhia (MILANOVIC et al., 2007; ELNASHAR, et al., 2014). Projetado originalmente para operar na faixa de 150 MHz a 2 GHz, é possível estender para além dessa faixa por meio do ajuste dos parâmetros. A perda de percurso para o Ericsson, pode ser obtida pela seguinte expressão:

$$PL_E = a_0 + a_1\log_{10}(d) + a_2\log_{10}h_{Rx} + a_3\log_{10}h_{Tx}\log_{10}(d) - 3,2(\log_{10}11,75h_{Rx})^2 + g(f) \quad (14)$$

Onde:

$$g(f) = 44,9 \log_{10}(f) - 4,78[\log_{10}(f)] \quad (15)$$

onde f é a frequência de operação (MHz), d é a distância entre a estação rádio base e o receptor (m), h_{Tx} é a altura da antena da estação rádio base (m) e h_{Rx} é a altura da antena do receptor (m), Por fim, a_0, a_1, a_2 e a_3 são constantes que podem ser modificadas de acordo com o cenário. Os valores padrão dessas constantes são: $a_0 = 36,2, a_1 = 30,2, a_2 = 12,0$ e $a_3 = 0,1$.

2.3.4 Espaço Livre

Esse modelo é aplicado quando a linha de visada entre o transmissor e o receptor está livre de obstáculos, prevendo que a potência diminui com o aumento da distância de separação entre transmissor e receptor. A equação para calcular a potência recebida também conhecida como fórmula de Friss para o espaço livre, é dada pela seguinte expressão (RAPPAPORT, 2009):

$$P_r(d) = \frac{P_t g_t g_r \lambda^2}{(4\pi)^2 d^2 L} \quad (16)$$

onde P_t é a potência transmitida, $P_r(d)$ é a potência recebida (em watts), g_t e g_r são os ganhos da antena transmissora e antena receptora, respectivamente, λ é o comprimento de onda, d é a distância (m) e L é o fator de perda, com $L > 1$. Na forma logaritma, (16) é expressa como:

$$P_r(d) = P_t(dB) + G_t(dB) + 20 \log\left(\frac{\lambda}{4\pi d}\right) - L \quad (17)$$

Os valores dos parâmetros estão em dB. Para o cálculo da atenuação:

$$\text{Atenuação (dB)} = P_t(dB) - P_r(dB) \quad (18)$$

Embora a equação de perda de espaço livre dada acima pareça indicar que a perda depende da frequência, a atenuação proporcionada pela distância percorrida no espaço não depende deste parâmetro, sendo constante. Aplicando o uso da antena isotrópica, e colocando a perda básica de transmissão no espaço livre em função da frequência, tem-se:

$$P_{EL} = 32,45 + 20 \log(f) + 20 \log(d) \quad (19)$$

onde d é a distância entre a estação rádio base e o receptor (m) e f é a frequência de operação. Os valores dos parâmetros estão em dB.

2.3.5 TR 36.942

Este modelo de propagação foi criado pelo grupo de especificações técnicas *Third Generation Partnership Project (3GPP)* como uma das especificações para o LTE, apresentado no relatório técnico 36.942. O TR 36.942 ser aplicado em ambientes urbanos / suburbanos e rurais. O cálculo da perda de caminho para áreas urbanas e suburbanas é obtido através de:

$$L = 40[1 - 0,004Dhb] \log_{10}(d) - 18 \log_{10}(Dhb) + 21 \log_{10}(f) + 80 \quad (20)$$

onde d é a distância entre a estação rádio base e o receptor, em quilômetros, f é a frequência de operação e Dhb é a altura da antena transmissora, media a partir do nível médio dos telhados.

Após L ser calculado, um fator de sombreamento com distribuição log-normal, $\text{Log } F$, com desvio padrão de 10 dB deve ser adicionado. Um fator de correlação de sombreamento (variando entre 0,5 e 1, dependendo do tipo de sombreamento) também deve ser utilizado. A fórmula final é expressa como:

$$PL_{TR} = L - \text{Log}F \quad (21)$$

Capítulo 3

Campanha de Medições

A campanha ocorreu no bairro de Lagoa Nova, na cidade de Natal, Rio Grande do Norte, nos meses de outubro e dezembro de 2016. As medições foram realizadas entre o *campus* da UFRN e ruas próximas. O clima durante todas as campanhas foi de sol predominante, com céu claro e poucas nuvens. O local apresenta uma densidade regular de vegetação e edifícios de tamanho médio, o que caracteriza o ambiente como suburbano (Figura 2).



Figura 2: Uma das ruas do bairro de Lagoa Nova, com destaque para a antena em painel, utilizada para receber o sinal. Fonte: o autor.

O conjunto de equipamentos utilizados para a transmissão e recepção dos sinais foram: um amplificador de banda larga *Rhode & Schwarz*, modelo *R&SBBA150* (9 kHz - 6 GHz)⁴ e um transmissor de rádio *Anritsu*, modelo *MG3700A* (50 Hz - 6 GHz)⁵. Foram utilizados 15 *watts* de potência para transmitir o sinal, além de dois pares de

⁴ Mais informações sobre o amplificador podem ser encontradas nos apêndices ou em: https://www.rohde-schwarz.com/us/product/bba150-productstartpage_63493-35728.html

⁵ Mais informações sobre o transmissor podem ser encontradas nos apêndices ou em: <https://www.anritsu.com/en-US/test-measurement/products/mg3700a>

antenas diretivas da *Pasternack*: uma antena de painel (2,5 GHz - 2,7 GHz)⁶ com um ganho nominal de 14 dBi foi empregada na frequência de 2600 MHz, enquanto uma antena de painel dupla (806-960MHz e 1710-2500 MHz)⁷ com 7 dBi de ganho nominal foi utilizada nas transmissões de 800 MHz e 1800 MHz.

As mesmas antenas foram utilizadas na recepção de sinais. O sinal transmitido foi uma Onda Contínua (*Continuous Wave - CW*). O transmissor de rádio e o amplificador de banda larga são apresentados na Figura 3.



Figura 3: Transmissor de ondas de rádio e amplificador de banda larga. Fonte: o autor.

Com relação à medição do sinal, foi empregado um analisador de espectro da *Anritsu*, modelo MS2721B⁸ (ilustrado na Figura 4). O analisador também possui um aparelho de GPS (*Global Positioning System*) integrado - responsável por fornecer a localização precisa dos pontos medidos.

A antena utilizada para transmissão foi instalada no telhado do Complexo Tecnológico de Engenharia (CTEC), no campus da UFRN a 20 metros de altura. Um cabo coaxial com baixas perdas foi usado para conectar a antena ao amplificador de banda larga, que por sua vez foi conectado ao transmissor de sinais.

⁶ Mais informações sobre a antena podem ser encontradas nos apêndices ou em: <https://www.pasternack.com/panel-antenna-n-female-2500-2700-mhz-14-dbi-pe51043-p.aspx>

⁷ Mais informações sobre a antena podem ser encontradas nos apêndices ou em: <https://www.pasternack.com/panel-antenna-dual-band-7-dbi-pe51054-p.aspx>

⁸ Mais informações sobre o analisador podem ser encontradas nos apêndices ou em: <https://www.anritsu.com/en-US/test-measurement/products/MS2721B>

Com o objetivo de cobrir os diferentes pontos ao longo do trajeto, foi estabelecido um laboratório móvel - um carro (Figura 5), concedido pela UFRN, devidamente equipado com uma antena receptora instalada no topo do veículo, com uma altura total de 3,6 metros, medida a partir do chão e conectada ao analisador de espectro. O veículo viajou por três rotas diferentes, perto da universidade (Figura 6), com uma velocidade constante de 20 km/h.




Figura 4: Analisador de espectro, utilizado na recepção. Fonte: o autor.



Figura 5: O laboratório móvel, destacando o prédio da CTEC ao fundo. Fonte: o autor.



Figura 6: Rotas cobertas pela campanha. Fonte: Google Maps, 2017.

Após a coleta dos dados experimentais, foi necessário realizar a conversão entre a potência medida para a perda de propagação em si. Esse processo foi executado utilizando a equação (22):

$$PL = P_t + G_t + G_r - L_C + P_m \quad (22)$$

Onde PL é a perda de propagação (*propagation loss*), G_t e G_r são o ganho (*gain*) das antenas transmissora e receptora, respectivamente e L_C é a perda (*loss*) nos cabos. Por fim, P_m representa a potência medida.⁹

⁹ Maiores informações sobre os dados medidos, além dos *datasheets* dos equipamentos e cabos utilizados, estão presentes nos Anexos.

Capítulo 4

Técnicas de Otimização

4.1 Algoritmos Genéticos

Algoritmos genéticos são um ramo, dentro dos Algoritmos Evolucionários (AE)¹⁰, podendo ser definidos como uma técnica de busca baseada em uma metáfora do processo biológico da evolução natural. Os AGs são uma técnica heurística¹¹ de otimização global (LINDEN, 2008).

Esses algoritmos, baseados nos mecanismos de seleção natural e da genética, exploram informações baseadas nos indivíduos da população para encontrar pontos onde são esperados os melhores desempenhos. Esse processo é executado por meio de processos iterativos, em que cada iteração é chamada de geração (SILVA, 2005).

A cada iteração, populações de indivíduos candidatos à solução do problema são submetidos aos operadores genéticos: seleção, cruzamento (*crossover*) e mutação. Por meio da seleção, é determinada a forma e quais indivíduos conseguirão se reproduzir, gerando um certo número de descendentes para a próxima geração, com uma probabilidade determinada pelo seu índice de aptidão (*fitness*).

Desse modo, os indivíduos com maior nível de aptidão têm maiores chances de se reproduzir. Essa população de possíveis soluções para o problema em questão evolui de acordo com operadores genéticos, havendo tendência de que, na média, os indivíduos representem soluções cada vez melhores à medida que o processo evolutivo prossegue (ou seja, ao longo das iterações).

Apesar de o algoritmo genético usar um método heurístico e probabilístico para obter os novos elementos, essa técnica não pode ser considerada uma simples busca aleatória, uma vez que realiza de maneira inteligente a busca por novos indivíduos

¹⁰ Algoritmos Evolucionários são um subconjunto da computação evolutiva. Trata-se de uma metaheurística, um algoritmo genérico de otimização baseada em população. Um AE usa mecanismos inspirados pela evolução biológica, como: reprodução, mutação, recombinação e seleção.

¹¹ Heurística é um método ou processo criado com o objetivo de encontrar possíveis soluções para um determinado problema.

(possíveis soluções) capazes de melhorar ainda mais um critério de desempenho (SILVA, 2005).

Devido ao fato de serem uma metáfora biológica, os AGs utilizam diversos conceitos e terminologias da biologia e genética, além de termos próprios, adequados para o seu contexto. Alguns desses termos são apresentados na Tabela 3.

Tabela 3 – Terminologia dos AGs.

Termo	Significado
Gene	Variáveis de otimização que se apresentam de forma codificada
Cromossomo	Conjunto ordenado de genes que caracteriza um indivíduo. É uma possível solução para o problema
População Inicial	Conjunto de indivíduos criados aleatoriamente utilizados como base para o processo de busca
Gerações	Populações criadas a partir da população inicial e das gerações anteriores através dos operadores genéticos
Funções de <i>Fitness</i>	Função utilizada para calcular a aptidão que um indivíduo tem como solução do problema
Pais	Indivíduos da atual população que foram escolhidos para o processo de cruzamento (<i>crossover</i>)
Filhos	Indivíduos da próxima geração que foram gerados pelo processo de cruzamento (<i>crossover</i>)
Offspring	As novas populações geradas após o processo de seleção, cruzamento e mutação
Elitismo	No elitismo, uma cópia do melhor indivíduo é transferida para a população seguinte

Fonte: Cavalcante, 2010.

O algoritmo do AG é resumido a seguir (LINDEN, 2008), na Figura 7, sendo complementado pelo seu esquema.

- a. Inicialize a população de cromossomos;
- b. Avalie cada cromossomo na população;
- c. Selecione os pais para gerar novos cromossomos;
- d. Aplique os operadores de recombinação e mutação a estes pais de forma a gerar os indivíduos da nova geração;
- e. Apague os velhos membros da população;
- f. Avalie todos os novos cromossomos e insira-os na população;
- g. Se o tempo acabou, ou o melhor cromossomo satisfaz os requerimentos e desempenho, retorne-o, caso contrário, volte para o passo *c*.

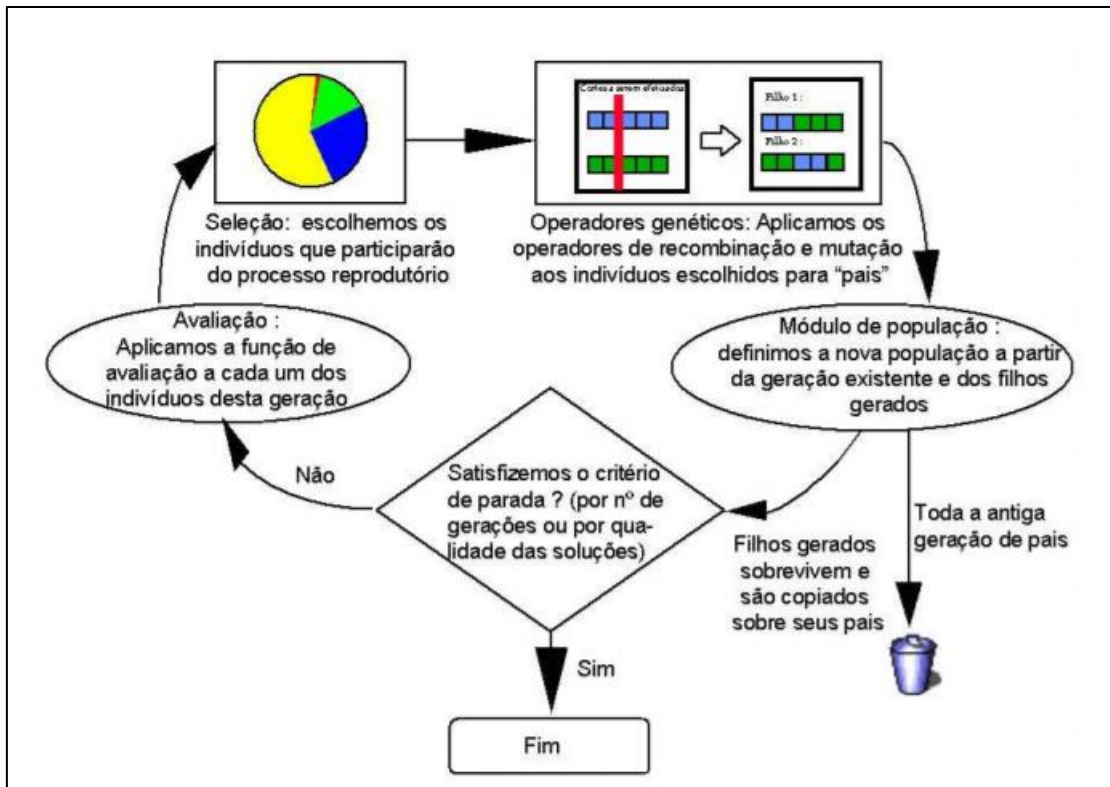


Figura 7: Esquema do algoritmo genético. Fonte: LINDEN, 2008.

4.1.1 Representação Cromossomial

A representação do cromossomo é fundamental para o algoritmo genético. Ela consiste, basicamente, em uma maneira de traduzir a informação do problema em uma maneira viável de ser tratada pelo computador (LIDEN, 2008).

A menor unidade desta representação é chamada de gene, sendo a representação cromossomial completamente arbitrária, ficando sua codificação de acordo com o programador. Contudo, algumas regras devem ser seguidas (LINDEN, 2008):

1. A representação deve ser a mais simples possível;
2. Se houver soluções proibidas ao problema, então elas não devem ter uma representação;
3. Se o problema impuser condições de algum tipo, estas devem estar implícitas dentro nossa representação.

Essa codificação do cromossomo é um fator primordial para o sucesso da técnica. Uma escolha inadequada pode levar a uma convergência mais lenta ou mesmo a uma não convergência do algoritmo genético. Pode-se destacar três tipos de codificações de variáveis utilizadas com mais frequência nos algoritmos genéticos: Codificação Binária, Codificação Gray e a Codificação Real (CAVALCANTE, 2010).

4.1.1.1 Codificação Binária

A representação binária é historicamente importante (GOLDBERG, 1989, apud SILVA, 2005), tendo sido utilizada nos trabalhos pioneiros, como o de HOLLAND, 1975¹². Por esse motivo histórico e por ser de fácil utilização e manipulação, além de ser teoricamente simples de analisar, ainda é a representação mais utilizada.

No entanto, se um problema possui parâmetros contínuos e o implementador desejar trabalhar com maior precisão, provavelmente acabará utilizando longos cromossomos para representar as soluções, gerando uma grande demanda por memória (SILVA, 2005). Na codificação binária, cada cromossomo é uma série de bits, sendo 0 ou 1 (Tabela 4), onde cada bit é um gene.

Tabela 4– Exemplo de codificação binária.

Cromossomo A	[111000111000]
Cromossomo B	[000111000111]

Fonte: o autor.

4.1.1.2 Codificação Real

A representação usando valores reais é mais naturalmente compreendida pelo ser humano, além de requer menos memória que aquela usando uma cadeia de bits. A utilização da codificação real é mais prática, uma vez que se trabalha com variáveis reais por natureza e se usa uma linguagem de programação que lida diretamente com números reais (ÁVILA, 2002, apud CAVALCANTE, 2010).

Considera-se que a a codificação real é mais rápida e eficaz, além de possuir resultados mais consistentes ao longo de varias simulações. Contudo, tal codificação torna os métodos de troca de informações genéticas mais complexas (HAUPT e

¹² John Henry Holland foi um cientista e professor norte-americano, sendo um dos pioneiros na abordagem dos algoritmos genéticos. Destaca-se seu trabalho precursor na área: *Adaptation in Natural and Artificial Systems* (1975).

HAUPT, 2004, apud CAVALCANTE, 2010). Um exemplo de representação real é apresentada na Tabela 5.

Tabela 5 – Exemplo de codificação real.

Cromossomo A	[13 25 7,8 92 194 1,2]
Cromossomo B	[11 45 5,3 12 19 10]

Fonte: o autor.

4.1.1.3 Codificação Gray

Assim como na codificação binária, na codificação Gray¹³ se utilizam apenas cadeias de 0 e 1 para representar as variáveis. A diferença entre elas está na facilidade de operação, que ocorre devido à propriedade de semelhança existente na cadeia codificada que representa números inteiros adjacentes (ÁVILA, 2002). Na codificação Gray, somente um bit é alterado entre dois números sucessivos (Tabela 6).

Com a utilização do código Gray, uma pequena taxa de perturbação ajuda na convergência final dos AGs, enquanto que no binário poderia ampliar a região de exploração. Com isso pode-se verificar que o código Gray favorece a precisão da solução, mas pode levar a um ótimo local. Já o código binário se torna mais “livre” para explorar novas regiões e localizar o ótimo global, mas o refinamento da solução torna-se mais difícil (ÁVILA, 2002, p. 15).

Tabela 6– Comparação entre as codificações decimal, binária e Gray.

Números Decimais	0	1	2	3	4	5	6	7
Codificação Binária	0	1	10	11	100	101	110	111
Codificação Gray	0	1	11	10	110	111	101	100

Fonte: o autor.

¹³ O código de Gray é um sistema de código binário inventado por Frank Gray, um físico e pesquisador do *Bell Labs*. O sistema de codificação Gray surgiu quando os circuitos lógicos digitais se realizavam com válvulas termoiônicas e dispositivos eletromecânicos. Apesar de sua aplicação na eletrônica, é muito utilizado na matemática.

4.1.2 Inicialização

A representação do espaço de busca deve ser a mais sensível possível. Isso leva a algumas ponderações, representadas nos tipos de inicialização (SILVA, 2005):

- Inicialização Aleatória: a população inicial é gerada de forma aleatória;
- Inicialização Determinística: a população inicial é gerada seguindo uma determinada heurística;
- Inicialização Aleatória com nicho: a população inicial é gerada de forma que os indivíduos possam ser divididos em espécies, ou seja, indivíduos com características semelhantes;

Na maior parte dos casos, a população inicial de indivíduos é gerada de maneira aleatória ou por meio de algum processo heurístico (que requer um conhecimento prévio do problema).

Assim como no caso biológico, não existe evolução sem variedade: a teoria da seleção natural acontece em razão dos recursos limitados e organismos com características hereditárias que favoreçam a sobrevivência e a reprodução tendem a deixar mais descendentes do que os demais, o que faz com que essas características aumentem em frequência ao longo das gerações. Desse modo, é importante que a população inicial cubra a maior área possível do espaço de busca (SILVA, 2005).

Deve-se atentar para o escopo dos espaços de busca, uma vez que a população inicial não precisa, necessariamente, ser gerada aleatoriamente dentro de um espaço muito grande. O objetivo é gerar uma população dentro de certo intervalo onde se acredita estar a solução para o problema.

