

# Rede Neural Artificial Aplicada na Predição de Cobertura de Sinal em Vegetação

Nivea P. Carvalho, Leni J. Matos e Edson Cataldo

**Resumo**— Uma rede neural é empregada buscando melhorar a predição de sinal rádio móvel em um ambiente com vegetação. Para isso, uma campanha de medições foi realizada em Niterói, Rio de Janeiro, gerando dados para treinamento e teste da rede, com variações em frequência, altura da antena de transmissão e rotas, tomados como dados de entrada da rede. Como saída da rede foram obtidos os níveis de potências preditas e comparados com os obtidos pelo modelo de predição *log-distance*, mostrando a eficácia da rede neural na melhoria da predição de sinal.

**Palavras-chave**— Modelos de predição, predição de cobertura, propagação em vegetação, rede neural artificial.

**Abstract**— A neural network is used to improve signal strength prediction of a mobile radio channel in a vegetated environment. For this, a measurement campaign was carried out in Niterói, Rio de Janeiro, generating data for training and testing the network, with variations in frequency, height of the transmission antenna and routes, taken as input data to the network. The predicted signal strength were obtained as a network output and compared with those obtained by the *log-distance* prediction model, showing its efficiency.

**Keywords**— Prediction models, coverage prediction, propagation in vegetation, artificial neural network.

## I. INTRODUÇÃO

A cobertura do sinal rádio móvel nunca foi tão estudada como nos dias atuais onde, com o avanço da tecnologia, as aplicações simplificam seus processos para facilitar o uso em dispositivos portáteis. Com um aparelho celular é possível fazer uma jornada inteira de trabalho enquanto se ouve música e, ao mesmo tempo, se monitora todo o corpo com uma pulseira inteligente (*smart watch*). Para que todas as ações sejam feitas sem perda de dados valiosos ou redução do desempenho, é imprescindível que o sinal seja entregue com nível adequado, sofrendo pouca atenuação durante o deslocamento no ambiente. São encontrados, na literatura, muitos estudos e modelos sobre o comportamento do sinal em áreas urbanas onde são considerados efeitos de prédios, veículos e sinalizações [1-3] e de ambientes com densa vegetação como florestas [4-5], mas sobre ambientes urbanos ou residenciais arborizados e parques com árvores de menor porte há poucos modelos [6-8], havendo necessidade de um maior número de testes em campo para se chegar a modelos empíricos mais realistas.

Nivea Portugal<sup>1</sup>, Leni Matos<sup>2</sup>, Edson Cataldo<sup>3</sup>; PPGEET, Universidade Federal Fluminense, Niterói-RJ<sup>1,2,3</sup>; e-mail: niveaportugal@id.uff.br<sup>1</sup>, lenijm@id.uff.br<sup>2</sup>, ecataldo@id.uff.br<sup>3</sup>.

Parques são ambientes de lazer e descanso onde, em geral, a população busca entretenimento nos dispositivos celulares. Focando nesse tipo de ambiente, uma praça arborizada com construções ao redor e veículos atravessando o percurso transmissor-receptor, foi o local escolhido para a realização das medições apresentadas nesse trabalho. Para esses ambientes, os modelos mais usuais de predição não costumam ter bom ajuste, uma vez que a vegetação entre transmissor (TX) e receptor (RX) tem muita influência no sinal que por ela se propaga, principalmente causando absorção e espalhamento, acarretando não só em atenuação como dispersão do mesmo, respectivamente. Muitas vezes, é o modelo básico *log-distance* que acaba por ser o de melhor ajuste nesses ambientes mistos, como ocorre em [9].

Com o intuito de melhorar a predição de cobertura, uma rede neural, com o estímulo apropriado (os dados de entrada e saída), pode ser usada para predição do comportamento do sinal rádio móvel e é aqui aplicada, mostrando bons resultados para a predição. Alguns trabalhos, onde redes neurais são aplicadas à cobertura de ambientes *indoor* [10] ou *outdoor* [11] são encontrados, mas não é do conhecimento da autora sua aplicação a ambientes de vegetação. Assim, o objetivo deste trabalho é mostrar predições realizadas com o emprego das redes neurais artificiais na melhoria do modelo *log-distance* aplicado no ajuste do nível de potência média recebida, medida numa praça [9].