4.1.3 Avaliação

Algoritmos genéticos necessitam de informação do valor de uma função objetivo para cada membro da população, que deve ser um valor não-negativo. Nos casos mais simples, usa-se justamente o valor da função que se quer otimizar. A função objetivo dá, para cada indivíduo, uma medida de quão bem adaptado ao ambiente ele está, ou seja, suas chances de sobreviver no ambiente e reproduzir-se, passando parte do seu material genético a gerações posteriores. (SILVA, 2005, p. 11).

Cada indivíduo da população representa uma possível solução para o problema em questão, sendo necessário avaliar o nível de aptidão de cada um desses indivíduos como solução.

A função de avaliação (ou função de *fitness*) é a maneira utilizada para determinar a aptidão que um indivíduo tem como solução do problema em questão. Ela calcula um valor numérico que reflete o nível de eficiência dos parâmetros representados no cromossomo na resolução do problema (CAVALCANTE, 2010).

Ou seja, a função de *fitness* usa os valores armazenados no cromossomo, retornando um valor numérico, cujo significado é uma métrica da qualidade da solução obtida utilizando aqueles parâmetros (LINDEN, 2008). Uma escolha eficiente da função de *fitness* é primordial na obtenção de um resultado esperado para a solução do problema.

4.1.4 Operadores Genéticos

Os operadores genéticos tem como objetivo modificar a população ao longo das sucessivas gerações, buscando melhorar o nível de aptidão dos indivíduos. Se tratam de métodos probabilísticos baseados na genética e são necessários para manter a diversidade e perpetuar características importantes adquiridas pelas gerações anteriores (CAVALCANTE, 2010).

Como um algoritmo de otimização global, os AGs devem ser capazes de explorar pontos inteiramente novos dentro do espaço de busca, além de intensificar a busca em determinadas regiões consideradas promissoras. Esse mecanismo de diversificação e intensificação é obtido através da correta aplicação dos operadores genéticos (SILVA, 2005).

Na literatura, pode-se encontrar vários tipos de operadores genéticos, sendo boa parte deles, específicos para determinadas codificações e tipos de problemas. Dentre os operadores, pode-se destacar: seleção, cruzamento (*crossover*) e mutação.

4.1.4.1 Seleção

O operador genético da seleção (também chamado de reprodução) seleciona os indivíduos que sofrerão os processos de cruzamento e mutação. Da mesma forma que ocorre no processo de seleção natural, aqueles indivíduos mais qualificados, mais adaptados ao meio, de acordo com a equação de mérito, têm mais chances de serem escolhidos (ÁVILA, 2002).

De acordo com a teoria da evolução de Darwin, os indivíduos mais aptos sobrevivem e se reproduzem, repassando suas heranças genéticas para as gerações posteriores. Dentro do contexto dos algoritmos genéticos, a seleção é um método que escolhe aleatoriamente os indivíduos da população, de acordo com seu valor de *fitness*. Quanto melhor esse valor, mais chance um indivíduo tem de ser selecionado (SIVANANDAM, 2007 apud CAVALCANTE, 2010).

Contudo, a seleção não deve se basear exclusivamente na escolha do indivíduo com maior aptidão, uma vez que há chances deste não estar localizado perto da solução ótima global. Desta forma, deve-se manter alguma probabilidade de que indivíduos com valores de *fitness* mais baixos possam participar do processo de reprodução (ÁVILA, 2002). Dentre os métodos utilizados para fazer a seleção, podemos destacar: Roleta, Torneio e *Ranking*.

No Método da Roleta, cada indivíduo é representado em uma roleta proporcionalmente ao seu índice de aptidão, (calculado pela função de *fitness*). Desse modo, os indivíduos com maior aptidão obtêm uma porção maior na roleta, sobrando para os indivíduos com menor índice de aptidão, as porções menores (ÁVILA, 2002).

Um exemplo com cinco indivíduos é apresentado na Tabela 7, com seus respectivos níveis de *fitness* e os valores percentuais relativos à soma de todos os valores de *fitness* da população, totalizando os 100%. Enquanto isso, a distribuição proporcional de cada indivíduos dentro roleta é mostrada na Figura 8.

Tabela 7 – Representação do método da Roleta.

Indivíduo	Código	Fitness	% População
1	000111	19	34,55
2	110011	5,5	10
3	101010	12	21,82
4	101011	6	10,91
5	111000	12,5	22,7

Fonte: o autor.




Figura 8: Distribuição de cada indivíduo na roleta. Fonte: o autor.

A probabilidade p_i que um indivíduo i tem de ser escolhido em função da sua função de *fitness* $f(i)$ é expressa como (CAVALCANTE, 2010):

$$p_i = \frac{f(i)}{\sum_i f(i)} \quad (23)$$

Como se trata de uma técnica probabilística, tanto indivíduos com nível de *fitness* mais alto quanto com nível mais baixo, tem chances de serem selecionados, proporcionando uma variedade genética às gerações posteriores. Contudo, a utilização desse método de seleção pode causar uma convergência prematura, uma vez que os indivíduos que possuem um nível de *fitness* mais alto em relação à média, poderem dominar o processo de seleção. Este fato poderá causar uma pressão seletiva, diminuindo a diversidade genética das próximas populações (ÁVILA, 2002).

No Método do Torneio, n indivíduos da população são escolhidos de maneira aleatória, com a mesma probabilidade. O indivíduo com maior nível de *fitness* dentre os n indivíduos é selecionado para uma população intermediária. Esse processo é repetido até que a população intermediária seja preenchida (SILVA, 2005). A seleção via Método do Torneio para três indivíduos é apresentada na Figura 9.

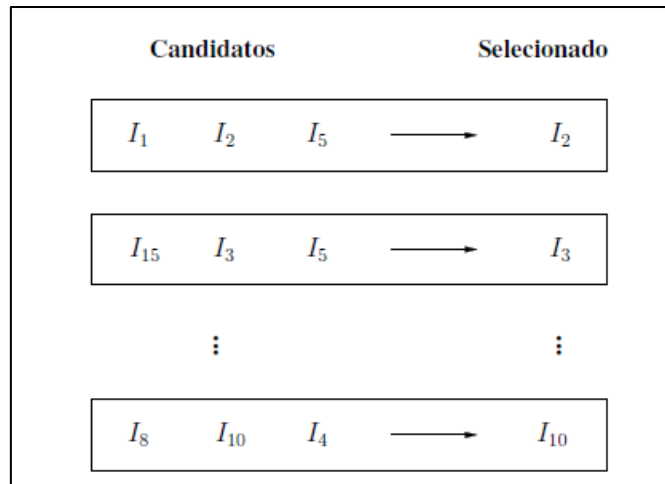


Figura 9: Método do Torneio para $n=3$. Fonte: SILVA, 2005.

Por último, a seleção por *Ranking* é um método que evita a convergência prematura e a dominância de um super indivíduo. Neste caso os indivíduos são ordenados em uma lista, ou seja, são *ranqueados*, de acordo com o valor da função de *fitness*. A posição de cada indivíduo é utilizada como base da seleção, ao invés de se utilizar diretamente o valor de *fitness* (LINDEN, 2008).

Esse método de seleção apresenta algumas vantagens e desvantagens, tais como (CAVALCANTE, 2010):

- Vantagens: redução da pressão seletiva¹⁴ sobre a população no início do processo, uma vez que, nessa fase, geralmente os valores da função de *fitness* dos indivíduos tem um alto nível de desigualdade, tornando a convergência mais lenta; aumento da pressão seletiva sobre a população na fase final do processo, uma vez que, nessa fase, geralmente os valores da função de *fitness* dos indivíduos são, muito próximos um dos outros, deixando o processo de convergência mais rápido;
- Desvantagens: Como desvantagem, pode-se citar o tempo extra gasto no processamento do algoritmo a cada geração, ordenando os indivíduos segundo o valor de *fitness*.

¹⁴ Qualquer conjunto de condições ambientais que causem o favorecimento de determinados genes em relação a outros em uma determinada população.

4.1.4.2 Cruzamento

O cruzamento é um processo sexuado (ou seja, é necessário mais de um indivíduo para que a reprodução aconteça), responsável pela permutação de características entre pares de indivíduos, originando dois filhos. O cruzamento (*crossover*) ocorre após a seleção dos pares de indivíduos (CAVALCANTE, 2010).

Trata-se de um processo aleatório, dependente de uma dada probabilidade P_{CROSS} , cujo valor deve ser especificado pelo implementador. Como este operador genético é o maior responsável pela criação de novos indivíduos, o valor de P_{CROSS} deve ser alto, entre 70 e 100%. Isto é similar ao que ocorre na natureza, onde a maioria dos casais possui filhos (ÁVILA, 2002). Dentre as várias formas de cruzamento, pode-se destacar o cruzamento uniforme e o cruzamento de n pontos.

No cruzamento uniforme, uma cadeia de bits guiará a troca entre os fragmentos de cromossomos. Caso o valor sorteado seja igual a um, o filho número um receberá o gene da posição corrente do primeiro pai, enquanto que o segundo filho receberá o gene corrente do segundo pai. Se o valor sorteado for igual a zero, ocorre o inverso: o primeiro filho recebe o gene da posição corrente do segundo pai, enquanto o segundo filho recebe o gene corrente do primeiro pai (Figura 10).

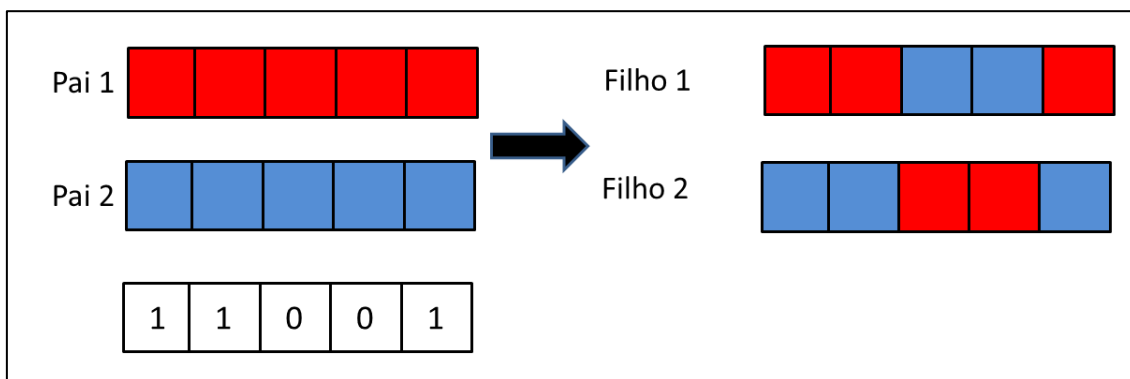


Figura 10: Cruzamento Uniforme. Fonte: o autor.

Outra variação do cruzamento envolve pontos de corte. Após a seleção dos indivíduos que serão pais, pode-se escolher, aleatoriamente, n pontos de corte. Cada ponto de corte constitui uma posição entre genes de um cromossomo. Um cromossomo com n genes possui $n-1$ pontos de corte. No caso do cruzamento com 1 ponto de corte (Figura 11), após a seleção do ponto, cada pai é separado em duas partes: uma à esquerda do ponto de corte e outra à direita.

A formação dos dois novos indivíduos se dará pela concatenação dos materiais genéticos separados dos pais. O primeiro filho gerado é composto pela concatenação da parte esquerda do primeiro pai, com a parte direita do segundo pai. Já segundo filho é composto por meio da concatenação da parte direita do primeiro pai com a parte esquerda do segundo pai (CAVALCANTE, 2010).




Figura 11: Cruzamento com 1 ponto. Fonte: o autor.

4.1.4.3 Mutação

A mutação nada mais é do que a inserção de material genético novo na população. Este processo depende, da mesma forma que o cruzamento, de uma dada probabilidade de mutação (P_{MUT}). O valor dessa probabilidade deve ser bem baixo, em torno de 0 a 5%, para que a busca pelo indivíduo ótimo não seja puramente aleatória. Isto é análogo ao comportamento da natureza, onde mutações ou anormalidades nos indivíduos são mais raras de acontecer (ÁVILA, 2002).

A mutação é um operador genético simples de ser realizado, sendo caracterizado pela alteração aleatória do material genético dos indivíduos. Essa característica é ressaltada na Figura 12.




Figura 12: Operador de mutação. Fonte: o autor.

4.1.5 Aplicação na Otimização de Modelos de Perda de Propagação

Os algoritmos genéticos são amplamente aplicados em vários problemas envolvendo otimização em diversas áreas, incluindo telecomunicações, como pode ser observado em Munyaneza et al. (2008), Cavalcante (2010) e Ávila (2002).

Neste trabalho, o AG padrão (Figura 13), baseado no esquema apresentado na Figura 7, foi aplicado para a otimização dos modelos de perda de propagação. Todo o algoritmo foi desenvolvido pelos autores e nenhuma função de otimização específica do MATLAB® foi usada no código.

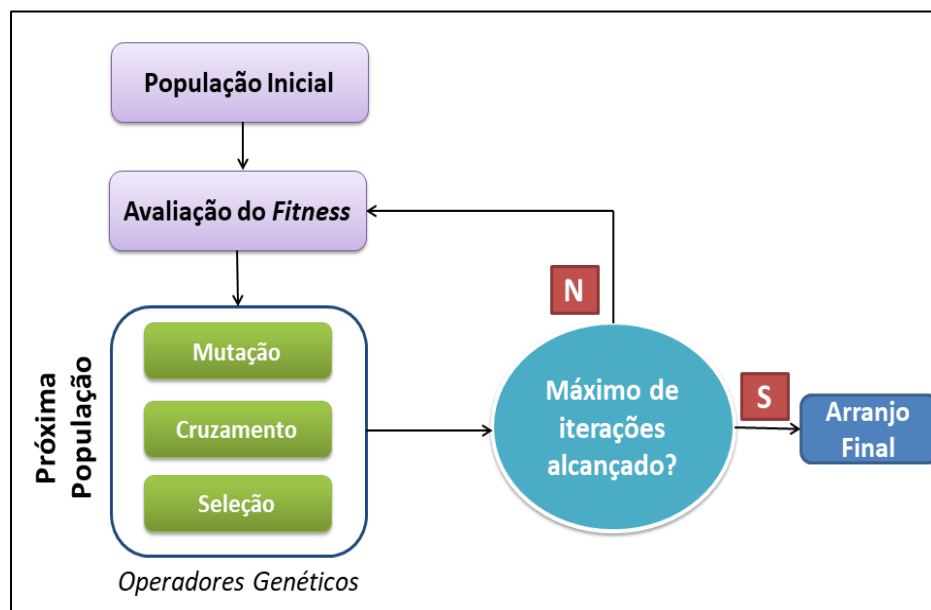


Figura 13: Esquema do AG implementado. Fonte: o autor.

O código é executado ao longo de várias iterações, até que o critério de parada seja atingido, ou seja, o número máximo de gerações ou se o índice de variância mínima for alcançado. A função de *fitness* avalia o quão próximo um indivíduo está da solução do problema. No contexto deste trabalho, é obtido através da diferença entre a perda de propagação medida e simulada:

$$\Delta_{PL} = \frac{1}{N} \sum_{i=1}^N PL_i^{medido} - PL_i^{predito} \quad (24)$$

Uma vez concluído o processo, os indivíduos com os maiores valores de *fitness* formam o conjunto final, contendo os valores das constantes a serem aplicadas nos modelos de propagação, substituindo seus valores padrão. O *offspring* (novas gerações)

possui o mesmo tamanho da população inicial. Os parâmetros da configuração básica do algoritmo genético são apresentados na Tabela 8.

Tabela 8 – Valores dos parâmetros da configuração básica dos AGs.

Parâmetro	Valor
Tamanho da população	10
Codificação do cromossomo	Permuta
Método de seleção	<i>Ranking</i> com elitismo
Tipo de cruzamento	Dois pontos
Taxa de cruzamento	85% a 95%
Taxa de mutação	4% a 6%
Número max. de gerações	25

Fonte: o autor.

Após vários testes, usando tamanhos da população maiores, variando de 20 a 30 indivíduos e aumentando o número máximo de gerações, de 30 a 50 gerações, não foram observadas diferenças relevantes nos resultados, causando apenas um custo computacional extra.

4.2 Método dos Mínimos Quadrados

O método dos mínimos quadrados é o procedimento de estimação dos parâmetros de um modelo de regressão por meio da minimização da soma dos quadrados das diferenças entre os valores observados da variável resposta em uma amostra e seus valores preditos pelo modelo. Possui aplicações em áreas como biologia, engenharia, estatística, física matemática, entre outras, principalmente aquelas que objetivam relacionar uma variável dependente (Y) em função de variáveis explicativas (X_1, \dots, X_k). O método foi proposto independentemente pelos matemáticos Carl Friedrich Gauss por volta de 1795 e Adrien Marie Legendre em torno de 1805 (QUININO et al., p.1, 2013).

A técnica dos mínimos quadrados geralmente mostra resultados satisfatórios quando aplicado a problemas locais de otimização, que é o caso dos modelos de predição de perda de propagação utilizados neste estudo. Vários trabalhos na literatura, como os de Yang e Shi (2008), Pallardó (2008) e Castro et al. (2011), utilizam esse método para ajustar os modelos com base em dados coletados em campanhas de medição.

O princípio básico dos mínimos quadrados é minimizar a soma dos quadrados dos resíduos, sendo um resíduo a diferença entre um valor observado e o valor ajustado fornecido por um modelo. No contexto da predição de perda de propagação, o modelo matemático é dado por:

$$E = \sum_{i=1}^n (PL_{medido_i} - PL_{predito_i})^2 \quad (25)$$

Onde E é a função de erro e n é o número de pontos de dados coletados na campanha de medição. Existem alguns métodos que podem ser utilizados na resolução do problema dos mínimos quadrados (Moon e Wynn, 2000), sendo o método selecionado para este trabalho baseado no algoritmo de *Levenberg-Marquardt* (MARQUARDT, 1963).

Este algoritmo é usado para resolver problemas de ajuste de dados não-lineares dentro do contexto dos mínimos quadrados, o que significa que cada iteração tentará reduzir o erro contra a execução anterior. O critério de parada padrão escolhido para este método se baseia no valor do gradiente da função de erro, o que significa que quando a diferença entre o valor atual e o valor anterior for inferior a 1×10^{-6} , o algoritmo irá parar ou se quando o número máximo de iterações for alcançado, o que para este trabalho foi definido para 1×10^3 iterações.

Esse método é implementado em MATLAB® pela função *lsqcurvefit.m*. O processo de implementação desta função é trivial, consistindo nas entradas PL_{medido_i} e $PL_{predito_i}$, a descrição do modelo de propagação como identificador de função (*function handler*) e valores iniciais arbitrários para iniciar as iterações do algoritmo. Para todas as simulações, os valores iniciais foram ajustados para zero.

A função continuará ajustando os parâmetros até que o tamanho do gradiente seja menor que o valor padrão de tolerância da função do MATLAB®, que é de 1×10^{-6} . Após a conclusão do critério de parada, a função retorna os novos valores de parâmetros encontrados.

Capítulo 5

Redes Neurais Artificiais

O trabalho em redes neurais artificiais [...] tem sido motivado desde o começo pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital convencional. O cérebro é um computador (sistema de processamento de informação) altamente complexo, não-linear e paralelo. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma a realizar certos processamentos, por exemplo, reconhecimento de padrões, percepção e controle motor, muito mais rapidamente que o mais rápido computador digital até hoje existente. (HAYKIN, 2001 p.27).

As Redes Neurais Artificiais (RNAs), são técnicas computacionais que apresentam modelos matemáticos que se assemelham às estruturas neurais biológicas e que possuem capacidade computacional adquirida por meio de aprendizagem e generalização (BRAGA et al., 2000 apud DA SILVA, 2009).

Esses modelos buscam semelhança com o sistema nervoso dos seres vivos e a com sua capacidade de processar informações. Trata-se, enfim, de uma metáfora da maneira como o cérebro humano processa as informações, sendo utilizadas em aplicações na computação.

As redes neurais se assemelham com o cérebro em dois aspectos diferentes (HAYKIN, 2001):

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

O procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem. Sua função é alterar os pesos sinápticos até que um determinado objetivo seja alcançado (SILVA, 2005).

5.1 Propriedades

Diferentes características dotam as redes neurais artificiais da capacidade de resolver problemas complexos, insolucionáveis por meio de abordagens tradicionais. Dentre as principais, podemos destacar (SILVA, 2005):

1. Estrutura paralela: o processamento de uma rede neural artificial é baseado no paralelismo, se assemelhando na forma como o cérebro lida com as informações recebidas pelos neurônios;
2. Habilidade de aprendizagem e generalização: generalização é a capacidade da rede de produzir saídas adequadas para entradas que não estavam no conjunto de treinamento;
3. Não-linearidade: uma rede neural formada por neurônios não lineares permite uma relação não linear entre entradas e saídas;
4. Mapeamento de entrada-saída: a aprendizagem supervisionada (aprendizagem com um “professor”) envolve a modificação dos pesos sinápticos de uma rede neural pela aplicação de um conjunto de amostras de treinamento. Cada exemplo consiste em um sinal de entrada e de uma resposta desejada correspondente. Apresenta-se para a rede um exemplo escolhido ao acaso do conjunto, e os pesos sinápticos são modificados para minimizar a diferença entre a resposta desejada e a resposta real da rede, produzida pelo sinal de entrada, de acordo com um determinado critério estatístico. O treinamento da rede é repetido por muitos exemplos do conjunto até que a rede alcance um estado de estabilidade, onde não haja mais mudanças significativas nos pesos sinápticos. Os exemplos de treinamento previamente aplicados podem ser reaplicados durante a sessão de treinamento, mas em uma ordem diferente. Desse modo, a rede aprende dos exemplos ao construir um mapeamento entrada-saída para aquele problema considerado;
5. Adaptabilidade: as redes neurais possuem uma capacidade inata de adaptar seus pesos sinápticos a modificações em diferentes ambientes.

Uma rede neural treinada para atuar em um ambiente específico pode ser facilmente retreinada para lidar com pequenas modificações nas condições de operação do ambiente;

6. Resposta a evidências: atuando como uma classificadora de padrões, uma RNA pode fornecer em sua saída, não apenas informação relativa a qual conjunto aquela entrada pertence, mas também informação sobre a confiança no resultado. Essas informações podem ser utilizadas para rejeitar padrões ambíguos;
7. Tolerância a falhas: uma vez que o conhecimento é distribuído pela RNA, caso uma parte das conexões se torne inoperante, isso não resultará em mudanças significativas no desempenho de toda a rede.

5.2 Modelo de um Neurônio

O neurônio é a unidade básica de processamento de uma RNA. Sua modelagem possui inspiração no neurônio biológico (Figura 14). É possível destacar as partes que constituem o neurônio do cérebro humano (ORTEGA, 2008):

- Os dendritos são os elementos receptores, ou seja, as entradas do neurônio. Eles conduzem os estímulos captados do ambiente ou mesmo de outras células para a soma;
- O axônio é a linha de transmissão: ele transmite para outras células os impulsos nervosos provenientes da soma;
- As sinapses são as regiões onde as terminações axônicas de dois neurônios se encontram. A comunicação ocorre por meio de neurotransmissores, agentes químicos liberados por um neurônio. A sinapse converte um sinal elétrico pré-sináptico em um sinal químico e em seguida de volta em um sinal elétrico pós-sináptico. A sinapse pode impor ao neurônio receptor a excitação ou inibição;
- A soma ou corpo celular é a parte do neurônio responsável pelo processamento dos sinais de entrada. Caso os valores das entradas atinjam um determinado limiar, o neurônio ‘dispara’, liberando um impulso elétrico que flui da soma para o axônio, que pode estar conectado à entrada de outro neurônio, formando uma sinapse.




Figura 14: O neurônio biológico. Fonte: BORGES, 2015.

A partir do neurônio biológico, foram desenvolvidos modelos para o neurônio artificial, tentando reproduzir suas características. O modelo de um neurônio, conhecido como modelo de McCulloch-Pitts (Figura 15), forma a base para os projetos de redes neurais artificiais (SILVA, 2005).

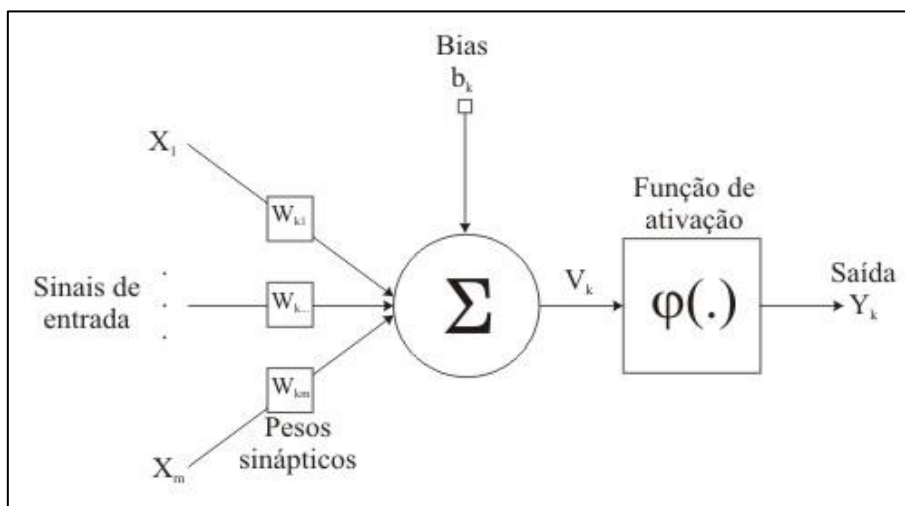


Figura 15: Modelo de um neurônio artificial, segundo McCulloch-Pitts. Fonte: SILVA, 2005.

Tendo como base o modelo de um neurônio, é possível identificar três elementos básicos (HAYKIN, 2001):

1. Um conjunto de sinapses caracterizadas por um peso próprio. Especificamente, um sinal x_j na entrada da sinapse j conectada a um neurônio k será multiplicado pelo peso sináptico w_{kj} . Nesse sentido, o primeiro índice se refere ao neurônio em questão enquanto o segundo se refere ao terminal de entrada da sinapse à qual o peso se refere. Diferentemente de uma sinapse presente no cérebro, o

peso sináptico de um neurônio artificial pode incluir valores negativos ou positivos;

2. Um somador, ou combinador linear, para somar os sinais de entrada, que são ponderados pelas respectivas sinapses do neurônio;
3. Uma função de ativação, que irá associar o sinal resultante do combinador linear (chamado de potencial de ativação), a um determinado valor de saída. Desse modo, a função de ativação irá restringir a amplitude do sinal de saída de um neurônio, a um valor finito. Tipicamente, essa limitação fica entre $[0,1]$ ou $[-1,1]$, por uma questão de normalização do sinal.

O modelo do neurônio artificial também inclui um sinal de bias, que é aplicado paralelamente, sendo representado por b_k . O bias possui o efeito de aumentar ou diminuir a entrada da função de ativação, dependendo se esse valor é negativo ou positivo, respectivamente (HAYKIN, 2001).

Dentro do contexto matemático, é possível descrever um neurônio k utilizando as seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (26)$$

$$y_k = \varphi(u_k + b_k) \quad (27)$$

onde x_1, x_2, \dots, x_m são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; u_k é a saída do combinador linear; b_k é o bias; $\varphi(\cdot)$ é a função de ativação, enquanto y_k é o sinal de saída do neurônio artificial. A utilização do bias tem como objetivo aplicar uma transformação afim à saída u_k do combinador linear:

$$v_k = u_k + b_k \quad (28)$$

Dependendo se o sinal do bias for positivo ou negativo, a relação entre o potencial de ativação v_k do neurônio k e a saída do combinador linear u_k é modificada (Figura 16). É possível notar que, como resultado desta transformação afim, o gráfico de v_k não passa mais pela origem.

Formulando a combinação das Eqs. (26) a (28), obtêm-se:

$$v_k = \sum_{j=0}^m w_{kj} x_j \quad (29)$$

$$y_k = \varphi(v_k) \quad (30)$$

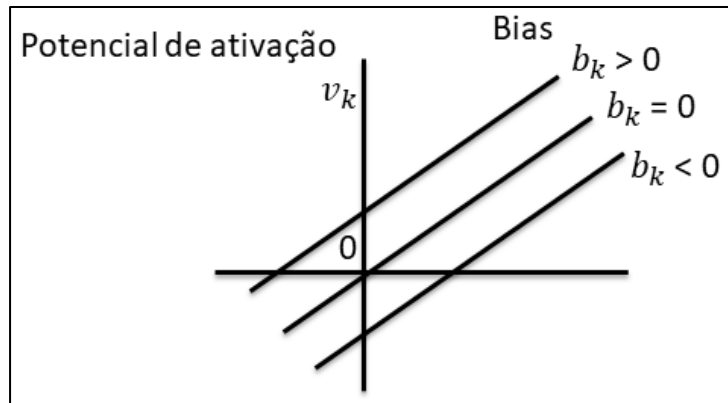


Figura 16: Transformação afim produzida pela presença do bias. Fonte: o autor.

Na Equação (27) é adicionada uma nova sinapse:

$$x_0 = +1 \quad (31)$$

cujo peso é:

$$w_{k0} = b_k \quad (32)$$

É possível então, reformular o modelo do neurônio k (Figura 17), onde o efeito do bias é levado em conta de duas maneiras:

1. Adicionando-se um novo sinal de entrada, fixo em +1;
2. Adicionando-se um novo peso sináptico igual ao bias b_k .

Também vale ressaltar que, embora os modelos das Figuras 15 e 17 sejam aparentemente diferentes, ambos são matematicamente equivalentes (HAYKIN, 2001).




Figura 17: Outro modelo não linear de um neurônio artificial. Fonte: SILVA, 2005.

5.3 Tipos de Função de Ativação

A função de ativação $\varphi(v)$ é responsável por definir a saída de um neurônio em termos do potencial de ativação v . É possível destacar três tipos básicos de função de ativação (HAYKIN, 2001, apud ORTEGA, 2008):

- a) Função de limiar: é utilizada no neurônio de McCulloch & Pitts, limitando a saída do neurônio a apenas dois valores, binário (0 ou 1) ou bipolar (-1 ou 1). Geralmente é utilizada para criar neurônios que tomem decisões binárias, como nos classificadores:

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq 0 \\ 0, & \text{se } v < 0 \end{cases} \quad (33)$$

- b) Função linear por partes:

$$\varphi(v) = \begin{cases} 1, & \text{se } v \geq +\frac{1}{2} \\ v, & \text{se } +\frac{1}{2} > v > -\frac{1}{2} \\ 0, & \text{se } v \leq -\frac{1}{2} \end{cases} \quad (34)$$

- c) Função sigmoide: função que geralmente adotada em redes neurais pelo fato de ser contínua, monotônica, não linear e facilmente diferenciável em qualquer ponto:

$$\varphi(v) = \frac{1}{1+\exp(-av)} \quad (35)$$

Onde a é o parâmetro de inclinação da função. Ao se variar esse parâmetro, é possível obter funções sigmóides com diferentes inclinações.

As funções de ativação definidas anteriormente se estendem de 0 a +1. Contudo, algumas vezes é desejável que a função de ativação seja bipolar, se estendendo de -1 a +1 e assumindo uma forma anti-simétrica em relação á origem. Nesse caso, a função de limiar é definida como:

$$\varphi(v) = \begin{cases} 1, & \text{se } v > 0 \\ 0, & \text{se } v = 0 \\ -1, & \text{se } v < 0 \end{cases} \quad (36)$$

Essa função é denominada função sinal. Para a forma correspondente de uma função sigmoide, é possível utilizar a função tangente hiperbólica:

$$\varphi(v) = \tanh(v) \quad (37)$$

Os gráficos com os comportamentos das funções de ativação abordadas, estão presentes na Figura 18.

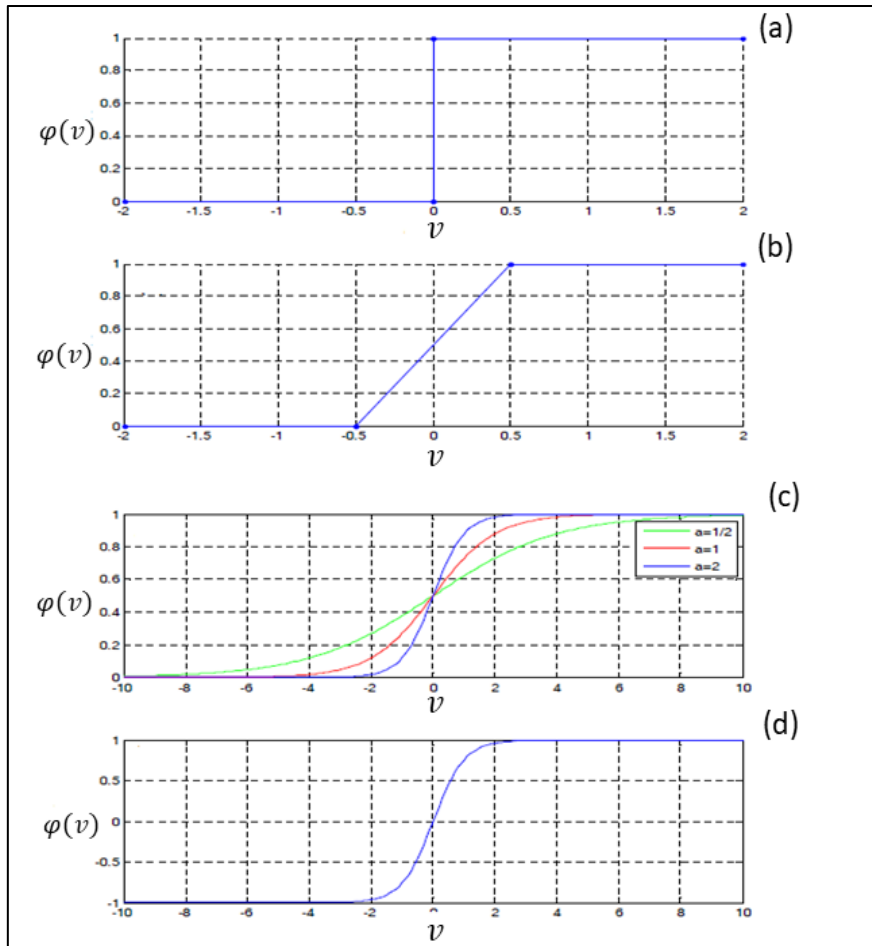


Figura 18: Principais funções de ativação. Fonte: Adaptado de ORTEGA ,2008.

5.4 Arquiteturas de Redes Neurais

A arquitetura das redes neurais é definida pela maneira como os neurônios artificiais podem ser agrupados. É possível identificar três classes, fundamentalmente distintas, de arquiteturas.

5.4.1 Redes *Feedforward* de Camada Única

Conhecidas como *Feedforward Single Layer Perceptron*¹⁵. Trata-se de uma variação mais simples das redes neurais organizadas em várias camadas, onde, nesse caso, os neurônios se organizam em uma única camada (HAYKIN, 2001). A rede é composta de uma camada de entrada de dados, seguida de uma única camada de processamento, que irá calcular e fornecer as saídas (Figura 19). A saída de cada um dos neurônios constitui uma saída da rede.

A rede é sempre alimentada adiante, uma vez que a camada de nós fonte fornece os sinais de entrada para a camada de saída e não o contrário, ou seja: não há laços de realimentação (ORTEGA, 2008). O termo camada única se refere ao fato de existir apenas uma camada de nós computacionais: a camada de saída, uma vez que a camada de entrada não é considerada, pois não realiza nenhum tipo de processamento.




Figura 19: Rede *Feedforward* de camada única. Fonte: ORTEGA, 2008.

5.4.2 Redes *Feedforward* de Múltiplas Camadas

Conhecidas como *Feedforward Multi Layer Perceptron*. Essa classe de redes neurais se caracteriza pela presença de uma ou mais camadas de nós computacionais entre as camadas de entrada e saída, conhecidas como camadas ocultas ou neurônios ocultos (ORTEGA, 2008) (Figura 20).

¹⁵ O perceptron é a forma mais simples de uma rede neural artificial, usado para classificar padrões linearmente separáveis. Consiste de um único neurônio com pesos sinápticos e bias ajustáveis.

O perceptron é capaz de resolver apenas problemas linearmente separáveis, podendo classificar as entradas em dois grupos diferentes. Já as redes com múltiplas camadas são capazes de gerar mais valores.

Nesse tipo de arquitetura, os nós de fonte da camada de entrada fornecem os sinais de entrada aos neurônios da primeira camada oculta. As saídas provenientes desses nós serão usadas como entradas dos neurônios da próxima camada, e assim por diante até o final da rede. O conjunto de sinais de saída dos neurônios da última camada constituem a resposta global da rede (HAYKIN, 2001).




Figura 20: Rede *Feedforward* de múltiplas camadas. Fonte: ORTEGA, 2008.

Ao se adicionar uma ou mais camadas ocultas, a rede se torna capaz de extrair estatísticas de ordem elevada, adquirindo uma perspectiva global, apesar de sua conectividade local, devido ao conjunto extra de conexões sinápticas e também da dimensão extra de interações neurais. Essa habilidade dos neurônios ocultos de extrair características de ordem elevada é particularmente valiosa em casos onde o tamanho da camada de entrada é grande.

5.4.3 Redes Recorrentes

As RNAs do tipo recorrente se diferem das redes alimentadas adiante pelo fato de possuírem pelo menos um laço de realimentação. Os laços de realimentação causam um impacto profundo na capacidade de aprendizagem da rede neural e, conseqüentemente, em seu desempenho.

Esses laços de realimentação envolvem o uso de ramos particulares, que são compostos de elementos de atraso unitário, resultando em um comportamento dinâmico não-linear (se admitindo que a rede contenha unidades não-lineares). Esse tipo de rede, contendo um neurônio oculto (destacado em cor cinza) e dois neurônios de saída, é apresentado na Figura 21.




Figura 21: Redes Recorrentes. Fonte: ORTEGA, 2008.

5.5 Paradigmas de Aprendizagem

A propriedade mais importante das redes neurais é a habilidade de aprender acerca de seu ambiente e, com isso, melhorar o seu desempenho. Isto pode ser feito através de um processo iterativo de ajustes aplicados aos pesos sinápticos da rede, chamado de treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma determinada classe de problemas. Todos os modelos de redes neurais possuem uma regra de treinamento, onde os pesos de suas conexões sinápticas são ajustados de acordo com os padrões apresentados, ou seja, a rede aprende através de exemplos provenientes de casos reais conhecidos (ORTEGA, 2008, p.59).

Os paradigmas de aprendizagem, ou treinamento, podem ser classificados em duas categorias: aprendizagem supervisionada e não-supervisionada.

5.5.1 Aprendizagem Supervisionada

Este paradigma de aprendizagem também é conhecido como aprendizagem com um professor. O estado do ambiente é representado por um vetor que é aplicado à entrada de ambos: a rede neural e o professor. O professor possui conhecimento sobre aquele ambiente, representado por um conjunto de exemplos de entrada-saída, fornecendo assim, a resposta desejada (ORTEGA, 2008).

O sinal de saída da RNA é comparado com a resposta desejada, gerando um sinal de erro. Esse erro é utilizado no ajuste dos pesos sinápticos da rede produzindo na saída uma resposta tão próxima quanto possível da desejada. Este processo é repetido para cada exemplo de treinamento até que a rede neural consiga emular o professor. Após o término do processo, o conhecimento do professor foi transferido para os pesos sinápticos da rede neural, e este não é mais necessário.

Existem vários algoritmos supervisionados que podem ser utilizados para o treinamento da rede, como *Regra de Hebb* e *Máquina de Boltzman*. Contudo, o mais utilizado no treinamento das redes perceptron de múltiplas camadas é o algoritmo da *Retropropagação do Erro*, ou *Backpropagation*.

O procedimento da retropropagação do erro é resumido em duas fases: a primeira ocorre quando as entradas são apresentadas à rede, sendo, em seguida, propagadas adiante, até que seja computado um valor de saída. Esse valor é comparado com a saída desejada e o erro resultante da diferença entre esses dois valores é calculado. Na segunda fase, o erro é propagado na direção contrária da entrada (para trás), tendo como objetivo a alteração dos pesos sinápticos, tendo como base o erro retropropagado. Após o término dessas duas fases é que são apresentadas novas entradas (SILVA, 2005).

5.5.2 Aprendizagem Não-Supervisionada

Nesse tipo de aprendizagem, não há um professor responsável pelo fornecimento da resposta desejada, ou seja: não existem exemplos da função a ser aprendida pela rede, sendo utilizados apenas os valores de entrada. Neste caso, a rede utiliza os neurônios como classificadores, e as entradas como elementos a serem classificados,

por meio de um processo de competição e cooperação entre os neurônios da rede. Um exemplo de RNA deste tipo são os Mapas Auto - Organizáveis de Kohonen (ORTEGA, 2008).

5.6 Redes Neurais Empregadas na Predição de Perda de Propagação

A abordagem utilizando redes neurais artificiais presentes nesse trabalho, utiliza dois métodos distintos:

1. Um modelo com duas entradas distintas: uma contendo as distâncias entre transmissor e receptor, e outra com a diferença entre dados experimentais e valores preditos pelos modelos, tendo como inspiração as abordagens de Popescu et al. (2002) e Sanches e Cavalcante (2004). A saída é representada pelos valores coletados nas medições.
2. Um modelo com quatro entradas, baseadas em características do terreno e do *set up* de medições: distâncias do transmissor ao receptor, altitude do receptor e nível médio do terreno. O nó de saída é a perda de propagação medida.