A quantidade de dados coletados nas medições é uma dificuldade apresentada em alguns estudos, pois para que seja analisado cada parâmetro, é necessário um número considerável de elementos. No trabalho aqui apresentado, foram feitas medições variando a altura da antena de transmissão e frequências de um sinal CW para duas rotas. Com isso, garantiu-se uma boa base de dados para treinamento e teste da rede e uma análise mais profunda do comportamento do sinal de saída de acordo com os conjuntos de entrada. Na continuidade, a Seção II descreve a campanha de medições assim como os valores fixados nos equipamentos; na Seção III será descrito o processamento do sinal e a verificação do melhor modelo de predição para o ambiente; na Seção IV será discutida e apresentada a arquitetura da rede neural escolhida bem como seu treinamento. A aplicação da rede e os resultados finais estão na Seção V e conclusões e considerações finais, na Seção VI.

## II. MEDIÇÕES EM CAMPO

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

casas e ruas com alta movimentação de veículos de transporte de massa, a importância de uma boa cobertura fica evidente.

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



Fig. 1. Vista aérea da Pça. Nilo Peçanha destacando as rotas de medições [9].

#### A. Setup de Transmissão

O sistema de transmissão compõe-se de um gerador de sinais, um amplificador de potência, uma fonte digital, cabos interligando os equipamentos e uma antena omnidirecional, especificados na Tabela I.

TABELA I. ESPECIFICAÇÕES DO SISTEMA TRANSMISSOR

Equipamento	Especificações
Gerador vetorial de Sinal MG3700A, Anritsu	250 kHz a 6 GHz
Amplificador de potência ZHL-16W-43+, Minicircuits	Ganho: de 40 a 47 dB para a faixa de 700-4000 MHz
Fonte Digital PS-5000, Icel	2 fontes de 0-30 V/3 A e 1 de 0-5V/3 A
Antena OmniI-ATO-380-6000, RFS	Ganho: 1 dB/705 MHz, 5dB/1.79 GHz, 6 dB/2.4, 3.5 e 4 GHz
Cabo Anritsu, de 1 m	50 $\Omega$ (gerador para o PA)
Cabo R&S, de 1,7 m	50 $\Omega$ (PA p/ antena Tx)
Cabo Nacional, de 1 m	Cabo adicional (PA para antena Tx) = 4,2 m

#### B. Setup de Recepção

Para a captura do sinal, o sistema receptor foi montado sobre um carrinho, que se deslocou continuamente, percorrendo as rotas já apresentadas. Na recepção do sinal, foram usados uma antena omnidirecional com altura fixa de 1,59 metros, o analisador de espectro MS2692A e um cabo, ambos da Anritsu, especificados na Tabela II e com seus respectivos ganhos e perdas para cada parâmetro que foi variado.

TABELA II. ESPECIFICAÇÕES DO SISTEMA RECEPTOR

Equipamento	Especificações
Antena Multi Band OmniMA-CQ27-1X, 380 MHz - 6 GHz, MARS	Ganho: 3 dB/705 MHz, 5dB/1.79 GHz, 6 dB/2.4, 3.5 e 4.0 GHz
Analisador de Sinal MS2692A, Anritsu	50 Hz a 6,5 GHz
Cabo Anritsu, de 1 m	50 $\Omega$ (antena Rx p/ analisador)

Uma vez fixada uma frequência e uma altura de antena transmissora, cada rota foi percorrida com uma velocidade média de 1,5 m/s em um tempo de 60 segundos para cada percurso. Foram medidos níveis de sinal recebido para cada trio: altura, frequência e rota, que neste trabalho chamaremos de conjunto de medidas. A Tabela III mostra como este conjunto foi dividido, para facilitar o entendimento, onde A1 é igual a 1.7 m e A2 igual a 4.2 m.