Ambas as abordagens estão dentro do paradigma de aprendizagem supervisionada, onde o professor é representado pelos dados coletados em medições. No caso da RNBT, a perda de propagação medida atua como professor, guiando a rede no ajuste dos pesos sinápticos no processo de mapeamento de entradas e saídas.

5.6.1 Rede Neural com entrada Baseada em Erro

A entrada da rede é composta por dois vetores:

- Distância entre transmissor e receptor;
- Erro entre os valores medidos e os calculados pelos modelos:

$$E = PL_{medido} - PL_{preditado} \quad (38)$$

O vetor de saída, também conhecido como alvo da rede neural, compreende a perda de propagação medida. A fase de treinamento da estrutura da rede neural é representada na Figura 22, enquanto a arquitetura da rede está presente na Figura 23.

A RNA implementada é do tipo perceptron de múltiplas camadas. Sua arquitetura consiste em 2 entradas e 1 saída, com uma camada oculta. O conjunto de entrada consiste em dois vetores, referentes a valores coletados ao longo de três rotas para cada frequência: conta com 560 elementos para o cenário de 800 MHz, 357 no caso de 1800 MHz e 519 valores na frequência de 2600 MHz.

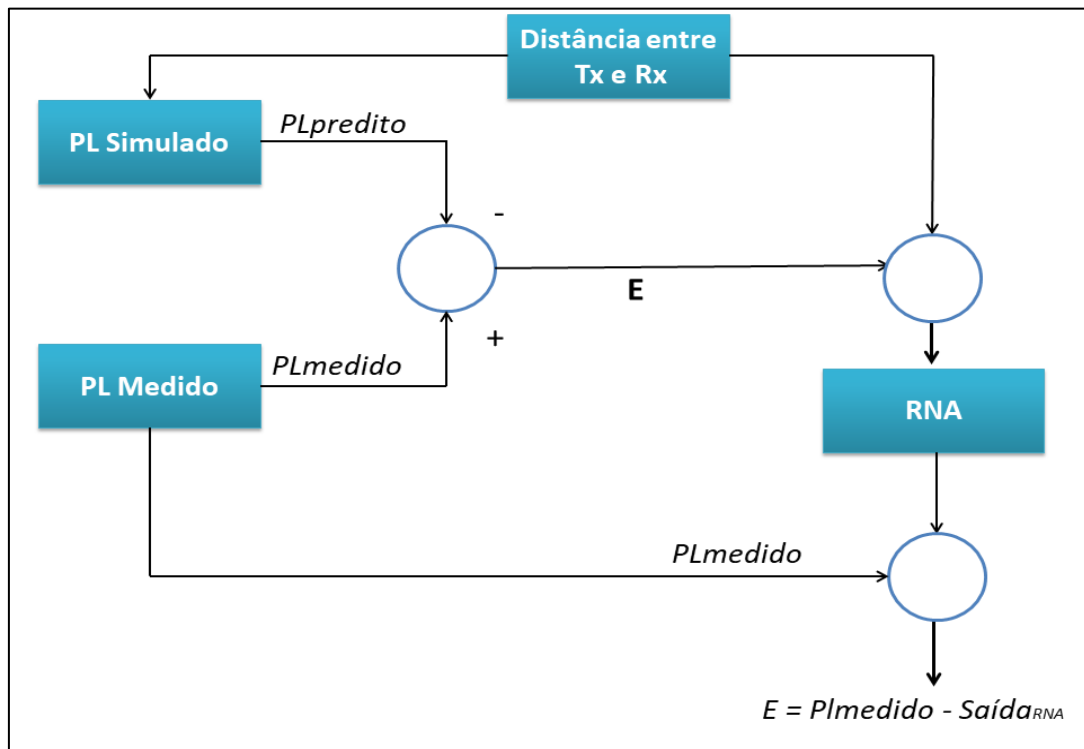


Figura 22: Fluxograma do processo de treinamento. Fonte: o autor.

As funções de transferência utilizadas para camadas ocultas e de saída foram tangente sigmóides e linear, respectivamente, enquanto o algoritmo escolhido para treinar a rede foi o *Levenberg-Marquardt*.

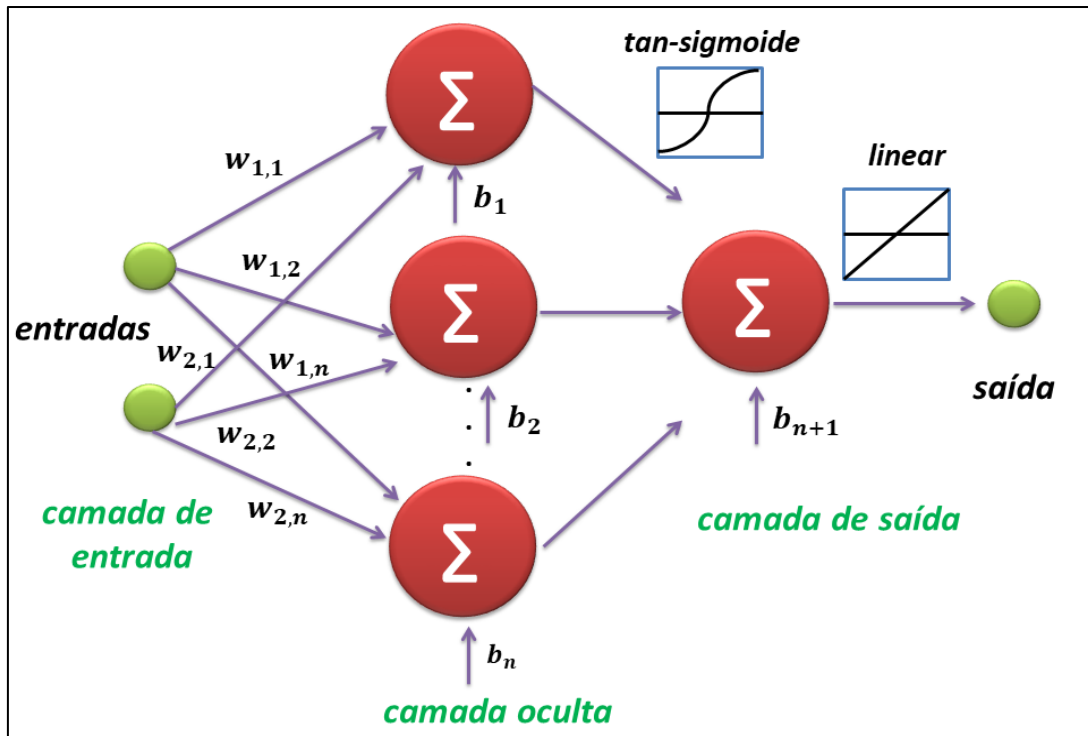


Figura 23: Arquitetura da RNA implementada. Fonte: o autor.

Buscando evitar o sobre-ajuste (*overfitting*)¹⁶ e fazer com que a rede adquira a propriedade de generalização, os dados foram divididos em três conjuntos (Tabela 9): o primeiro foi usado no treinamento da rede para ajuste de pesos. O segundo conjunto, usado como um conjunto de validação, verifica a eficiência em relação à capacidade de generalização da rede, servindo também como um critério de parada (usando uma estratégia de validação cruzada¹⁷). Por fim, o terceiro conjunto, definido como conjunto de testes, fornece uma estimativa realista do desempenho da rede usando dados novos.

Tabela 9–Parâmetros básicos da RNBE.

Parâmetro	Valor
Taxa de treinamento	60%
Taxa de validação	25%
Taxa de teste	15%
Número máximo de épocas	1000

Fonte: o autor.

¹⁶ Um modelo sobre-ajustado apresenta alta precisão quando testado com seu conjunto de dados, porém não é uma boa representação da realidade.

¹⁷ Técnica que avalia a capacidade de generalização de um modelo, a partir de um conjunto de dados, sendo amplamente empregada em problemas onde o objetivo da modelagem é a predição. Busca-se então estimar o quão preciso é este modelo na prática (seu desempenho para um novo conjunto de dados). O conceito central é o particionamento do conjunto de dados em subconjuntos mutuamente exclusivos, e posteriormente, utiliza-se alguns destes subconjuntos para a estimação dos parâmetros do modelo (dados de treinamento) e o restante dos subconjuntos (dados de validação ou de teste) são empregados na validação do modelo.

5.6.2 Rede Neural com Entradas Baseadas no Terreno

Seu modelo possui a mesma arquitetura apresentada na Figura 23. As funções de transferência utilizadas para camadas ocultas e de saída novamente foram tangente sigmóides e linear, respectivamente, enquanto o algoritmo de treinamento permaneceu o *Levenberg-Marquardt*. A principal diferença é com relação às entradas. O modelo RNBT possui 4 entradas diferentes, com características do terreno e do *set up* de propagação (referentes às três rotas):

- Distâncias entre Tx e Rx;
- Altitude do receptor;
- Nível médio do terreno (origem e destino);
- Azimute entre Tx e Rx.

Com relação à saída desejada da rede, ela é representada pelas perdas de propagação medidas para cada uma das frequências consideradas. Por fim, a divisão de dados segue a mesma proporção presente no modelo da RNBE, apresentado na Tabela 9.

Ambos os métodos (RNBE e RNBT) foram implementados usando o MATLAB®. Dentre as várias funções utilizadas, se destacam: função *fitnet.m* para a criação da rede e função *train.m* para o seu treinamento

Capítulo 6

Análise de Resultados

A campanha de medições consistiu na transmissão de um sinal de onda contínua, ao longo de três diferentes rotas, no bairro de Lagoa Nova, próximo ao campus da UFRN, em três frequências diferentes: 800 MHz, 1800 MHz e 2600 MHz. Um fator importante que indica a taxa a qual a perda de percurso diminui com a distância é o expoente de perda de percurso, γ .

Esse valor geralmente varia entre 2 e 4 (WEINSTOCK, 2006). O valor $\gamma = 2$ seria um ambiente no espaço livre (visada direta, sem obstruções), enquanto $\gamma=4$ representa um ambiente com grandes perdas. A Tabela 10 apresenta os valores de perda de percurso para cada rota e frequência.

Tabela 10 – Expoentes de Perda de Percurso.

Rota	Frequência	γ
1	800 MHz	2,4
	1800 MHz	2,5
	2600 MHz	2,9
2	800 MHz	2,4
	1800 MHz	3,4
	2600 MHz	3,1
3	800 MHz	2,3
	1800 MHz	2,7
	2600 MHz	2,8

Fonte: o autor.

6.1 Técnicas de Otimização

Com relação aos métodos de otimização, a avaliação foi obtida ajustando os valores do conjunto de constantes padrão dos modelos. Ambas as técnicas (algoritmos genéticos e método dos mínimos quadrados) ajustaram termos relativos à distância e frequência, na maioria dos casos, nas equações.

Para tal, a diferença entre os valores preditos na simulação e os medidos é calculada para diferentes combinações de valores das constantes. As equações originais são apresentadas na Tabela 11. Já as equações modificadas, referentes às três faixas,

são destacadas nas Tabelas 12,13 e 14. Os valores alterados estão destacados em negrito.

Com relação aos algoritmos genéticos, para não correr o risco de o resultado cair num mínimo local, tomou-se o cuidado de restringir a faixa abrangida a valores não muito distantes dos termos originais das equações.

Tabela 11 –Versões Originais das Equações

Modelo	Equação Original
Free Space	$PL_{FSPL} = \mathbf{32,45} + \mathbf{20} \log(d) + \mathbf{20} \log(f)$
3GPP TR 36,942	$PL_{TR} = \mathbf{40}[1 - 0,004h_{Tx}] \log_{10}(d) - \mathbf{18} \log_{10}(h_{Tx}) + \mathbf{21} \log_{10}(f) + \mathbf{80}$
Ericsson	$PL_E = \mathbf{36,2} + \mathbf{30,2} \log_{10}(d) + \mathbf{12} \log_{10} h_b + \mathbf{0,1} \log_{10} h_b \log_{10}(d) - 3,2(\log_{10} 11,75 h_r)^2 + g(f)$
SUI	$\gamma = \mathbf{4} - \mathbf{0,0065} h_b + \frac{\mathbf{17,1}}{h_{Tx}}$
	$s = 0,65[\log_{10}(f)]^2 - 1,3 + \log_{10}(f) + \mathbf{5,2}$
ECC	$A_{bm} = 20,41 + \mathbf{9,83} \log_{10}(d) + \mathbf{7,894} \log_{10}(f) + \mathbf{9,56} [\log_{10}(f)]^2$
	$G_r = [42,47 + \mathbf{13,7} \log_{10}(f) \log_{10}(f)] [\log_{10}(h_{RX}) - 0,585]$

Fonte: o autor.

Vale ressaltar, com relação ao modelo SUI, que a versão otimizada foi referente aos terrenos tipos A e B, apresentados na equação (5). Com relação ao modelo ECC, a versão submetida à otimização foi aquela que cobre cidades médias, referente à equação (12).

Tabela 12–Equações Modificadas para 800 MHz

Modelo	Equação Modificada (AG)	Equação Modificada (LMS)
Free Space	$PL_{FSPL} = 67,4 - 17,6 \log(d) + 35,78 \log(f)$	$PL_{FSPL} = 0,94 + 2,75 \log(d) + 38,17 \log(f)$
3GPP TR 36,942	$PL_{TR} = 38,73[1 - 0,004h_{Tx}] \log_{10}(d) - 8,77 \log_{10}(h_{Tx}) + 32,73 \log_{10}(f) + 38,46$	$PL_{TR} = 40,57[1 - 0,004h_{Tx}] \log_{10}(d) + 13,39 \log_{10}(h_{Tx}) + 33,18 \log_{10}(f) + 11,43$
Ericsson	$PL_E = 43,1 + 43,46 \log_{10}(d) - 0,21 \log_{10} h_b - 7,1 \log_{10} h_b \log_{10}(d) - 3,2(\log_{10} 11,75 h_r)^2 + g(f)$	$PL_E = 16,1 + 14,3 \log_{10}(d) + 20,86 \log_{10} h_b + 18,51 \log_{10} h_b \log_{10}(d) - 3,2(\log_{10} 11,75 h_r)^2 + g(f)$

Fonte: o autor.

Tabela 13 - Equações Modificadas para 1800 MHz

Modelo	Equação Modificada (AG)	Equação Modificada (LMS)
3GPP TR 36,942	$PL_{TR} = 35,3[1 - 0,004h_{Tx}] \log_{10}(d) - 41,8 \log_{10}(h_{Tx}) + 45,72 \log_{10}(f) + 39,54$	$PL_{TR} = 43,63[1 - 0,004h_{Tx}] \log_{10}(d) + 12,64 \log_{10}(h_{Tx}) + 35,1 \log_{10}(f) + 10,8$
Ericsson	$PL_E = 49,03 + 40,97 \log_{10}(d) + 4,08 \log_{10} h_b - 4,32 \log_{10} h_b \log_{10}(d) - 3,2(\log_{10} 11,75 h_r)^2 + g(f)$	$PL_E = 20,18 + 15,32 \log_{10}(d) + 26,18 \log_{10} h_b - 19,85 \log_{10} h_b \log_{10}(d) - 3,2(\log_{10} 11,75 h_r)^2 + g(f)$
SUI	$\gamma = 24,78 - 1,01 h_b - \frac{1,22}{h_{Tx}}$	$\gamma = 0,29 + 0,19 h_b + \frac{0,21}{h_{Tx}}$
	$s = 0,65[\log_{10}(f)]^2 - 1,3 + \log_{10}(f) + 12,01$	$s = 0,65[\log_{10}(f)]^2 - 1,3 + \log_{10}(f) + 16,97$
ECC	$A_{bm} = 20,41 + 18,12 \log_{10}(d) + 24,18 \log_{10}(f) + 11,25[\log_{10}(f)]^2$	$A_{bm} = 20,41 + 24 \log_{10}(d) + 25 \log_{10}(f) + 6,3[\log_{10}(f)]^2$
	$G_r = [42,47 + 31,1 \log_{10}(f) \log_{10}(f)] [\log_{10}(h_{RX}) - 0,585]$	$G_r = [42,47 + 0,9 \log_{10}(f) \log_{10}(f)] [\log_{10}(h_{RX}) - 0,585]$

Fonte: o autor.

Tabela 14 - Equações Modificadas para 2600 MHz

Modelo	Equação Modificada (AG)	Equação Modificada (LMS)
3GPP TR 36,942	$PL_{TR} = 49,38[1 - 0,004h_{Tx}]log_{10}(d) + 31,06log_{10}(h_{Tx}) + 43,6log_{10}(f) - 38,65$	$PL_{TR} = 50,84[1 - 0,004h_{Tx}]log_{10}(d) + 12,14log_{10}(h_{Tx}) + 35,61log_{10}(f) - 10,38$
Ericsson	$PL_E = 44,82 + 36,92log_{10}(d) + 10,84log_{10}h_b + 6,44log_{10}h_b log_{10}(d) - 3,2(log_{10}11,75 h_r)^2 + g(f)$	$PL_E = 21,8 + 17,82log_{10}(d) + 28,28log_{10}h_b + 23,14log_{10}h_b log_{10}(d) - 3,2(log_{10}11,75 h_r)^2 + g(f)$
SUI	$\gamma = 31,23 - 1,32 h_b + \frac{0,81}{h_{Tx}}$	$\gamma = 0,5 + 0,22h_b - \frac{0,53}{h_{Tx}}$
	$s = 0,65[log_{10}(f)]^2 - 1,3 + log_{10}(f) + 5,89$	$s = 0,65[log_{10}(f)]^2 - 1,3 + log_{10}(f) + 6,57$
ECC	$A_{bm} = 20,41 + 30,1log_{10}(d) + 19,63log_{10}(f) + 17,03[log_{10}(f)]^2$	$A_{bm} = 20,41 + 30,56log_{10}(d) + 20,29log_{10}(f) + 8,41[log_{10}(f)]^2$
	$G_r = [42,47 - 25,51log_{10}(f)log_{10}(f)] [log_{10}(h_{RX}) - 0,585]$	$G_r = [42,47 + 0,89log_{10}(f)log_{10}(f)] [log_{10}(h_{RX}) - 0,585]$

Fonte: o autor.

6.2 Modelos de Rede Neural RNBE e RNBT

O Erro Quadrático Médio (EQM, do inglês, *Mean Square Error* - MSE) foi usado como parâmetro de desempenho pelo algoritmo para avaliar a taxa de convergência. Um gráfico de progresso de desempenho em relação às curvas de cada conjunto para o modelo ECC a 2600 MHz é apresentado na Figura 24.

Não há indícios de problemas importantes com o processo, uma vez que as curvas de treinamento, validação e teste são muito semelhantes. Se a curva de teste tivesse aumentado antes da curva de validação, isso indicaria um problema de sobreajuste (OSTLIN et al., 2004).




Figura 24: Uma das execuções com os parâmetros de treinamento, validação e teste. Fonte: o autor.

A rede foi projetada com uma única camada oculta. Para encontrar a configuração ideal, foi realizado um teste de convergência, com base em um procedimento de tentativa e erro, para selecionar o número apropriado de nós ocultos para cada cenário. O MSE relativo ao modelo com entrada baseada em erro, para diferentes números de nós ocultos com 5, 10, 20, 30 e 40 neurônios foi comparado. Cada caso foi executado 20 vezes, com o objetivo de obter os valores médios.

O valor do MSE para o conjunto de validação em relação ao número de nós ocultos para cada modelo de propagação aplicado está representado nas Tabelas 15, 16 e 17, para 800 MHz 1800 MHz e 2600 MHz, respectivamente. Os melhores valores estão marcados em negrito, enquanto os piores resultados são apresentados em itálico.

Tabela 15 –MSE do arranjo de dados de validação em relação ao número de neurônios na camada oculta para 800 MHz.

Camadas Ocultas	Ericsson	Espaço Livre	TR 36.942
5	<i>1,79E-05</i>	<i>1,54E-06</i>	6,29E-06
10	1,70E-06	6,67E-07	7,68E-07
20	1,91E-06	3,62E-08	1,92E-06
30	3,94E-06	1,87E-07	2,74E-07
40	1,73E-05	8,31E-07	<i>6,60E-05</i>

Fonte: o autor.

Tabela 16 –MSE do arranjo de dados de validação em relação ao número de neurônios na camada oculta para 1800 MHz.

Camadas Ocultas	Ericsson	ECC-33	TR 36.942	SUI
5	7,40E-06	1,79E-07	1,95E-06	<i>1,79E-05</i>
10	2,00E-06	5,44E-08	5,61E-07	1,29E-06

20	1,57E-06	1,20E-07	1,12E-07	5,61E-07
30	3,69E-06	1,19E-06	2,08E-06	4,42E-07
40	0,0027	1,52E-06	3,54E-05	1,08E-05

Fonte: o autor.

Tabela 17 - MSE do arranjo de dados de validação em relação ao número de neurônios na camada oculta para 2600 MHz.

Camadas Ocultas	Ericsson	ECC-33	TR 36.942	SUI
5	1,26E-05	6,78E-08	1,72E-06	4,03E-06
10	1,17E-06	1,06E-07	5,12E-07	1,30E-06
20	1,91E-06	4,23E-08	1,57E-07	3,51E-07
30	6,23E-07	5,19E-08	3,63E-06	4,38E-07
40	7,15E-07	1,22E-07	1,12E-06	9,62E-07

Fonte: o autor.

Para a melhor configuração obtida para cada modelo, calculamos o RMSE alcançado no procedimento, computando esses valores e executando a rede neural novamente, mais 30 vezes (50 no total) e calculamos o valor do RMSE. O melhor resultado obtido é aplicado. Os resultados são apresentados a seguir.

Um procedimento de tentativa e erro também foi conduzido para encontrar uma configuração eficiente para a RNBT. Levando em consideração as frequências de 800 MHz, 1800 MHz e 2600 MHz, respectivamente. O modelo Ericsson obteve melhores resultados com 30, 20 e 20 neurônios; o modelo TR 36.942 apresentou maior eficiência com 30, 30 e 40 neurônios. Com relação ao modelo SUI, este obteve melhores índices, para as três frequências, com 30 neurônios. Nas mesmas faixas, o modelo ECC-33 alcançou melhores resultados com 20 neurônios. Por fim, o modelo do Espaço Livre, para 800 MHz, atingiu menores valores de MSE ao utilizar 20 neurônios na camada oculta.

É possível concluir que os melhores resultados foram obtidos utilizando configurações com 20 e 30 neurônios, na maioria das vezes. Redes neurais com mais neurônios na camada oculta convergiam mais rapidamente, mas na maior parte dos casos, apresentavam resultados inferiores.

6.3 Resultados

O desempenho de cada uma das técnicas foi avaliado comparando o RMSE e aplicando o teste de *Wilcoxon rank-sum*. Plotagens em um diagrama de caixa compara os conjuntos de dados obtidos por cada abordagem em relação aos dados coletados das

medições. Os cenários de simulação foram realizados para as frequências de 800 MHz, 1800 MHz e 2600 MHz.

A diferença de desempenho entre os métodos avaliados, considerando todos os modelos, em relação aos resultados do teste RMSE e *Wilcoxon*, estão enfatizados na Tabela 18. Os valores apresentados correspondem à média das três rotas.¹⁸ O valor de *p* determina o nível de significância estatística no experimento. Valores de *p* maiores indicam que a distribuição de dados é mais semelhante aos valores medidos; o limite para que um resultado seja considerado nulo é qualquer valor abaixo de 1×10^{-6} . A coluna de significância expressa, com base no valor de *p*, se o modelo é considerado exato e estatisticamente equivalente a dados reais. Se o valor de *p* for inferior a 0,05, o método é considerado Significativamente Diferente (S.D); caso contrário, é classificado como Significativamente Equivalente (S.E).

Tabela 18– RMSE e valor de *p* para todas as técnicas em 800 MHz.

Modelo	RMSE	Teste W. Ranksum	Signif.@95%
Ericsson	14,94	nulo	S.D
LMS Ericsson	7,84	0,6	S.E
AG Ericsson	7,88	0,64	S.E
RNBE Ericsson	$8,1 \times 10^{-4}$	0,98	S.E
TR 36.942	8,62	$2,47 \times 10^{-4}$	S.D
LMS TR 36.942	7,84	0,6	S.E
AG TR 36.942	7,85	0,61	S.E
RNBE TR 36.942	$3,3 \times 10^{-4}$	0,99	S.E
Espaço Livre	30,85	nulo	S.D
LMS Espaço Livre	7,84	0,6	S.E
AG Espaço Livre	7,87	0,55	S.E
RNBE Espaço Livre	$2,4 \times 10^{-4}$	0,93	S.E
RNBT	5,01	0,72	S.E

Fonte: o autor.

Resultados correspondentes à frequência de 800 MHz são apresentados nas Figuras 25, 26 e 27. São apresentados valores referentes às curvas de perdas em relação aos modelos Espaço Livre, TR 36.942 e Ericsson, relativos às rotas 1, 2 e 3,

¹⁸ As tabelas com os resultados por rota estão disponíveis nos Anexos.

respectivamente. Em todos os cenários, ambos os modelos baseados em RNAs e ambas as técnicas de otimização apresentaram regularidade em seu desempenho.




Figura 25: Curvas de perda de propagação em relação ao modelo do Espaço Livre, rota 1, em 800 MHz. Fonte: o autor.




Figura 26: Resultados em relação ao modelo TR 36.942 em 800 MHz na rota 2. Fonte: o autor.




Figura 27: Perda de propagação em relação ao modelo Ericsson em 800 MHz na rota 3. Fonte: o autor.

Os modelos de propagação obtiveram um desempenho bem inferior, se mostrando a técnica menos eficiente. O modelo do Espaço Livre permaneceu longe dos pontos medidos ao longo de toda a rota 1, com um valor de RMSE de 31,27 dB. Já o TR 36.942, na rota 2, mostrou-se como a exceção: se manteve perto dos dados experimentais, juntamente com as curvas obtidas pelo AG e LMS, ao longo de todo o trajeto. Isso se reflete em seu RMSE de 7,75 dB. Por fim, a performance do modelo Ericsson na rota 3, pode ser considerado mediana: a curva só cruza com os dados medidos no início da rota, até os 700 metros, voltando a se aproximar novamente apenas no final. O valor de RMSE computado nesse cenário foi de 14,28 dB.

Em relação aos métodos de otimização, eles alcançaram resultados próximos aos valores medidos, mantendo uma curva suave ao lado dos dados experimentais, melhorando o desempenho dos modelos de perda de propagação. Tanto a AG quanto o LMS apresentaram desempenho praticamente equivalente para os três cenários. Isso se reflete no RMSE obtido: o AG apresentou 7,68 dB, 7,37dB e 8,46 dB, enquanto o método LMS obteve 7,77 dB, 7,28 dB e 8,46 dB nas rotas 1, 2 e 3, respectivamente.

O modelo RNBT exibiu um desempenho confiável, seguindo os dados experimentais durante todo o curso de medições, em todos os cenários. Isso se reflete no RMSE: o método atingiu 4,69 dB, 5,51 dB e 4,81 dB para os casos apresentados nas Figuras 25, 26 e 27, respectivamente.

Contudo, a técnica que atingiu os melhores resultados foi a rede RNBE, uma vez que as marcas da rede neural foram praticamente iguais aos dados experimentais. O valor de RMSE obtido pela rede foi próximo de 0 dB para todos os cenários.

O diagrama de caixa (ou *boxplot*), apresentado na Figura 28, é um gráfico utilizado para avaliar a distribuição do dados. O *boxplot* é formado por quatro quartis, além da mediana. O primeiro quartil representa 25% das menores medidas, enquanto a caixa que abriga o segundo e terceiro quartis, representam 50% do total das medidas, estando 25% das maiores medidas, representados pelo quarto quartil. Já a mediana representa o valor do meio, o centro que divide a distribuição de dados em duas partes iguais. Caso uma medida ultrapasse o limite superior ou inferior, é chamado de valor discrepante (*outlier*).

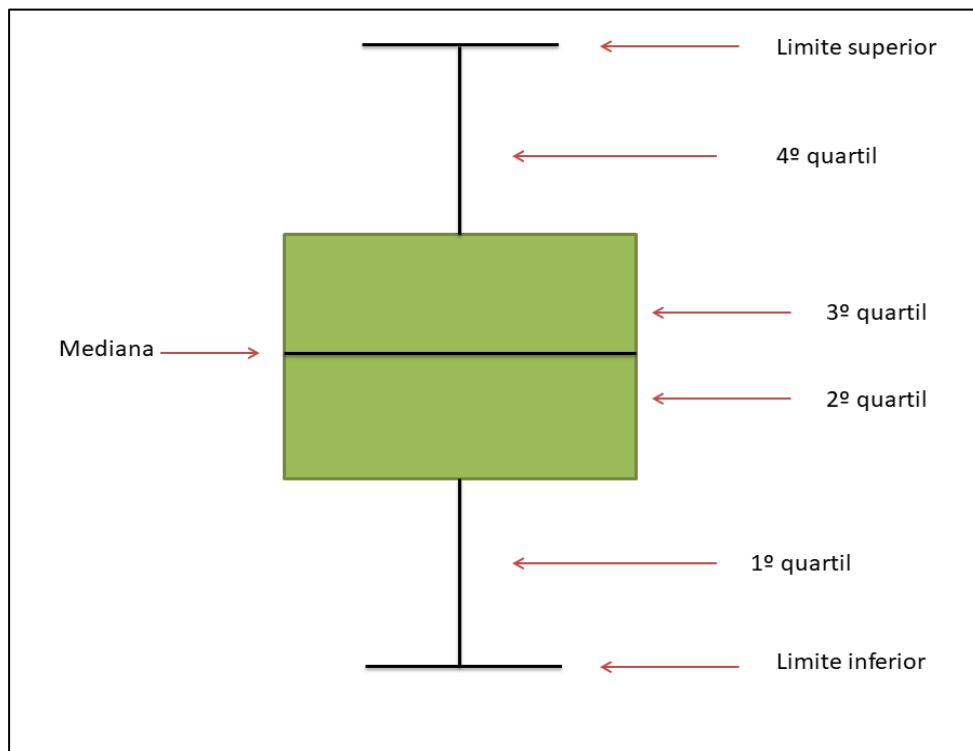


Figura 28:Elementos do diagrama de caixa. Fonte: o autor.

No diagrama de caixa, apresentado na Figura 29, estão os cinco conjuntos de dados do cenário presente na Figura 25. Nota-se que a distribuição de dados do modelo Espaço Livre ocupou a parte superior da faixa das medições, alinhando-se apenas parcialmente com a faixa dos dados experimentais, indicando valores mais elevados de perda de propagação previstos; isso se reflete no valor de p do modelo Espaço Livre, considerado nulo por ter ficado abaixo de 1×10^{-6} .

Com relação aos métodos de otimização, neste cenário, eles praticamente se alinharam à faixa interquartil, apresentando alta similaridade entre valores medidos e otimizados. No entanto, eles obtiveram uma menor fidelidade na distribuição de dados, uma vez que o intervalo GA e LMS ocupa apenas parcialmente o espaço de dados medidos. Já os valores das medianas (representados pela linha vermelha) se mostram bastante próximos. A técnica do LMS obteve um valor de p de 0,8093 enquanto o AG conseguiu 0,7919, indicando um alto nível de similaridade com os valores medidos.

Em relação ao modelo RNBT, embora levemente mais achatado, quase corresponde ao intervalo interquartil, apresentando alta similaridade com os dados medidos. No entanto, obteve uma menor fidelidade na distribuição de dados, uma vez que sua extensão ocupa apenas parte do espaço de amostragem de dados medidos (seu valor obtido de p foi 0,88). A rede neural RNBE corrigiu esses problemas, obtendo uma distribuição de dados tão próxima quanto pode chegar aos valores medidos, alcançando um valor de p igual a 0,94.




Figura 29: Diagrama de caixa para os resultados do modelo Espaço Livre na rota 1 em 800 MHz. Fonte: o autor.

Os resultados das diferentes técnicas utilizadas, em termos de RMSE e em seu valor de p para 1800 MHz (média para as três rotas) são apresentados na Tabela 19.

Tabela 19 – RMSE e valor de p para todas as técnicas em 1800 MHz.

Modelo	RMSE	Teste W. Ranksum	Signif.@95%
Ericsson	10,2	0,16	S.E
LMS Ericsson	8,58	0,45	S.E
AG Ericsson	8,75	0,11	S.E
RNBE Ericsson	$4,65 \times 10^{-4}$	0,99	S.E
TR 36.942	14,31	nulo	S.D
LMS TR 36.942	8,58	0,3	S.E
AG TR 36.942	8,77	0,24	S.E
RNBE TR 36.942	$1,77 \times 10^{-4}$	0,99	S.E
ECC	9,31	0,22	S.E
LMS ECC	8,58	0,3	S.E
AG ECC	8,74	0,1	S.E
RNBE ECC	$1,76 \times 10^{-4}$	0,99	S.E
SUI	9,5	0,23	S.E
LMS SUI	8,57	0,36	S.E
AG SUI	8,75	0,15	S.E
RNBE SUI	$8,16 \times 10^{-5}$	0,98	S.E
RNBT	4,95	0,95	S.E

Fonte: o autor.

Foram destacados três resultados, apresentados nas Figuras 30, 31 e 32. São apresentados valores das curvas de perdas referentes aos modelos TR 36.942, SUI e ECC, correspondentes às rotas 1, 2 e 3, respectivamente. Assim como nos cenários apresentados anteriormente, os modelos baseados em RNAs e ambas as técnicas de otimização produziram um padrão bem definido em termos de performance.

Os modelos de propagação repetiram o desempenho apresentado anteriormente, sendo a técnica com resultados mais pessimistas. O TR 36.942 permaneceu próximo aos pontos medidos apenas até os 600 metros, apresentando proximidade novamente apenas no final do curso de medições. Seu desempenho pode ser considerado mediano, com um valor de RMSE de 14 dB. Por sua vez, o modelo SUI, na rota 2, obteve uma

performance mais regular, permanecendo próximo das curvas correspondentes aos modelos otimizados.. Seu valor de RMSE foi de 10 dB. Já o ECC, na rota 3, conseguiu uma boa performance: apesar da grande dispersão de dados presente nesse cenário, o modelo obteve uma performance bastante regular, parecida com as dos modelos otimizados. Seu valor de RMSE foi de 9,16 dB.




Figura 30: Curvas das perdas em relação ao modelo TR 36.942 para a rota 1 em 1800 MHz. Fonte: o autor.




Figura 31: Perdas de propagação em relação ao modelo SUI, 1800 MHz na rota 2. Fonte: o autor.

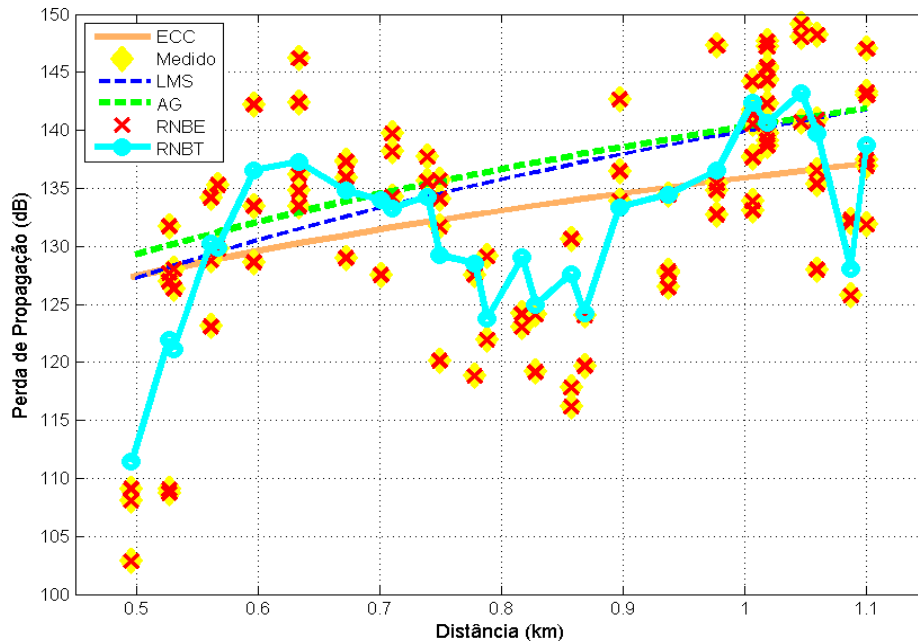


Figura 32: Perdas em relação ao modelo ECC para 1800 MHz na rota 3. Fonte: o autor.

As técnicas de otimização obtiveram resultados regulares. Contudo, foram pouco eficientes nos cenários das rotas 2 e 3, uma vez que pouco puderam fazer para melhorar o desempenho (otimista) apresentado pelos modelos de perda de propagação. Isso é bastante visível no cenário da rota 3, onde a otimização, em termos de RMSE foi de menos de 1 dB. Com relação aos valores de RMSE obtidos, para o algoritmo genético foram computados os valores: 8,74 dB, 7,69 dB e 9,08 dB, enquanto o método LMS atingiu 8,76 dB, 8,25 dB e 8,81 dB nas rotas 1, 2 e 3, respectivamente.

Apesar de a técnica da rede neural com entradas baseadas no terreno e no *set up* de medições obter, novamente, um desempenho muito acima da média, seguindo de perto os dados experimentais durante todo o curso de medições, em todos os cenários (RMSE: 4,57 dB; 4,65 dB e 5,61 dB), o modelo da rede neural com entradas baseada em erro foi, mais uma vez, o método com a melhor performance, com marcas virtualmente idênticas aos dados experimentais, com um valor de RMSE próximo aos 0 dB em todos os casos.

O diagrama de caixa apresentado na Figura 33, traz os cinco conjuntos de dados do cenário presente na Figura 31. Observa-se uma distribuição de dados mais homogênea, com um destaque negativo do modelo SUI, que ocupa apenas parcialmente com a faixa dos dados experimentais, indicando valores menores de perda de propagação previstos; seu valor de p foi considerado nulo por ser inferior a 1×10^{-6} .

As técnicas de otimização se encaixaram parcialmente na faixa interquartil e na distribuição geral dos dados, apresentando baixa similaridade entre valores medidos e otimizados, com os valores da média distantes do obtido pelos dados experimentais. Essa baixa similaridade se reflete no valor de p : o LMS obteve um valor de p de $1,61 \times 10^{-5}$ enquanto o AG alcançou apenas $2,59 \times 10^{-4}$.

O modelo RNBT corresponde virtualmente ao intervalo interquartil dos dados medidos, mas apresenta uma distribuição de dados levemente inferior. Seu valor de p foi de 0,89. Já o modelo RNBE, além de obter uma distribuição de dados praticamente equivalente dos dados experimentais, reproduziu fielmente os *outliers* (representados pelas cruces vermelhas), alcançando um valor de p de 0,99.

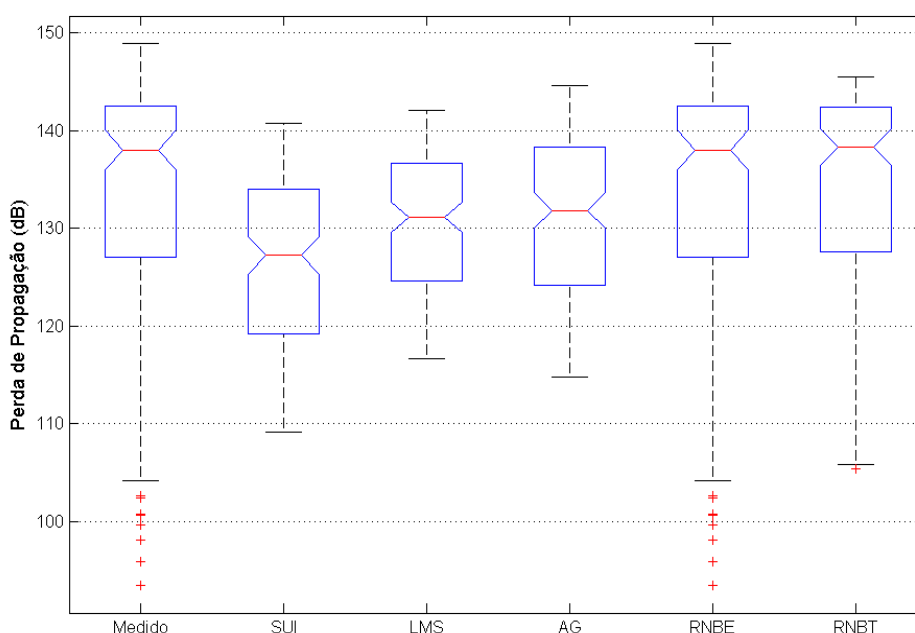


Figura 33: Diagrama de caixa para os resultados do modelo SUI, 1800 MHz na rota 2. Fonte: o autor.

Por fim, os valores obtidos pelas diferentes técnicas, (valores médios para as rotas 1, 2 e 3) na frequência de 2600 MHz são apresentados na Tabela 20.

Tabela 20 – RMSE e valor de p para todas as técnicas em 2600 MHz.

Modelo	RMSE	Teste W. Ranksum	Signif.@95%
Ericsson	10,55	0,11	S.E
LMS Ericsson	9,33	0,21	S.E
AG Ericsson	9,4	0,29	S.E

RNBE Ericsson	$8,26 \times 10^{-5}$	0,99	S.E
TR 36.942	16,28	nulo	S.E
LMS TR 36.942	9,4	0,21	S.E
AG TR 36.942	9,4	0,29	S.E
RNBE TR 36.942	$1,62 \times 10^{-4}$	0,98	S.E
ECC	10,3	0,19	S.E
LMS ECC	9,38	0,18	S.E
AG ECC	9,42	0,21	S.E
RNBE ECC	$5,74 \times 10^{-5}$	0,99	S.E
SUI	10,45	0,15	S.E
LMS SUI	10,25	0,018	S.E
AG SUI	9,92	0,33	S.E
RNBE SUI	$5,25 \times 10^{-4}$	0,99	S.E
RNBT	5,26	0,87	S.E

Fonte: o autor.