TABELA III. ORGANIZAÇÃO DO CONJUNTO DE MEDIDAS

Frequência (MHz)	Altura da Transmissora /Rota			
	A1/R1	A2/R1	A1/R2	A2/R2
705	A1F1R1	A2F1R1	A1F1R2	A2F1R2
1790	A1F2R1	A2F2R1	A1F2R2	A2F2R2
2400	A1F3R1	A2F3R1	A1F3R2	A2F3R2
3500	A1F4R1	A2F4R1	A1F4R2	A2F4R2
4000	A1F5R1	A2F5R1	A1F5R2	A2F5R2

### III. ANÁLISE E PROCESSAMENTO DOS DADOS

No analisador de espectro, os dados dos níveis de potência recebidos foram coletados e armazenados em planilhas Excel. Com programação adequada do sinal, foi plotado o gráfico do sinal medido para cada conjunto de medidas e a curva de ajuste para a perda no percurso, *path loss*.

A fim de ajustar o melhor modelo de predição, foram calculadas as predições de perdas por três modelos, sendo eles: *log-distance* [12], ITU-R [13] e FITU-R [8]. O primeiro é um modelo básico, que costuma ser a partida para outros modelos; o segundo e terceiro são modelos criados para ambientes com vegetação. Suas expressões são:

#### A. Modelo Log-distance

Sua equação é apresentada em (1), onde  $d_0$  é distância da transmissora ao ponto inicial de medição da rota,  $d$  é a distância da transmissora a qualquer ponto da rota,  $P_r$  é o nível de potência, em dBm, do sinal recebido em  $d$ ,  $d_0$  é a distância de referência, no ponto mais próximo da transmissora, e  $N$  é o coeficiente de perda de percurso [12].

$$P_r(d) = P_r(d_0) - 10.N.\log(d/d_0) \quad (1)$$

#### B. Modelo ITU-R

É um modelo empírico, conhecido como *Early ITU* [13], e aplicável para distâncias menores que 400 metros. A computação em excesso à perda de espaço livre, devido à propagação através de uma floresta, é dada por:

$$A_v = 0,2 f^{0,3} d^{0,6} \quad (2)$$

onde  $f$  está em MHz e  $d$ , em metros. Vale lembrar que a perda total ( $L$ ) seria a soma da perda do espaço livre ( $L_0$ ) com a perda em excesso ( $A_v$ ).

### C. Modelo do espaço livre

Conhecida como equação de Friis [12] para a perda de sinal em ambiente sem multipercurso e obstruções, é descrita como:

$$L_0 = 32,4 + 20.\log_{10}(d) + 20.\log_{10}(f) \quad (3)$$

onde  $d$  é a distância entre as antenas transmissora e receptora, em km, e  $f$  é a frequência da portadora transmitida, em MHz.

### D. Modelo FITU-R

A partir de medições realizadas para distâncias menores que 120 m, um modelo ajustado ao ITU-R foi proposto em [15], onde a perda em excesso na vegetação, em dB, é calculada por:

$$A = 0.37 \times f^{0.18} d^{0.59}, \text{ sem folhas} \quad (4)$$

$$A = 0.39 \times f^{0.39} d^{0.25}, \text{ com folhas} \quad (5)$$

onde  $f$  é a frequência em MHz e  $d$  é a profundidade das vegetação, em metros.

Aplicados os modelos ao ambiente em questão, mostra-se a comparação gráfica dos modelos em relação ao ajuste das medidas, para o conjunto A2F2R2, na Fig. 2. A *path loss* [12] é obtida dos dados, determinando-se a curva média de ajuste aos dados.