Para a frequência de 2600 MHz, destacam-se três casos (Figuras 34, 35 e 36). São apresentados valores referentes às curvas de perdas em relação aos modelos SUI (rota 1), Ericsson (rota 2) e ECC-33 (rota 3). Nestes cenários, vale destacar a pouca eficácia dos métodos de otimização em relação aos modelos de perda de propagação (que, por si só, apresentaram bons resultados).

No primeiro cenário (Figura 34), o modelo SUI obteve um RMSE de 8,52 dB, deixando pouco espaço para a otimização das técnicas do LMS (8,39 dB) e AG (8,26 dB). Essa tendência se repetiu, em menor intensidade, no cenário seguinte (Figura 35): o modelo Ericsson obteve um RMSE de 10,04 dB, enquanto as otimizações obtiveram 8,06 dB (no caso do LMS) e 7,85 dB (algoritmo genético). Por fim, no terceiro cenário, tanto o modelo ECC (Figura 36), quanto as otimizações alcançaram valores de RMSE na faixa dos 11 dB, tendo a otimização um efeito mínimo. Já os modelos baseados em redes neurais, mais uma vez, tiveram a melhor performance. O destaque pertence novamente ao modelo RNH, que apresentou valores limítrofes a zero.




Figura 34: Curvas das perdas de propagação em relação ao modelo SUI, rota 1, em 2600 MHz.
Fonte: o autor.




Figura 35: Perdas em relação ao modelo Ericsson em 2600 MHz na rota 2. **Fonte:** o autor.

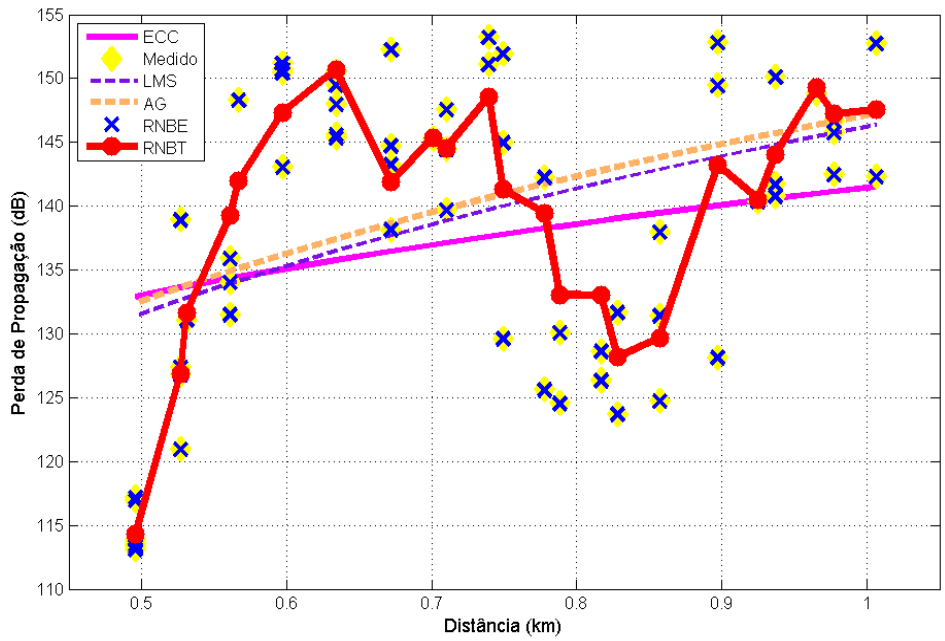


Figura 36: Curvas das perdas em relação ao modelo ECC, 2600 MHz na rota 3. Fonte: o autor.

O diagrama de caixa (Figura 37) traz os cinco conjuntos de dados do caso apresentado na Figura 36. É possível observar uma pequena distribuição de dados do modelo ECC, caracterizando sua performance de caráter mais linear. Apesar disso, seu valor de p foi de 0,12, classificando os dados como significativamente equivalentes. Os valores do ECC contrastam com os dados experimentais, que apresentam uma alta taxa de dispersão.




Figura 37 : Diagrama de caixa para os resultados do modelo ECC em 2600 MHz, rota 3. Fonte: o autor.

Com relação às técnicas de LMS e AG, apesar da otimização pobre em termos de RMSE, conseguiram aproximar a distribuição dos dados do ECC com os valores medidos. Os valores de p atingidos foram de 0,55 e 0,63 pelas técnicas do LMS e AG, respectivamente.

Os modelos baseados em RNA reproduziram mais fielmente a distribuição dos dados experimentais, principalmente as distâncias interquartis. Nesse contexto, o destaque pertence mais uma vez ao modelo RNBE, com exata similaridade com os dados medidos, com um valor de p igual a 1. Já o modelo simples obteve um valor de p de 0,91.

Ao analisar todos os resultados, é possível tecer algumas considerações:

- Ambas as redes neurais foram capazes de diminuir os valores de RMSE enquanto aumentavam o valor de p , diminuindo bastante a diferença entre valores simulados e medidos (no caso da RNBE, valores de RMSE se apresentaram limítrofes a zero). Isso demonstra a habilidade da rede neural em aprender e naturalmente incorporar valores incertos e não-determinísticos presentes nos dados experimentais;
- Com relação às técnicas de otimização, o AG e LMS conseguiram, na maioria dos casos, aproximar os resultados dos modelos de propagação dos dados medidos, aumentando a precisão das previsões, principalmente em casos onde os modelos tiveram uma performance ruim;
- Ambas as técnicas de otimização apresentaram uma performance bastante similar, valendo a pena recomendar a técnica do LMS para a otimização devido à sua implementação de menor complexidade e com menos esforço computacional;
- Em vários casos, nos cenários de 1800 MHz e 2600 MHz, os métodos de otimização obtiveram valores de p menores que 0,05. Isso é explicado pelo fato de, principalmente nas rotas 2 e 3, existir uma dispersão maior dos dados medidos, com muitos *outliers*;
- Com relação aos modelos de perda de propagação, com base nos resultados, recomenda-se utilizar: modelo TR 36.942 para 800 MHz, modelo ECC para 1800 MHz e os modelos SUI e ECC para 2600 MHz, pois estes modelos apresentaram um valor de erro menor, além de uma maior similaridade com os dados medidos;

- A técnica mais eficiente, que obteve valores de RMSE próximos a zero e obteve valores de p limítrofes a 1, sendo recomendada para a predição de perda de propagação em ambientes dentro dos cenários analisados, foi a rede neural RNBE.

Capítulo 7

Considerações Finais

As redes de telefonia móvel 3G e 4G, representadas pelas tecnologias LTE e LTE-A, buscam preencher as demandas criadas por um novo modelo de comunicação, onde os usuários estão sempre conectados a serviços *on line*, exigindo uma melhor cobertura e conexões com maior largura de banda. A importância das tecnologias móveis na prestação desses serviços se torna ainda maior em locais carentes de acesso à redes *Wi Fi*.

Buscando trazer uma maior eficiência e dinamismo na elaboração de projetos de sistemas de comunicação sem fio, muito esforço é investido na implementação de técnicas de simulação de previsão de cobertura que tenham a capacidade de estimar com precisão os dados medidos.

Nesse contexto, esse trabalho realizou uma análise dos principais modelos de propagação, desenvolvendo e aplicando dois métodos baseados em RNAs: um modelo com entrada baseada em erro (RNBE), utilizando modelos empíricos de propagação (e o modelo do Espaço Livre) e um modelo com entradas baseadas no terreno (RNBT), baseado em dados do terreno/propagação, em áreas suburbanas para sistemas LTE e LTE-A, tendo como base os trabalhos de Popescu et al. (2002) e Sanches e Cavalcante (2004).

Os dois métodos são comparados com os modelos empíricos SUI, ECC, TR 36.942, Ericsson e o modelo determinístico do Espaço Livre, além das técnicas de otimização dos mínimos quadrados e algoritmos genéticos. As frequências de interesse foram: 800 MHz, 1800 MHz e 2600 MHz. Dados experimentais foram coletados por meio de uma campanha de medições realizada no bairro de Lagoa Nova, perto do campus da UFRN.

Buscando evitar o sobre-ajuste (*overfitting*) e melhorar a capacidade de generalização, uma estratégia de validação cruzada junto com um conjunto de testes foi realizada na execução dos modelos de rede neural. Esta estratégia permite que a rede

seja capaz de prever a perda de propagação em diferentes ambientes, embora em circunstâncias semelhantes.

Os resultados obtidos pela RNBE foram comparados com os alcançados por modelos de propagação, as duas técnicas de otimização e a rede neural simples. O modelo com entrada baseada em erro provou ser bem mais preciso do que os outros métodos nos cenários testados, apresentando os índices de RMSE mais baixos e valores de p mais altos.

O uso de métodos de predição através da simulação na fase de planejamento dos sistemas de comunicação pode aumentar significativamente a eficiência e a precisão em diversos ambientes de implantação de sistemas de comunicação sem fio, representando também a economia de tempo e dinheiro.

Portanto, essa técnica é uma ferramenta útil para projetistas de redes LTE e LTE-A, provando ser um método de predição de perda de propagação eficaz e preciso, pois exibiu dados de simulação próximos das medidas de campo reais. Para trabalhos futuros, sugere-se expandir o escopo do estudo, cobrindo novos tipos de ambientes, frequências de operação e modelos de propagação, além de outras técnicas de análise.

Referências Bibliográficas

AGUIAR, F. G. **Utilização de redes neurais artificiais para detecção de padrões de vazamento em dutos**. 2010. 95 f. Dissertação (Mestrado em Térmica e Fluidos) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2010.

AHMAD, Y. A.; HASSAN, W. A.; RAHMAN, T. A. Studying different propagation models for LTE-A system. In: **Computer and Communication Engineering (ICCCE), 2012 International Conference on**. IEEE, p. 848-853, 2012.

AHMED, M. H. A. Performance test of 4G (LTE) networks in Saudi Arabia. In: **Technological Advances in Electrical, Electronics and Computer Engineering (TAECE), 2013 International Conference on**. IEEE, p. 28-33, 2013.

ALAM, D. ; KHAN, R. H. Comparative study of path loss models of WiMAX at 2.5 GHz frequency band. **International Journal of Future Generation Communication and Networking**, v. 6, n. 2, p. 11-23, 2013.

ANGELES, J. C. D.; DADIOS, E. P. Neural network-based path loss prediction for digital TV macrocells. In: **Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM), 2015 International Conference on**. IEEE, 2015. p. 1-9.

AVILA, S. L. **Algoritmos Genéticos Aplicados na Otimização de Antenas Refletores Florianópolis**, 2002. 84f. Dissertação de Mestrado. Mestrado em Engenharia Elétrica - Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2002.

BASU, A.; BANERJEE, P.; SEN, S. Optimization of RF Propagation Models for Cognitive Radio. **International Research Journal of Engineering and Technology (IRJET)** e-ISSN: 2395 -0056, v. 3, ed. 10, 2016.

BORGES, R. R. et al. Sincronização de disparos em redes neuronais com plasticidade sináptica. **Caderno Brasileiro de Ensino de Física**, v. 37, n. 2, 2015.

BRAGA, A. de P.; CARVALHO, A.C.P.L.F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. 2ed. São Paulo: LTC Editora, 2000. 228p.

CASTRO, B. S. L et al. Comparison between known propagation models using least squares tuning algorithm on 5.8 GHz in Amazon region cities. **Journal of Microwaves, Optoelectronics and Electromagnetic Applications**, v. 10, n. 1, p. 106-113, 2011.

CAVALCANTE, G. A. **Otimização de modelos de predição da perda de propagação aplicáveis em 3, 5GHZ utilizando algoritmos genéticos**. 2010. 75 f. Dissertação (Mestrado em Automação e Sistemas; Engenharia de Computação; Telecomunicações) - Universidade Federal do Rio Grande do Norte, Natal, 2010.

CHAN, W. et al. Listen, attend and spell: A neural network for large vocabulary conversational speech recognition. In: **Acoustics, Speech and Signal Processing (ICASSP), 2016 IEEE International Conference on**. IEEE, p. 4960-4964, 2016.

DA SILVA, A. M. **Utilização de redes neurais artificiais para classificação de spam**. 2009. Dissertação (Mestrado em Modelagem Matemática E Computacional) - Centro Federal de Educação Tecnológica de Minas Gerais, Belo Horizonte, 2009.

ELECTRONIC COMMUNICATION COMMITTEE (ECC) WITHIN THE EUROPEAN CONFERENCE OF POSTAL AND TELECOMMUNICATIONS ADMINISTRATIONS (CEPT). **The Analysis of the Coexistence of FWA Cells in the 3.4-3.8 GHz Band**, Relatório técnico, Vilamoura, 2006.

ELNASHAR, A.; EL-SAIDNY, M. A.; SHERIF, M. **Design, deployment and performance of 4G-LTE networks: A practical approach**. John Wiley & Sons, 2014.

ERAS, L. E. C. et al. **Modelo de propagação de campo elétrico para TV digital em percursos mistos do tipo cidade-rio na região Amazônica**. 2016. 83 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Pará, Instituto de Tecnologia, Belém. 2016.

ERCEG, V. et al. An empirically based path loss model for wireless channels in suburban environments. **IEEE Journal on selected areas in communications**, v. 17, n. 7, p. 1205-1211, 1999.

GOLDBERG, D. E.; HOLLAND, J. H. Genetic algorithms and machine learning. **Machine learning**, v. 3, n. 2, p. 95-99, 1988.

HAUPT, R. L.; HAUPT, S. E. **Practical genetic algorithms**. New Jersey: John Wiley & Sons, 2004.

HAYKIN, S. **Redes Neurais: Princípios e práticas**. Tradução de Paulo Martins Engel, v. 2, p. 27-32, Porto Alegre: Bookman, 2001.

JADHAV, A. N.; KALE, S. S. Suburban Area Path loss Propagation Prediction and Optimization Using Hata Model at 2375 MHz. **International Journal of Advanced Research in Computer and Communication Engineering**, v. 3, n. 1, p. 5004-5008, 2014.

LI, W. et al. Deepreid: Deep filter pairing neural network for person re-identification. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**, p. 152-159, 2014.

LINDEN, R. **Algoritmos genéticos**. 2 ed. São Paulo: Brasport, 2008. 428p.

MAHESH, B. C.; RAO, B. P. Design and Modeling of Propagation Models for WiMAX Communication System at 3.7 GHz & 4.2 GHz. **IPASJ International Journal of Electronics & Communication (IJEC)**, v. 2, n. 1, 2014.

MARQUARDT, D. W. An algorithm for least-squares estimation of nonlinear parameters. **Journal of the society for Industrial and Applied Mathematics**, v. 11, n. 2, p. 431-441, 1963.

MILANOVIC, J.; RIMAC-DRLJE, S.; BEJUK, K. Comparison of propagation models accuracy for WiMAX on 3.5 GHz. In: **Electronics, Circuits and Systems, 2007. ICECS 2007. 14th IEEE International Conference on**. IEEE, p. 111-114. 2007.

MOON, T. K. S.; WYNN, C. **Mathematical methods and algorithms for signal processing**. New Jersey: Prentice Hall, 2000.

MUNYANEZA, J.; KURIEN, A.; VAN WYK, B. Optimization of antenna placement in 3G networks using genetic algorithms. In: **Broadband Communications, Information Technology & Biomedical Applications, 2008 Third International Conference on**. IEEE, p. 30-37, 2008.

NKORDEH, N. S. et al. LTE Network Planning using the Hata-Okumura and the COST-231 Hata Pathloss Models. In: **World Congress on Engineering 2014, London, UK, 2014. Proceedings...** Orlando, p. 705-709, 2014.

ORTEGA, G. V. C. **Redes neurais na identificação de perdas comerciais do setor elétrico**. 2008. Tese de Doutorado. Dissertação de Mestrado, Departamento de Engenharia Elétrica-PUC-Rio, Rio de Janeiro, Brasil. 2008.

OSTLIN, E.; ZEPERNICK, Hans-Jürgen; SUZUKI, Hajime. Macrocell path-loss prediction using artificial neural networks. **IEEE Transactions on Vehicular Technology**, v. 59, n. 6, p. 2735-2747, 2010.

PALLARDÓ, G. R. **On DVB-H Radio Frequency Planning: Adjustment of a Propagation Model Through Measurement Campaign Results**. Dissertação de Mestrado, Department of technology and Built Environment - University of Gävle, Sweden, 2008.

POPESCU, I. et al. Applications of generalized RBF-NN for path loss prediction. In: **Personal, Indoor and Mobile Radio Communications, 2002. The 13th IEEE International Symposium on**. IEEE, p. 484-488, 2002.

POPESCU, I.; NAFORNITA, I.; CONSTANTINOU, P. Comparison of neural network models for path loss prediction. In: **Wireless And Mobile Computing, Networking And Communications, 2005.(WiMob'2005), IEEE International Conference on**. IEEE, p. 44-49, 2005.

QUININO, R. C. ; SUYAMA, E. ; REIS, E. A. ; BESSEGATO, L. F. . **Uma Abordagem Alternativa para o Ensino do Método dos Mínimos Quadrados no Nível Médio e Início do Curso Superior**. Juiz de Fora, MG: Universidade Federal de Juiz de Fora - Departamento de Estatística, 2013. Relatório Técnico do Projeto 03/2013.

RAMOS, G. L. **Medidas de radio propagação em 3,5 GHz em ambientes urbanos : análise de perda de percurso e variabilidade**. 2001. Dissertação de Mestrado. Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2001.

RAPPAPORT, T. S. et al. **Wireless communications: principles and practice**. New Jersey: Prentice Hall, 1996.

RAPPAPORT, T. S. **Comunicações sem fio: princípios e práticas**. New Jersey: Prentice Hall, 2009.

RUMNEY, M. et al. **LTE and the evolution to 4G wireless: Design and measurement challenges**. New Jersey: John Wiley & Sons, 2013.

SANCHES, M. A. R.; CAVALCANTE, G. P. S. Modelos neuro-adaptados para predição de radiopropagação em sistemas móveis terrestres. **Revista da Sociedade Brasileira de Telecomunicações**, v. 16, n. 1, p. 11-15, jun. 2001.

SANCHES, M. A. R. **Modelo Híbrido para Predição de Propagação em Ambientes de Rádio Móvel para Sistemas SMC e SMP**. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Pará, Belém do Pará, 2003.

SENARATH, G. Multi-hop relay system evaluation methodology (channel model and performance metric). http://ieeexplore.org/16/relay/docs/80216j-06_013r3.pdf, 2007.

SHABBIR, Noman et al. Comparison of radio propagation models for long term evolution (LTE) network. **arXiv preprint arXiv:1110.1519**, 2011.

SILVA, A. J. M. **Implementação de um Algoritmo Genético utilizando o modelo de ilhas**. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.

SILVA, D. R. C. **Redes neurais artificiais no ambiente de redes industriais foundation fieldbus usando blocos funcionais padrões**. 2005. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Rio Grande do Norte, 2005.

SIVANANDAM, S. N.; DEEPA, S. N. **Introduction to genetic algorithms**. New York: Springer Science & Business Media, 2008. 442p.

Technical Specification Group Radio Access Network, **Evolved universal terrestrial radio access (E-UTRA); physical channels and modulation**, 3rd Generation Partnership Project (3GPP), Tech. Rep. TS 36.211 Versão 8.7.0, Maio de 2009.

WANG, T.; GAO, H.; QIU, J. A combined adaptive neural network and nonlinear model predictive control for multirate networked industrial process control. **IEEE Transactions on Neural Networks and Learning Systems**, v. 27, n. 2, p. 416-425, 2016.

WEINSTOCK, H. C. **Focus on Cognitive Radio Technology**. New York: Nova Publishers, 2006.

WU, D.; ZHU, G.; AI, Bo. Application of artificial neural networks for path loss prediction in railway environments. In: **Communications and Networking in China (CHINACOM), 2010 5th International ICST Conference on**. IEEE, p. 1-5, 2010.

YANG, M.; SHI, W. A linear least square method of propagation model tuning for 3G radio network planning. In: **Natural Computation, 2008. ICNC'08. Fourth International Conference on**. IEEE, p. 150-154, 2008.

Apêndice A

Perdas de Propagação Calculadas

Neste apêndice, são informados os valores de perda de propagação calculados a partir das medições de campo elétrico obtidas durante a campanha de medições. O cálculo foi feito a partir da Eq. (22):

$$PL = P_t + G_t + G_r - L_C + P_m$$

Os valores dos parâmetros são listados a seguir:

- Potência transmitida, $P_t = 15$ W;
- Ganho da antena transmissora, $G_t = 14$ dBi (2600 MHz) e 7 dBi (800 MHz e 1800 MHz);
- Ganho da antena receptora, $G_r = 14$ dBi (2600 MHz) e 7 dBi (800 MHz e 1800 MHz);
- Perda no cabo, $L_C = 0,128$ dB $\times 9m = 1,15$ dB (800 MHz); $0,204$ dB $\times 9m = 1,83$ dB; $L_C = 0,245$ dB $\times 9m = 2,2$ dB. OBS: Deve-se somar 1 dB referente à perda dos conectores;
- Potência medida, P_m ;
- A perda de propagação, PL , é apresentada na Tabela A.1.