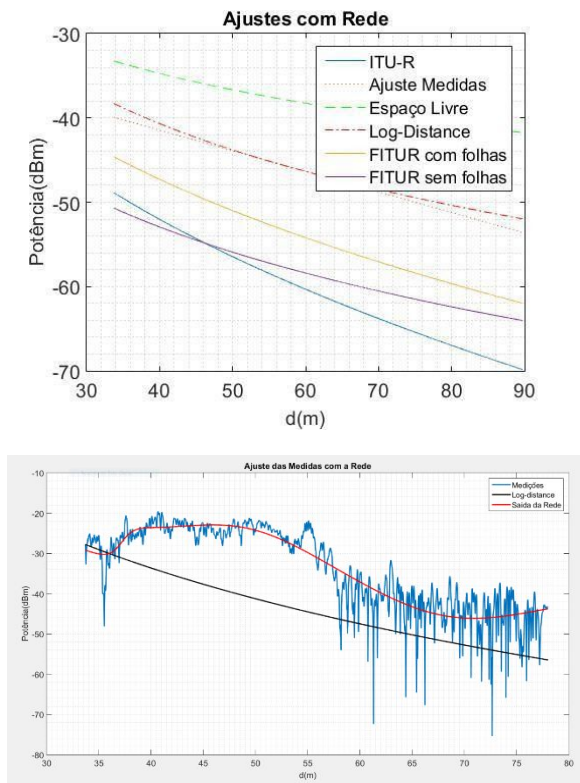


Fig. 2. Comparação dos modelos de predição de perda e a *path loss*.

Com o mesmo procedimento, para todas as vinte possibilidades da Tabela III, obteve-se como resultado da

comparação dos modelos, confirmando os resultados de Magalhães [9], o melhor ajuste às medidas em campo para o modelo *log-distance*, portanto, foi o escolhido para ser usado no treinamento da rede neural.

## IV. APLICAÇÃO DA REDE NEURAL ARTIFICIAL NA PREDIÇÃO

Para encontrar o melhor modelo de rede para o ambiente em questão, foram feitos treinamentos e testes de várias configurações de redes neurais, variando-se o número de camadas escondidas e de neurônios em cada uma delas. Para cada configuração, os valores de RMSE foram calculados e comparados. A configuração de rede que resultou no menor valor de RMSE foi escolhida.

A rede neural artificial (RNA) utilizada neste artigo foi MLP (*Multilayer Perceptron feedforward back propagation*) usando Levenberg-Marquardt como algoritmo de otimização [14]. Sua arquitetura e treinamento são apresentados nos tópicos que se seguem.

### A. Arquitetura das RNAs

A arquitetura geral de uma rede neural artificial é composta de neurônios de entrada, comumente chamados de dados de entrada, camadas escondidas e neurônios de saída. Os dados de entrada utilizados neste trabalho foram: a altura da antena, potência de transmissão, frequência do sinal, distância do transmissor até cada ponto da rota e os níveis de potências previstas pelo modelo *log-distance*, estes com o intuito de aplicar a rede na melhoria do melhor modelo de previsão para o ambiente. O dado de saída prevista, com a utilização da rede, é a potência do sinal recebido em cada ponto da rota.

Os neurônios tanto da camada escondida, como de saída, possuem funções de ativação que tem como finalidade restringir a amplitude do sinal de saída a um valor finito [17]. As funções aqui utilizadas foram respectivamente, tangente hiperbólica (*tansig*), e linear (*purelin*), todas amplamente utilizadas para problemas de adaptação de funções [15].

Na Fig. 3 está representada uma rede MPL genérica com parâmetros de entrada, uma camada escondida e conexões dos neurônios.

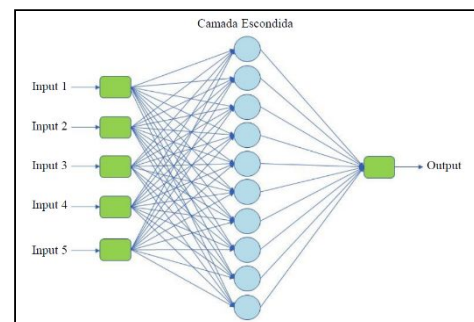


Fig. 3. Representação de uma rede MPL.

### B. Treinamento das RNAs

A fase de treinamento da rede é quando ocorre a aprendizagem, onde conjuntos de dados de entradas e suas respectivas saídas, são usadas para treinar a rede através de um algoritmo. Como algoritmo de treinamento, foi escolhido



Levenberg-Marquardt *backpropagation* (*trainlm*). Esses conjuntos de dados podem ser considerados como exemplos, que são separados dos valores totais dos dados obtidos na medição. Essa separação é comumente feita em porcentagens entre valores usados no treinamento, validação e teste da rede.