Tabela A.1 – Perda de propagação calculada para todos os cenários

800 MHz			1800 MHz			2600 MHz		
Rota 1	Rota 2	Rota 3	Rota 1	Rota 2	Rota 3	Rota 1	Rota 2	Rota 3
104,174	89,894	107,658	127,542	102,414	108,078	118,174	110,154	113,45
103,49	90,174	104,802	119,93	100,722	109,122	117,49	110,046	113,326
105,502	90,578	102,546	122,126	107,154	102,874	119,502	110,034	113,798
105,898	90,49	98,298	119,546	98,09	109,07	120,034	109,694	113,114
106,818	90,382	95,514	129,722	100,674	108,738	114,978	111,302	113,314
106,034	90,146	94,654	127,71	110,774	127,002	115,682	106,274	117,174
100,978	93,802	107,826	128,79	117,682	127,694	119,826	113,778	116,91
101,682	91,442	110,494	129,978	118,93	131,742	120,006	107,782	120,942
105,826	94,538	121,342	124,318	104,15	128,042	119,502	111,134	126,766
105,414	101,746	97,39	125,27	95,85	126,358	118,726	120,542	138,91
106,378	111,342	104,574	126,554	93,398	134,202	127,57	123,902	127,374
106,006	96,37	105,69	121,514	102,618	128,79	116,806	118,11	131,094
105,502	96,558	109,55	132,978	107,814	123,086	121,262	121,278	147,314
104,726	88,674	113,874	121,07	118,018	129,778	115,53	114,338	131,498
113,57	85,666	118,034	128,794	109,706	135,274	119,706	106,326	135,89

102,806	83,31	127,654	108,65	114,098	128,622	139,934	103,274	134,022
107,262	84,85	121,714	99,106	122,698	133,474	123,102	103,814	148,282
101,53	91,326	113,526	98,042	121,554	142,21	121,074	105,79	143,058
105,706	98,262	118,822	103,494	118,754	142,39	130,678	107,994	151,202
116,934	97,146	121,07	105,414	113,402	133,474	120,626	121,898	150,706
109,102	106,162	122,99	100,574	99,594	136,202	121,166	126,834	150,414
107,074	102,038	118,346	107,598	104,818	146,21	112,358	123,138	149,478
116,678	117,066	118,91	101,286	111,43	134,766	122,294	121,526	145,338
106,626	99,446	133,474	107,89	118,214	137,35	122,738	122,714	150,494
107,166	97,694	131,806	120,266	120,122	135,914	113,666	133,726	145,594
98,358	90,706	121,858	113,438	113,85	129,006	108,514	130,73	147,95
108,294	92,538	122,426	110,042	119,718	137,238	106,106	129,558	143,254
108,738	91,33	129,55	111,814	120,866	127,55	107,174	114,474	152,254
99,666	93,626	122,958	117,262	127,062	134,266	104,346	109,518	144,73
94,514	98,834	123,174	124,342	126,906	139,726	101,386	107,018	138,15
98,106	102,874	131,698	115,446	120,118	138,15	100,57	116,878	145,254
99,174	111,518	121,914	111,578	125,866	135,586	102,222	115,446	139,69
96,346	103,326	122,478	119,494	131,258	137,714	99,386	113,066	144,426
93,386	101,782	130,598	131,018	123,502	134,098	105,25	115,602	147,562
92,57	106,09	128,386	125,466	125,282	135,69	105,562	121,082	153,234
94,222	109,194	123,17	118,626	133,686	131,69	109,414	130,338	151,102
91,386	101,894	124,662	122,634	127,018	120,15	108,526	138,17	151,926
97,25	106,57	119,17	139,37	125,998	118,834	108,37	136,066	144,95
89,562	122,094	128,254	137,454	128,794	127,526	107,194	132,914	129,606
93,414	112,398	126,058	141,034	137,982	129,114	106,734	124,118	125,606
92,526	111,374	119,79	129,326	136,642	121,946	112,598	128,01	142,262
92,37	102,15	121,286	124,498	137,598	124,182	114,774	126,794	130,078
91,194	117,51	127,006	136,73	129,238	123,046	116,63	128,946	124,538
90,734	116,25	126,286	133,886	125,782	124,11	113,858	134,21	128,626
96,598	104,722	117,794	132,478	133,478	119,166	115,718	129,382	126,37
98,774	116,514	118,242	132,05	139,646	117,814	116,558	142,202	126,334
100,63	115,406	125,862	131,218	135,85	116,174	117,55	147,122	123,682
97,858	111,062	123,55	138,082	131,626	130,638	121,202	149,686	131,646
99,718	125,878	118,866	131,818	135,038	119,686	128,246	131,15	124,726
100,558	120,182	123,71	129,33	128,026	124,022	121,43	134,766	131,402
101,55	112,49	117,958	131,078	136,746	142,686	124,426	135,318	137,962
105,202	113,17	113,774	140,138	137,898	133,898	120,722	140,334	128,126
112,246	122,81	114,034	132,982	137,098	136,482	120,338	137,066	152,834
105,43	120,45	113,754	131,914	139,538	127,666	125,902	142,058	149,438
108,426	118,802	103,942	134,678	138,818	127,846	123,958	145,262	140,362
104,722	109,338	112,278	145,378	137,318	134,414	124,742	142,242	141,698
104,338	108,786	107,078	138,118	139,626	126,462	126,338	145,078	150,134
109,902	114,834	104,114	132,166	138,306	134,834	128,774	147,562	140,77
107,958	112,126	113,27	131,854	133,446	147,27	133,15	145,522	148,826
108,742	122,634	115,606	135,25	133,954	132,734	132,79	145,618	145,734
110,338	123,486	103,962	133,522	136,766	135,414	133,806	150,554	146,67

112,774	124,45	107,014	132,802	132,658	133,094	135,202	145,642	142,442
117,15	114,614	107,738	140,094	131,498	137,682	135,218	147,27	142,286
116,79	123,966	106,246	138,15	135,326	140,522	135,402	147,578	152,726
117,806	117,778	109,338	139,102	135,946	141,39	130,726	147,386	
119,202	124,43	103,734	142,038	130,434	133,894	137,614	134,834	
113,218	122,578	107,63	135,722	134,094	137,734	138,57	144,366	
113,402	106,93	131,838	133,37	126,998	141,702	141,258	150,646	
108,726	102,47	114,17	135,502	129,038	144,226	134,37	144,97	
115,614	100,33	114,474	132,366	135,194	142,33	144,238	149,806	
116,57	107,054	115,074	134,678	140,33	144,37	137,334	145,614	
119,258	103,814	122,194	136,794	140,13	139,13	135,178	149,158	
112,37	113,366	122,822	130,762	137,486	144,426	134,494	147,882	
122,238	109,75	116,622	133,322	144,514	140,71	126,014	148,142	
115,334	112,878	119,578	131,07	145,35	144,342	127,25	140,002	
113,178	119,526	119,182	140,662	139,17	138,682	135,27	142,09	
112,494	118,886	120,406	138,618	136,162	139,726	141,054	144,462	
104,014	117,702	113,046	137,162	139,782	145,494	139,034	142,57	
105,25	119,51	120,35	141,206	140,962	145,286	137,002	141,834	
113,27	115,298	114,034	138,042	142,738	147,678	139,254	149,214	
119,054	112,57	121,286	135,134	142,966	147,178	135,978	144,426	
117,034	123,99	118,142	145,25	139,694	149,146	128,542	140,67	
115,002	119,614	120,75	137,186	138,058	148,074	145,67	129,162	
117,254	117,342	121,986	143,326	143,302	140,718	136,898	132,018	
121,978	112,19	120,278	137,786	142,934	136,542	136,13	129,222	
114,542	106,298	123,73	135,378	140,054	140,914	139,222	130,93	
121,67	110,738	132,55	140,814	139,998	127,994	147,57	140,774	
116,898	110,814	123,97	142,174	142,638	148,254	134,318	127,358	
122,13	111,326	128,766	147,758	143,678	135,386	147,146	146,074	
125,222	135,862	132,678	142,174	145,21	132,094	143,134	136,45	
133,57	115,362	129,662	142,41	142,474	125,75	127,702	141,722	
120,318	121,042	127,27	141,174	146,382	132,282	150,238	146,146	
133,146	107,338	126,194	146,322	139,602	147,05	130,854	145,01	
129,134	107,282	128,77	141,886	142,25	143,306	134,154	153,318	
113,702	110,85	129,114	148,326	142,69	131,87	134,85	145,686	
126,238	118,57	129,522	141,294	144,834	143,006	130,442	148,554	
116,854	118,222	130,354	146,834	144,922	137,45	128,562	142,618	
120,154	122,018	132,254	139,854	144,158	136,918	132,134	133,406	
120,85	118,61	129,466	134,362	138,214		139,578	143,354	
116,442	125,85	133,494	135,382	142,858		134,698	153,674	
114,562	118,334	136,022	139,706	140,054		137,37	138,178	
118,134	120,906	128,902	136,758	143,262		136,438	138,082	
125,578	116,506	128,306	133,086	143,362		152,374	141,826	
120,698	128,686	129,622	130,59	139,822		147,298	137,454	
123,37	112,998	125,386	133,054	145,658		147,662	129,254	
122,438	117,242	125,73	140,742	143,146		154,982	132,942	
138,374	127,194	124,498	139,134	140,594		141,626	130,638	

133,298	125,598	125,59	143,446	144,762		140,374	138,818	
133,662	116,078	125,342	140,798	142,614		141,054	135,014	
140,982	125,418	125,618	142,626	140,766		150,014	149,854	
127,626	123,314		141,33	141,07		144,042	149,786	
126,374	123,846			140,594		143,35	148,802	
127,054	113,79			140,366		147,926	136,518	
131,014	121,89			141,35		149,018	129,994	
130,042	119,31			143,226		146,574	128,51	
129,35	119,762			143,094		134,366	154,618	
133,926	132,238			146,354		134,666	137,234	
131,018	121,938			132,19		139,786	139,166	
127,574	122,258			142,818		138,686	138,61	
120,366	115,266			142,91		140,586	140,914	
120,666	121,562			147,994		137,562	143,93	
125,786	128,498			142,122		131,802	143,638	
124,686	121,702			141,494		129,282	148,07	
126,586	116,47			148,946		138,866	142,438	
123,562	115,646			138,854		128,19	141,838	
111,802	117,37			143,182		129,882	142,302	
109,282	120,77			145,554		135,158	144,01	
118,866	116,998			141,494		137,79	143,578	
108,19	116,99			139,61		154,858	140,226	
109,882	113,454			138,762		144,146	137,702	
115,158	124,922			133,782		134,318	139,918	
117,79	123,102			138,57		139,39	137,542	
134,858	120,394			136,474		137,194	147,666	
124,146	123,458			137,658		130,73	145,158	
114,318	120,266			145,65		141,326	147,37	
119,39	120,082			143,578		133,446	149,77	
117,194	123,382			139,882		131,194	139,026	
110,73	116,302			135,41		137,998	148,226	
121,326	129,746			146,506		134,29	144,582	
113,446	115,042			135,226		136,906	146,586	
111,194	119,158			144,402		137,802	140,026	
117,998	112,754			142,558		134,318	142,27	
114,29	132,558			136,582		138,582	148,87	
116,906	122,474			140,77		135,778	139,634	
117,802	127,518			141,794		141,21	143,69	
114,318	119,99			144,734		146,058	142,238	
118,582	120,194			148,094		153,794	138,714	
115,778	117,142			138,226		148,918	142,186	
121,21	127,294					154,13	145,782	
126,058	132,434					143,346	139,43	
133,794	133,134					143,35	144,378	
128,918	131,994					141,638	146,586	
134,13	131,234					149,526	150,318	

123,346	112,558					157,398	145,102	
123,35	128,838					148,862	151,638	
121,638	118,754					144,326	145,114	
129,526	114,99					154,426	140,606	
137,398	113,294					145,594	140,986	
128,862	111,882					146,658	148,554	
124,326	115,254					139,098	146,246	
134,426	135,03					142,098	144,374	
125,594	128,106					137,73	149,038	
126,658	120,198					137,382	150,282	
119,098	125,066					145,262	142,342	
122,098	124,422					137,086	145,49	
117,73	121,566					136,234	150,302	
117,382	111,882					139,386	151,318	
125,262	127,414					133,29	150,37	
117,086	125,398					139,842	146,77	
116,234	119,514					147,366	149,31	
119,386	112,566					141,098	148,738	
113,29	116,882					139,45	150,746	
119,842	125,278					139,246	150,442	
127,366	135,818					147,014	149,334	
121,098	130,214					152,406	149,306	
119,45	119,914					138,318	151,754	
119,246	119,166					149,018	147,098	
127,014	130,638					139,374	143,862	
132,406	118,57					149,466	150,914	
118,318	120,994					150,874	147,978	
129,018	121,246					144,738	150,242	
119,374	122,998					145,674	143,558	
129,466	123,358					144,226	147,606	
130,874	126,17					154,77	146,854	
124,738	123,094					144,254	152,13	
125,674	126,466					154,478	142,522	
124,226	129,034					145,422	148,694	
134,77	135,798					135,058	151,506	
124,254	122,63					145,638	152,254	
134,478	126,402					135,342	152,35	
125,422	128,622					142,982	148,326	
115,058	125,17					137,274	149,818	
125,638	118,09					140,102	147,538	
115,342	122,834					144,002	152,566	
122,982	113,494					143,894	146,306	
117,274	115,998					137,386	150,418	
120,102	126,986					139,49	150,246	
124,002	119,878					139,298	151,61	
123,894	128,206					135,83	147,534	

117,386	127,458					141,614	149,606	
119,49	133,21					144,758	150,154	
119,298	124,254					141,902	153,606	
115,83	125,782					140,562	156,906	
121,614	130,11					135,338	158,014	
124,758	130,25					145,166	157,67	
121,902	141,65					136,914	157,63	
126,562	130,546					141,146	156,082	
121,338	129,17					146,514	159,586	
131,166	129,766					151,11	158,074	
122,914	131,446					138,914	159,922	
127,146	138,598					146,738	157,41	
132,514	130,082						156,438	
137,11	134,386						157,902	
124,914	144,282						160,034	
132,738	134,314						160,318	
	133,386						156,386	
	130,826						160,602	
	138,882						155,586	
	130,69						159,474	
	133,242						160,65	
	132,986						157,062	
	127,67						155,078	
	133,614						159,238	
	126,946						157,474	
	130,678						154,63	
	135,058						156,418	
	126,058						152,302	
	130,862						154,174	
	128,71						155,098	
	143,402						153,95	
	132,458						157,302	
	145,918						152,374	
	124,878						157,686	
	135,658						160,318	
	132,826						159,238	
							159,11	
							154,994	
							157,674	
							158,882	
							160,354	
							159,554	
							156,982	
							157,95	
							155,286	

Fonte: o autor.

Apêndice B

Resultados por Rota

Neste apêndice, a diferença de desempenho entre os métodos avaliados, considerando todos os modelos de propagação, em relação aos resultados do teste RMSE e Wilcoxon, envolvendo todas as rotas, são informados nas Tabelas B.1, B.2 e B.3.

Tabela B.1– RMSE e valor de p para todas as técnicas em 800 MHz.

Modelo	RMSE Rota 1	W. rank sum teste Rota 1	Signif. @95% Rota 1	RMSE Rota 2	W. rank sum teste Rota 2	Signif. @95% Rota 2	RMSE Rota 3	W. rank sum teste Rota 3	Signif. @95% Rota 3
Ericsson	14,95	<i>nulo</i>	S.D	15,57	<i>nulo</i>	S.D	14,29	<i>nulo</i>	S.D
LMS Ericsson	7,77	0,87	S.E	7,29	0,8598	S.E	8,46	0,056	S.E
AG Ericsson	7,65	0,97	S.E	7,541	0,8957	S.E	8,46	0,066	S.E
RNBE Ericsson	$1,06 \times 10^{-3}$	0,99	S.E	$9,5 \times 10^{-4}$	0,9919	S.E	$4,04 \times 10^{-4}$	0,96	S.E
TR 36.942	8,6708	$1,98 \times 10^{-4}$	S.D	7,75	$5,41 \times 10^{-4}$	S.D	9,43	<i>nulo</i>	S.D
LMS TR 36.942	7,7729	0,81	S.E	7,28	0,9442	S.E	8,47	0,045	S.D
AG TR 36.942	7,7044	0,8	S.E	7,37	0,9751	S.E	8,47	0,04	S.D
RNBE TR 36.942	$3,5 \times 10^{-4}$	0,99	S.E	$4,1 \times 10^{-4}$	0,9935	S.E	$2,3 \times 10^{-4}$	0,97	S.E
Espaço Livre	31,2719	<i>nulo</i>	S.D	31,43	<i>nulo</i>	S.D	29,85	<i>nulo</i>	S.D
LMS Espaço Livre	7,7729	0,81	S.E	7,28	0,9415	S.E	8,46	0,045	S.D
AG Espaço Livre	7,6818	0,79	S.E	7,48	0,7311	S.E	8,44	0,14	S.E
RNBE Espaço Livre	$2,11 \times 10^{-5}$	0,94	S.E	$3,3 \times 10^{-3}$	0,9480	S.E	$1,6 \times 10^{-4}$	0,91	S.E
RNS	4,6927	0,88	S.E	5,51	0,76504	S.E	4,81	0,52	S.E

Fonte: o autor.

Tabela B.2 – RMSE e valor de p para todas as técnicas em 1800 MHz.

Modelo	RMSE Rota 1	W. rank sum teste Rota 1	Signif. @95% Rota 1	RMSE Rota 2	W. rank sum teste Rota 2	Signif. @95% Rota 2	RMSE Rota 3	W. rank sum teste Rota 3	Signif. @95% Rota 3
Ericsson	12,0769	0,4852	S.E	8,5006	0,0016	S.D	10,0196	$2,02 \times 10^{-4}$	S.D
LMS Ericsson	8,7663	0,8345	S.E	8,1432	<i>nulo</i>	S.D	8,8326	0,0590	S.E
AG Ericsson	8,7958	0,3322	S.E	8,2813	$1,65 \times 10^{-4}$	S.D	9,1613	0,0111	S.E
RNBE Ericsson	$3,73 \times 10^{-4}$	0,9950	S.E	$7,87 \times 10^{-4}$	0,9962	S.E	$2,34 \times 10^{-4}$	0,9930	S.E
TR 36.942	14,0047	<i>nulo</i>	S.D	16,412	<i>nulo</i>	S.D	12,5002	<i>nulo</i>	S.D
LMS TR 36.942	8,7663	0,8345	S.E	8,1431	<i>nulo</i>	S.D	8,8327	0,059	S.E
AG TR 36.942	8,7455	0,6825	S.E	8,4976	$5,88 \times 10^{-5}$	S.D	9,0576	0,0292	S.D
RNBE TR 36.942	$2,57 \times 10^{-4}$	0,9883	S.E	$1,9 \times 10^{-4}$	0,9935	S.E	$8,1 \times 10^{-5}$	0,991	S.E
ECC	8,9441	0,0569	S.E	9,8374	<i>nulo</i>	S.D	9,1607	0,3759	S.E
LMS ECC	8,6546	0,8410	S.E	8,2733	$6,32 \times 10^{-5}$	S.D	8,8136	0,0584	S.E
AG ECC	8,7485	0,2931	S.E	8,3881	$2,58 \times 10^{-4}$	S.D	9,0876	0,0192	S.D
RNBE ECC	$2,54 \times 10^{-4}$	0,9917	S.E	$1,6 \times 10^{-4}$	0,9908	S.E	$1,1 \times 10^{-4}$	0,9809	S.E
SUI	10,1326	0,0263	S.D	10,0864	<i>nulo</i>	S.D	8,2965	0,4401	S.E
LMS SUI	8,7413	0,9883	S.E	8,2594	$1,61 \times 10^{-5}$	S.D	8,722	0,1056	S.E
AG SUI	9,3115	0,4481	S.E	7,6921	$2,6 \times 10^{-4}$	S.D	9,2376	0,0032	S.D
RNBE SUI	$1,07 \times 10^{-4}$	0,9850	S.E	$8,1 \times 10^{-5}$	0,9995	S.E	$5,59 \times 10^{-5}$	0,9789	S.E
RNBT	4,5725	0,9533	S.E	4,6543	0,8939	S.E	5,6112	0,9970	S.E

Fonte: o autor.

Tabela B.3 – RMSE e valor de p para todas as técnicas em 2600 MHz.