Além da variação na arquitetura da rede, dois conjuntos dessas porcentagens dos dados foram aplicados para que o maior número de configurações de diferentes treinamentos também fossem utilizados. Os conjuntos foram: 60% dos dados para treinamento, 20% validação e 20% teste e 80% dos dados para treinamento, 10% validação e 10% teste. Os dados utilizados nestes conjuntos de porcentagens foram os obtidos nas medições da rota 1, apresentada anteriormente.

A ferramenta para treinamento da rede (*nntaintool*) pode ser vista na Fig. 4, assim como o estado dos parâmetros da rede ao final do treinamento. Essas informações são importantes, pois determinam o quanto a rede “aprendeu” até prever um determinado resultado, possibilitando analisar sua complexidade.

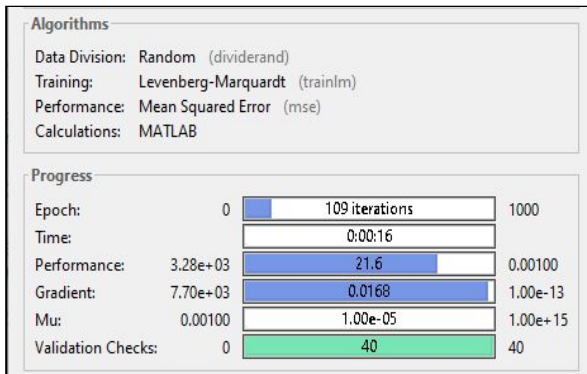


Fig. 4. Neural Network Training (*nntaintool*).

### C. Cálculo e Comparação entre os Valores de RMSE

O erro médio quadrático (RMSE) tem sua expressão dada pela equação abaixo e foi usado para determinar a melhor configuração da rede neural.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (f_i - g_i)^2}{N}} \quad (6)$$

onde  $f$  e  $g$  são as os níveis de potência a serem comparados e  $N$  é o número de amostras do sinal.

Primeiramente foram calculados os valores de RMSE, em cada ponto da rota, entre as potências previstas pelo modelo *log-distance* e as potências recebidas do sinal medido. Depois, para cada configuração de rede foram calculados os valores de RMSE entre as potências previstas por ela e as potências recebidas do sinal medido.

A comparação foi feita entre os valores de RMSE das redes. A configuração da rede neural que apresentou o menor valor de RMSE foi a treinada com 80% dos dados da rota 1, 5 neurônios de entrada, uma camada escondida com 8 neurônios e uma camada de saída.

## V. APLICAÇÃO DA REDE E RESULTADOS

Na aplicação da rede, foram utilizados todos os dados de entrada de ambas as rotas, separados por seus 20 conjuntos de medidas e plotados os gráficos comparativos entre a saída da rede, a potência do sinal recebido e a predição do modelo *log-distance*.

Na Fig. 5 tem-se o gráfico comparativo de um dos conjuntos de medidas da rota 1 aplicado na rede treinada na mesma rota. Pelo fato da rede ter sido treinada com dados da rota 1, era esperado que seu comportamento fosse muito próximo aos da medição.

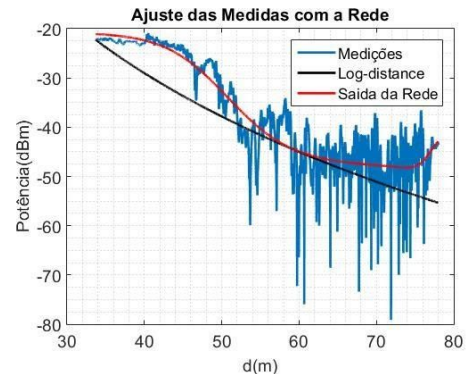


Fig. 5. Comparação entre os dados de saída da rede, com os obtidos nas medições e com a predição dada pelo modelo *log-distance*.

A aplicação dos dados da rota 2 na mesma rede pode ser vista na Fig. 6. Como esperado, o desempenho da rede aplicada na rota 2 foi inferior ao aplicado na rota 1, pelo fato de não ter seus dados aplicados no treinamento da mesma.

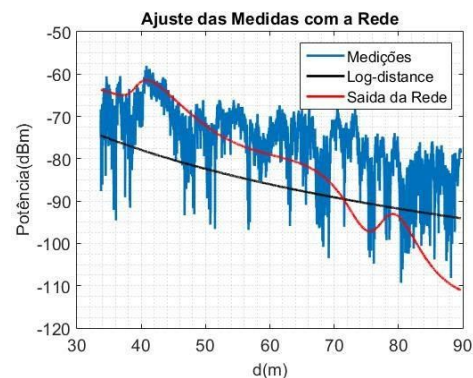


Fig. 6. Comparação entre os dados de saída da rede, com os obtidos nas medições e com a predição dada pelo modelo *log-distance*.

A Tabela IV mostra o RMSE, em dB, do modelo *log-distance* em relação aos dados obtidos na medição, para cada conjunto de medidas (altura de antena/Rota), nas cinco frequências adotadas.

TABELA IV. DISTÂNCIAS ENTRE PDF DA PREDIÇÃO DO MODELO *LOG-DISTANCE* COM AS MEDIÇÕES

	A1/R1	A2/R1	A1/R2	A2/R2
F1	0,055	0,108	0,045	0,059
F2	0,062	0,089	0,058	0,044
F3	0,044	0,063	0,046	0,06
F4	0,042	0,07	0,057	0,048
F5	0,045	0,048	0,063	0,104

A Tabela V mostra o RMSE entre o resultado da rede e a potência medida para cada conjunto de medidas.

TABELA V. DISTÂNCIAS ENTRE PDF DAS MEDIÇÕES COM A PREDIÇÃO DA REDE NEURAL

	A1/R1	A2/R1	A1/R2	A2/R2
F1	0,029	0,029	0,056	0,273
F2	0,031	0,036	0,064	0,19
F3	0,038	0,043	0,167	0,067
F4	0,034	0,041	0,184	0,096
F5	0,041	0,039	0,215	0,091

Comparando os resultados da Tabela V com os da Tabela IV, obtêm-se os percentuais de melhoria de predição do emprego da RNA em relação ao modelo *Log-distance*. Na Tabela VI são apresentados esses percentuais para a rota 1. Desses resultados, pode ser visto que a melhoria de predição com a RNA, na situação da R1 com variação de altura de antena, variou de 9,8% a 73,3%, enquanto para a rota 2, a melhoria foi de 12,7% na predição para a altura de 4.2m e frequência de 4GHz (A2F5R2). Ainda se verificou que os melhores resultados para a rota 1, foram para A2.

TABELA VI. MELHORIA DE PREDIÇÃO DA APLICAÇÃO DA RNA RELATIVA AO MODELO *LOG-DISTANCE* PARA A ROTA 1

	A1/R1	A2/R1
F1	47,3%	73,3%
F2	50,2%	59,9%
F3	14,6%	32,3%
F4	20,4%	41,6%
F5	9,8%	18,7%

## VI. CONCLUSÃO

Para melhoria do modelo de predição *log-distance*, frente aos dados experimentais obtidos de medições em ambiente de parque com vegetação, foi criada uma rede neural artificial *feedforward backpropagation*. Após treinamento e testes da rede, concluiu-se que a RNA construída mostrou-se eficiente na predição de potência do canal rádio móvel com vegetação em comparação com o modelo *log-distance* aplicado ao mesmo conjunto de dados. Com resultado destacado para o caso em que a RNA foi treinada em uma rota e aplicada em outra rota, levando a crer que essa técnica tem um grande potencial para ser aplicada em problemas desse tipo.

Mesmo com a eficácia da rede sendo comprovada, outros testes poderão ser feitos como a aplicação de dados coletados em outros ambientes, redução do número de parâmetros de entrada, aumento ou redução do número de camadas e neurônios, entre outros, sempre com o intuito de otimizar a predição do sinal.

## AGRADECIMENTOS

Os autores agradecem à CAPES e ao CNPq.