Modelo	RMSE Rota 1	W. rank sum teste Rota 1	Signif. @95% Rota 1	RMSE Rota 2	W. rank sum teste Rota 2	Signif. @95% Rota 2	RMSE Rota 3	W. rank sum teste Rota 3	Signif. @95% Rota 3
Ericsson	10,28	0,24903	S.E	10,0404	<i>nulo</i>	S.D	11,335	0,0798	S.E
LMS Ericsson	8,8091	0,0017	S.D	8,0636	4,9229e-005	S.D	11,1154	0,6319	S.E

AG Ericsson	9,1111	$1,11 \times 10^{-4}$	<i>S.D</i>	7,8564	$3,21 \times 10^{-4}$	<i>S.D</i>	11,2408	0,8844	<i>S.E</i>
RNBE Ericsson	$8,06 \times 10^{-5}$	1	<i>S.E</i>	$9,71 \times 10^{-5}$	0,9977	<i>S.E</i>	$7,01 \times 10^{-5}$	0,9867	<i>S.E</i>
TR 36.942	$\frac{12,969}{5}$	<i>nulo</i>	<i>S.D</i>	19,0032	<i>nulo</i>	<i>S.D</i>	16,8611	<i>nulo</i>	<i>S.D</i>
LMS TR 36.942	8,8092	0,0017	<i>S.D</i>	8,0635	4,9229e-005	<i>S.D</i>	11,1154	0,6319	<i>S.E</i>
AG TR 36.942	9,0413	$2,11 \times 10^{-4}$	<i>S.D</i>	7,8708	$2,91 \times 10^{-4}$	<i>S.D</i>	11,2054	0,8656	<i>S.E</i>
RNBE TR 36.942	$\frac{0,0001}{4813}$	0,9745	<i>S.E</i>	$2,6 \times 10^{-4}$	0,9900	<i>S.E</i>	$7,8 \times 10^{-5}$	0,9829	<i>S.E</i>
ECC	9,3115	0,2672	<i>S.E</i>	10,3305	<i>nulo</i>	<i>S.D</i>	11,2677	0,1208	<i>S.E</i>
LMS ECC	8,9113	0,0019	<i>S.D</i>	8,1273	$6,28 \times 10^{-5}$	<i>S.D</i>	11,1113	0,5529	<i>S.E</i>
AG ECC	9,2327	$8,93 \times 10^{-5}$	<i>S.D</i>	7,7923	0,0012	<i>S.E</i>	11,2464	0,6335	<i>S.E</i>
RNBE ECC	$\frac{7,9559}{e-005}$	0,9968	<i>S.E</i>	$5,54 \times 10^{-5}$	0,9992	<i>S.E</i>	$3,71 \times 10^{-5}$	0,9905	<i>S.E</i>
SUI	8,5251	0,4402	<i>S.E</i>	10,9167	<i>nulo</i>	<i>S.D</i>	11,9017	0,0123	<i>S.D</i>
LMS SUI	8,3909	0,0502	<i>S.E</i>	10,6549	<i>nulo</i>	<i>S.D</i>	11,6962	0,0030	<i>S.D</i>
AG SUI	8,2629	0,9516	<i>S.E</i>	10,1868	<i>nulo</i>	<i>S.D</i>	11,3171	0,0345	<i>S.D</i>
RNBE SUI	$\frac{0,0006}{7062}$	0,9911	<i>S.E</i>	$5,32 \times 10^{-4}$	0,9962	<i>S.E</i>	$3,7 \times 10^{-4}$	1	<i>S.E</i>
RNBT	5,2818	0,9154	<i>S.E</i>	4,6651	0,7956	<i>S.E</i>	5,8212	0,9146	<i>S.E</i>

Fonte: o autor.

Apêndice C

Transmissor de Rádio

Tabela C.1 – Especificações do transmissor MG3700A

Specifications		
Items		Specifications
Frequency	Range	250 kHz to 6 GHz (Option), 250 kHz to 3 GHz (Standard)
	Resolution	0.01 Hz
Output Level	Settable Range	-140 to +13 dBm (E-ATT), -140 to +19 dBm (M-ATT)
	Accuracy Range	CW: -136 to +6 dBm (E-ATT), -136 to +10 dBm (M-ATT)
	Accuracy	±0.5 dB (E-ATT, 25 MHz to 3 GHz, -120 to +6 dBm) ±0.8 dB (E-ATT, 3 GHz to 6 GHz, -120 to +3 dBm) ±0.5 dB (M-ATT, 25 MHz to 3 GHz, -120 to +10 dBm) ±0.8 dB (M-ATT, 3 GHz to 6 GHz, -100 to +7 dBm)
		Difference of CW and MOD
Signal Purity	Spurious/Harmonics	<-30 dBc (f > 300 MHz@E-ATT, f > 250 kHz@M-ATT)
	Spurious/Non harmonics	<-60 dBc (Expect the intersection spurious of 2.4 GHz, 25 MHz to 3 GHz) <-54 dBc (Expect the intersection spurious of 4.4 GHz, 3 GHz to 6 GHz)
Baseband Generator	Resolution	D/A 14 bit
	Sample Rate	20 kHz to 160 MHz
	Waveform Memory	2 GB = 512 Msample (Option)

		1 GB = 256 Msample (Standard)
	Waveform Output Mode	<p>MG3700A contains two built-in arbitrary waveform memories, and these two memories can each choose one waveform pattern, respectively. MG3700A can output the signal of either one of the memories, and can also combine and output both signals simultaneously.</p> <ul style="list-style-type: none"> • Defined Mode • Edit Mode
I/Q Modulation Bandwidth		120 MHz (Using internal baseband generator)
		150 MHz (Using external IQ input)
Mass		<15 kg (excluding option)
BER Measurement Function	Standard	<p>Input bit rate: 1 kbps to 20 Mbps Measurable pattern: PN9/11/15/20/23, ALL0, ALL1, Repetition of 0 and 1</p>
	Option	<p>Input bit rate: 100 bps to 120 Mbps Measurable pattern: PN9/11/15/20/23, PN9fix/11fix/15fix/20fix/23fix, ALL0, ALL1, Repetition of 0 and 1, UserDefine</p>
Storage of Waveform Data	HDD	40 GB HDD is built-in.
	CF	CF slot is arranged at the front panel.
Waveform Transmission	External → HDD	2 MB/s (typ., at 100Base Tx), or 1.5 MB/s (typ., CF card)
	HDD → ARB memory	14 MB/s (typ.)
Remote Control		GPIO, 100Base-Tx
The Method of Waveform Offer	IQproducer	<p>IQproducer is PC application software, that can generate waveform pattern and transmit them to MG3700A. IQproducer is provided with MG3700A as a standard feature, and has the following four functions. After trying the waveform pattern generation function with the IQproducer System function, in order to</p>

		<p>actually use a waveform pattern in MG3700A the license (option) corresponding to each system is required.</p> <p>System license (Option): [Model: MX3701xxA]</p> <p>MX370101A HSDPA IQproducer</p> <p>MX370102A TDMA IQproducer</p> <p>MX370103A CDMA2000 1xEV-DO IQproducer</p> <p>MX370104A Multi-carrier IQproducer</p> <p>MX370105A MOBILE WIMAX IQproducer</p> <p>MX370106A DVB-T/H IQproducer</p> <p>MX370107A Fading IQproducer</p> <p>MX370108A LTE IQproducer</p> <p>MX370108A-001 LTE-Advanced FDD Option [Requires MX370108A]</p> <p>MX370109A XG-PHS IQproducer</p> <p>MX370110A LTE TDD IQproducer</p> <p>MX370110A-001 LTE-Advanced TDD Option [Requires MX370110A]</p> <p>MX370111A WLAN IQproducer</p> <p>MX370111A-001 802.11ac (80MHz) Option [Requires MX370111A]</p>
	<p>Waveform PatteRNBT</p>	<p>Waveform pattern options provide waveform data that meet the requirements of various communication systems and can be used by the MG3700A built-in arbitrary waveform generator. Waveform patteRNBT are downloaded to MG3700A for use.</p> <p>Pre-installed waveform patteRNBT: W-CDMA, GSM/EDGE, CDMA2000 1X, 1xEV-DO, PDC, PHS, AWGN, GPS, WLAN (IEEE802.11a/b/g), Digital Broadcast (ISDB-T/BS/CS/CATV), Bluetooth</p> <p>Optional waveform patteRNBT (Option): [Model: MX3700xxA]</p> <p>MX370001A TD-SCDMA Waveform Pattern</p>
	<p>Generation of Custom Waveform Pattern</p>	<p>IQ sample data files (in ASCII format) programmed by using general EDA (Electronic Design Automation) tools such as MATLAB can also be converted to waveform patteRNBT for MG3700A.</p>
<ul style="list-style-type: none"> • CDMA2000® is a registered trademark of the Telecommunications Industry Association (TIA-USA). • Bluetooth® mark and logos are owned by Bluetooth SIG, Inc. and are used by Anritsu under license. <ul style="list-style-type: none"> • MATLAB® is a registered trademark of The MathWorks, Inc. • IQproducer™ is a registered trademark of Anritsu Corporation. 		

Fonte: Anritsu (2017).



Figura C.1: Tela principal do Transmissor Anritsu MG3700A. Fonte: Cardinal Circuit (2017).

Apêndice D

Amplificador de Potência

RF specifications

Main parameters		
Frequency range		9 kHz to 250 MHz instantaneously
Nominal output load		50 Ω
Nominal output power		125 W (51.0 dBm)
Output power	9 kHz to 50 MHz	min. 125 W (51.0 dBm)
	50 MHz to 225 MHz	min. 140 W (51.5 dBm)
	225 MHz to 250 MHz	min. 125 W (51.0 dBm)
Output power at 1 dB compression		min. 125 W (51.0 dBm)
Nominal power gain		54.4 dB
Gain flatness		± 2.5 dB
Gain adjustment range		> 15 dB
Harmonics	at 125 W	< -20 dBc
Third-order intercept point (TOI)	test frequencies 100 kHz apart	
	200 kHz to 120 MHz	min. 61 dBm
	121 MHz to 250 MHz	min. 60 dBm
Spurious	carrier offset > 100 kHz	nom. -80 dBc, max. -70 dBc
Noise figure at maximum gain	5 MHz to 50 MHz	nom. < 16.0 dB
	50 MHz to 250 MHz	nom. < 9.0 dB

Input		
Nominal input impedance		50 Ω
Input level for nominal output power		-3.4 dBm
Input VSWR	at 50 Ω	max. 2:1
Maximum input level	RF	+5 dBm
	DC	0 V

Output		
Nominal output impedance		50 Ω
Nominal forward output power	at VSWR < 6:1	continuous, without foldback
	at VSWR > 6:1	continuous, with gradual foldback to approx. 50 % of output power, depending on load impedance
Output mismatch protection, VSWR		100 %, without damage

Figura D.1: Especificações de radiofrequência do amplificador R&S®BBA150. Fonte: Rohde & Schwarz (2017).

Mechanical specifications

System size		
Dimensions	W × H × D, incl. fans, handles and stand	430 mm × 196 mm × 580 mm (16.93 in × 7.72 in × 22.83 in)
	for rack mounting	19" 1/2, 4 HU
Weight		approx. 16 kg (35 lb)

RF and sample connectors		
RF input port	either front panel	N female
	or rear panel	N female
RF output port	either front panel	N female
	or rear panel	N female
RF sample port	forward output power, optional	N female
	reflected output power, optional	N female
Detected sample port	forward output power, optional	N female
	reflected output power, optional	N female

Figura D.2: Especificações mecânicas do amplificador R&S@BBA150. Fonte: Rohde & Schwarz (2017).

Electrical specifications

AC supply voltage		
Nominal operating voltage range		100 V to 240 V AC ± 10 %, single phase, 50 Hz to 60 Hz ± 6 %
Rated current	at 110 V	9.1 A
	at 230 V	4.4 A
Rated power	$RF_{out} = 125 \text{ W (RMS)}, VSWR = 1$	1.0 kVA

Figura D.1: Especificações elétricas do amplificador R&S@BBA150. Fonte: Rohde & Schwarz (2017).

Apêndice E

Analizador de Espectro

OVERVIEW	APPLICATIONS	LIBRARY
Features	<ul style="list-style-type: none">• Handheld, battery-operated design• RBWs: 1 Hz to 3 MHz in 1-3 sequence, VBWs: 1 Hz to 3 MHz in 1-3 sequence• Normal, Max hold, Min hold, user settable trace averaging• 6 Markers plus 6 delta markers or choose one marker with 6 delta markers• Multi-segmented upper and lower limit lines	
Description		
Technologies		

Figura E.1: Especificações do Spectrum Master MS2721B. Fonte: Anristu (2017).

OVERVIEW	APPLICATIONS	LIBRARY
<p>Convenient operating procedures, high sensitivity, excellent repeatability and exceptional performance enable the MS2721B to simplify measurements on wireless systems for easy verification of system compliance. Typical applications include:</p>		
<ul style="list-style-type: none">• Transmitter Spectrum Analysis - occupied bandwidth, channel power, adjacent channel power ratio and modulation• Received Signal Analysis - location and identification of in-band interference and out-of-band spurious signals and spectral masks• Signal Strength Mapping - to determine the most suitable location for antennas, base stations and repeaters• Field analysis of 3G signals – fast sweep speed, field-swappable battery, smart measurements and daylight-viewable display make the MS2721B an ideal choice for the challenge of rugged environments• Broadcast measurement AM & FM analog and IBOC proofing measurements• Interference mitigation in many diverse situations including wireless patient telemetry in hospitals• Digital Video testing in DVB-T/H and ISDB-T formats		

Figura E.2: Aplicações do Spectrum Master MS2721B. Fonte: Anristu (2017).





Figura E.3: Tela principal do analisador de espectro. Fonte: o autor (2017).

Apêndice F

Antenas

Product Features

- WiFi Freq Range
- 2600 MHz
- 100W power handling
- High Gain, 14dBi
- Rugged Fiberglass Radome



Specifications ⁽¹⁾

Parameter	Value	Units	Description
Minimum Frequency	2500	MHz	
Maximum Frequency	2700	MHz	
Impedance	50	Ohms	
Gain	14	dBi	Max Gain
Horiz Beamwidth	30	Deg	
Vert Beamwidth	30	Deg	
Polarization			Vertical or Horizontal
Max Input Pwr	100	W	Watts (Max)
Maximum VSWR	<1.5	ratio	Between Min and Max Freq
Length/Width	216	mm	8.5 sq inches
Width	25	mm	1 inch
Mast Diameter	30-50	mm	Mast Mounting Info
Weight	1.2	Kg	
Connector Type		N(f)	N-Type Female
Maximum Wind Velocity	241	Km/Hr	

Figura F.1: Antena painel (2500 MHz – 2700 MHz). Fonte: Pasternack (2017).

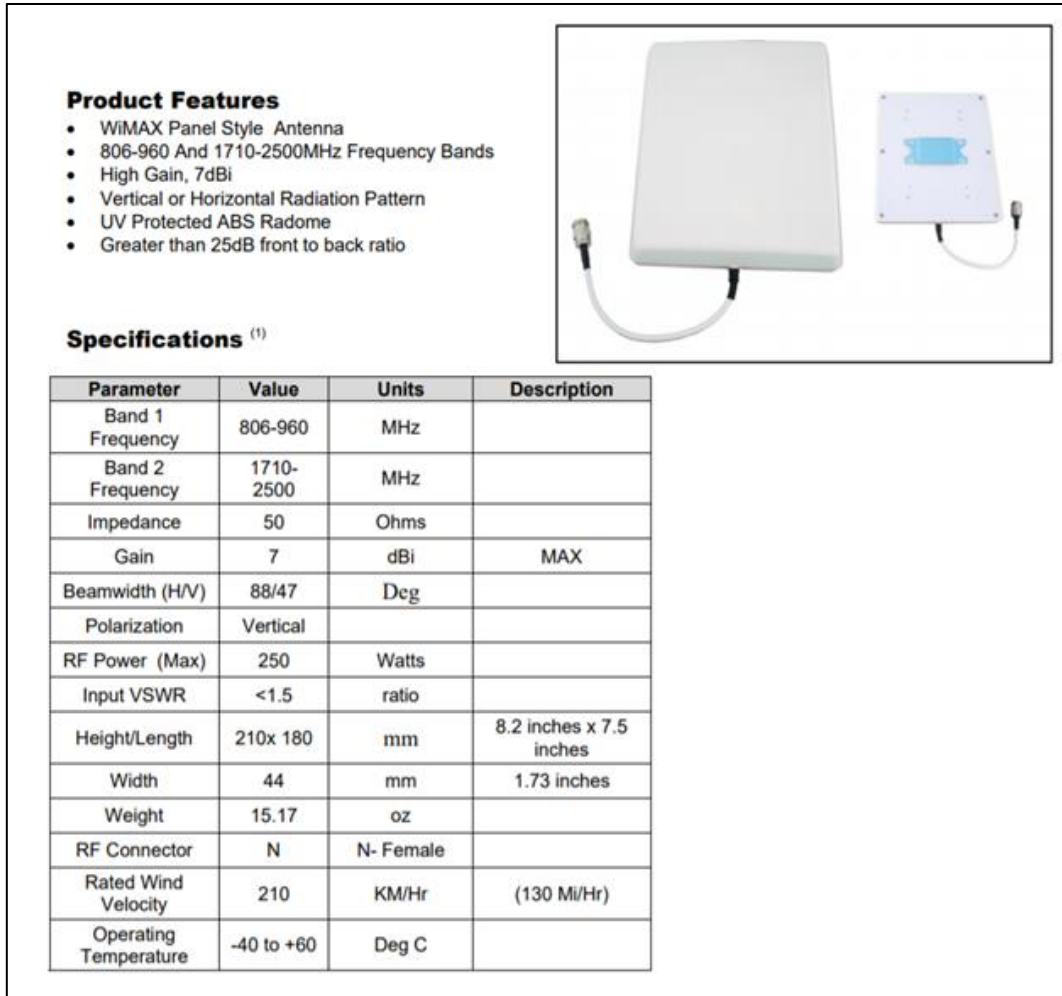




Figura F.2: Antena painel dupla (806 MHz – 960 MHz e 1710 MHz – 2500 MHz). Fonte: Pasternack (2017).

Apêndice G

Linha de Transmissão e Conectores

Cabos Coaxiais **DATALINK**

Produto
Cabo Coaxial **DLC 213 Premium**



Características

Parte do cabo	Material	mm	in
Condutor Interno	Copper Clad Aluminum	2,61	0,103
Isolação	Policetileno expandido	7,25	0,285
Condutor Externo	Fita aluminizada	7,35	0,289
Blindagem (trança)	Cobre estanhado (cobertura 75%)	8,14	0,320
Capa	Poliuretano preto	10,34	0,407

Especificações Mecânicas

Peso do cabo	0,096 kg/m	0,064 lb/ft
Raio mínimo de curvatura	25,4 mm	1,00 in
Temperatura de operação	80°C máx	176°F

Especificações elétricas

Impedância nominal	50 ohms
Velocidade de propagação	82%
Capacitância	82 pF/m
Máxima Tensão DC	2,5 kV // 1 min
Resistência do condutor interno	5,5 ohm/km
Resistência da blindagem	8 ohm/km

Frequência (MHz) à 20°C	Atenuação (dB/100m)	Potência Máxima (kW)
30	2,3	3,16
50	2,9	2,44
100	4,2	1,72
200	6,1	1,20
450	9,4	0,79
800	12,0	0,50
900	13,7	0,55
1000	14,6	0,51
1500	18,3	0,42
1800	20,4	0,38
2000	21,8	0,35
2400	24,1	0,32
3000	27,5	0,29
3500	30,2	0,26
5800	41,2	0,20
6600	44,7	0,18
10000	58,4	0,14

AF Datalink Eqtos. de Telecomunicações Ltda. Tel. (11) 5642-0066 Fax: (11) 5641-0012

Figura G.1: Antena painel dupla (806 MHz – 960 MHz e 1710 MHz – 2500 MHz). Fonte: Pasternack (2017).

Conectores de RF Série N169 - 16 IEC

ESPECIFICAÇÕES ELÉTRICAS

Impedância: 50/75 Ohms
Frequência: 0-11 Ghz
Tensão: 1500 V pico

Rígidez Dielétrica: 2500 V rms
VSWR: 1,3 Max. Na faixa 0-11 Ghz

RESISTÊNCIA DE CONTATO

*Central 1,0 mOhm

*Extenso 0,2 mOhm

*Corpo 0,1 mOhm

Fuga de RF: -90 dB mínimo em 3 Ghz

Perda por inserção 0,2 dB máximo em 10 Ghz

Resistência de isolamento: 5 GOhms (mínimo)

CARACTERÍSTICAS MECÂNICAS

Contatos: Ouro 0,05 μ
Corpo: Níquel 0,5 a 0,7 μ

MONTAGEM

Contato central: Climpado ou soldado
Prensa - cabo: porca e bucha para blindagem



ESPECIFICAÇÕES MECÂNICAS

Descrição

Contatos Fêmea
Contatos Macho
Corpos
Isolantes
Vedação

Material

Bronze BZ 3444
Latão
Latão
Teflon PTFE
Borracha

Tratamento

Ouro
Níquel
Níquel



Figura G.2: Conectores de RF série N169.