## REFERÊNCIAS

- [1] Y. Okumura, "Field strength and its variability in UHF and VHF land-mobile radio service. Rev. Elec. Commun. Lab., vol. 16, 1968.
- [2] V. Erceg, L. J. Greenstein, S. Y. Tjandra, S. R. Parkoff, A. Gupta, B. Kulic, A. A. Julius, and R. Bianchi, "An empirically based path loss

- model for wireless channels in suburban environments". Selected Areas in Communications, IEEE, vol. 17, Issue 7, Jul 1999, pp. 1205-1211.
- [3] COST 235, Radio Propagation Effects on Next Generation Fixed-Service Terrestrial Telecommunication Systems. Luxembourg, Final Rep. (1996).
- [4] S. S. Seker, A. Schneider. "Experimental Characterization of UHF Radiowave Propagation Through Forests", IEE Proceedings, vol.140, N.5, pp. 329-335, October 1993.
- [5] R. K. Tewari, S. Swarup, M. N. Roy. "Radio Wave Propagation Through Rain Forests of India", IEEE Trans. Antennas Propagation, vol. 38, N.4, pp. 443-449, 1990.
- [6] B. R. S. Mello, P. A. Pinna, M. S. Dias, F. J. B. Fonseca, and L. J. Matos, "Measurements in vegetation and modeling of a radio mobile channel in an urban park", in SBrT – International Telecommunications Symposium - ITS 2014, São Paulo, 2014.
- [7] S. A. Torrico, H.L. Bertoni, R. H. Lang, "Modeling Tree Effects on Path Loss in a Residential Environment", IEEE Trans. Antennas Propagat., vol.46, N.6, pp. 99-302, 1998.
- [8] Y. S. Meng and Y. H. Lee, "Investigations of foliage Effect on Modern Wireless Communication Systems: A REVIEW", Progress In Electromagnetics Research, vol. 105, 2010
- [9] D. A. B. Magalhães, Análise de Cobertura Modelagem do Sinal Rádio Móvel em Ambiente com Vegetação na Faixa 700 – 4000 MHz, Dissertação de Mestrado, UFF, Niterói, 2020.
- [10] M. B. Moura, D. C. Vidal, C. F. Schueler, L. J. Matos, T. N. Ferreira, "Outdoor-to-Indoor Power Prediction for 768 MHz Wireless Mobile Transmission using Multilayer Perceptron", in 2018 International Joint Conference on Neural Networks, 2018, Rio de Janeiro, Brazil, pp.1258-1264, Dec. 2018.
- [11] G. P. Ferreira, L. J. de Matos and J. M. M. da Silva, "Improvement of Outdoor Signal Strength Prediction in UHF Band by Artificial Neural Networks", IEEE Transactions on Antennas and Propagation, vol. 64, n. 12, pp. 5404-5410, Dec. 2016.
- [12] W.C.Y. Lee, Mobile Cellular Telecommunications Systems, McGraw-Hill, 1990.
- [13] J. C. Silva, G. L. Siqueira and P. V. G. Castellanos, "Propagation Model for Path Loss through Vegetated Environments at 700-800 MHz Band", Journal of Microwaves, Optoelectronics and Electromagnetic Applications, vol. 17, no. 1, March 2018.
- [14] Al-Nuaimi, M. O. and R. B. L. Stephens, "Measurements and prediction model optimization for signal attenuation in vegetation media at centimetre wave frequencies", IEE Proc. Microw. Antennas Propag., Vol. 145, No. 3, 201–206, 1998.
- [15] M. T. Hagan and M. B. Menhaj, "Training feedforward networks with the Marquardt algorithm", IEEE Trans. Neural Netw., vol. 5(6), pp. 989-993, Nov. 1994.
- [16] M. B. Moura, Melhoria na Predição de Cobertura de Sinal Rádio Móvel Outdoor-Indoor na Faixa de 700 MHz Através de Redes Neurais, Dissertação de Mestrado, UFF, Niterói, 2017.
- [17] S. Haykin. "Redes Neurais Princípios e Práticas", Bookman, 2001.