

# Statistics, Coverage, and Improvement of Modelling via ANN of Radio Mobile Signal in Vegetated Channel in the 700-4000 MHz Band

Pedro A. Vieira, *Senior member, IEEE*, Leni J. Matos, *Member, IEEE*, Pedro V. G. Castellanos, Leonardo H. Gonsioroski, and Edson Cataldo

**Abstract**—In communication system design, predicting radio signal coverage in channels with vegetation is challenging due to the way vegetation absorbs, reflects, spreads, and depolarizes the signal. Empirical models have been developed to predict signal coverage in these channels, such as parks and urban squares with vegetation, which are common in cities. To study these scenarios, this paper presents narrowband measurements taken in a public square with varied vegetation, using five carrier frequencies in the 700-4000 MHz band, including those used for cellular services, Wi-Fi 6 (Wireless Fidelity), and 5G (Fifth Generation) networks. Two transmitter antenna heights were used, and the measured data were analyzed graphically and quantitatively. The study found that an artificial neural network improved the signal prediction beyond that of the log-distance model, which is the basic model with the best results. Therefore, it can be used understand and model this kind of environment.

**Index Terms**—Artificial neural network, channel characterization, channel sounding, path loss, prediction models, propagation in vegetation.

## I. INTRODUÇÃO

Nos sistemas de comunicação móvel, o ambiente de propagação do sinal se altera constantemente devido à mobilidade do receptor e ao ambiente ao redor do sistema, ocasionando consideráveis alterações no sinal recebido. Para o planejamento do sistema, é de grande importância o conhecimento dessa variação de sinal para definir a qualidade cobertura do sistema de comunicação, de forma que o nível do sinal no receptor esteja adequado para utilização.

Em canais onde a vegetação é mais presente, geralmente não homogênea devido aos diversos tipos de árvores, arbustos e plantas, a qualidade de cobertura do sinal sofre a influência dos mecanismos de propagação e depende do comprimento de onda do sinal transmitido. Nestes locais, o desafio é manter boa cobertura do sinal de rádio móvel em diferentes cenários de recepção. Desta forma, os espalhadores distribuídos aleatoriamente, como folhas, ramos, galhos e troncos de árvores, além de prédios, pessoas e veículos, por exemplo, podem causar efeitos como reflexão, espalhamento, difração e absorção das ondas eletromagnéticas, resultando em múltiplos percursos do sinal transmitido, podendo levar a uma rápida degradação do sinal no interior e ao redor das áreas com vegetação.

Muitos autores têm caracterizado a perda do sinal de rádio devido à presença da vegetação [1]-[3], com algumas pesquisas analíticas e resultados significativos relatados em Bertoni [4]. Os modelos que fornecem previsão de propagação para parques e praças, em geral, tratam da atenuação em ambientes com vegetação densa e concentrada, como em florestas [5]-[8]. Pouco

se sabe sobre ambientes com vegetação mais rala ou com média e baixa densidade, tal como a encontrada em parques urbanos [9]-[10], estacionamentos [3] e [11] e ruas com pouca arborização enfileirada, onde existem áreas abertas e algumas árvores [12]. Geralmente, o que se constata é que, quando os modelos tradicionais, desenvolvido para um cenário com vegetação, são aplicados em outros, não apresentam bons resultados.

Para um melhor entendimento desse tipo de ambiente com vegetação, de alta complexidade e aleatoriedade, realizam-se sondagens do sinal de rádio móvel para estudar seu comportamento. Castro [12] partiu do modelo log-distância e desenvolveu um modelo com base em medições realizadas em regiões de cidades amazônicas, com ruas arborizadas. Mello [9] realizou medições envolvendo clareiras, vegetação lateral e alguma vegetação no percurso, desenvolvendo um modelo para parque urbano na faixa de 900-2400 MHz. Esse modelo foi aplicado no Jardim Botânico do Rio de Janeiro, nas condições de [13], e mostrou excelente ajuste aos dados obtidos das medições em 1880 MHz. A maioria dos modelos consagrados são exponenciais ou se baseiam no modelo log-distância.

Neste contexto, este estudo tem como objetivo caracterizar o canal de propagação rádio móvel em ambientes com vegetação em cinco frequências: 705 MHz, 1790 MHz, 2400 MHz, 3500 MHz e 4000 MHz, utilizando dados de [14]. São analisadas as estatísticas de desvanecimento (*fading*) de sinal no canal e determinada a perda de percurso (*path loss*) em diferentes configurações. Realiza-se também uma análise quantitativa e gráfica da aderência do *path loss* ao modelo log-distância. Para aprimorar a predição, foi estudada a modelagem com a utilização de redes neurais artificiais (RNA), o que demonstrou redução do erro de predição no ambiente estudado, comparado ao modelo de referência log-distância. Este trabalho contribui, adicionalmente, com diversos outros estudos que utilizam RNA na análise da cobertura e obtenção do *path loss*, como, por exemplo, os estudos apresentados para ambientes internos em [15] e ambientes externos em [16], [32] e [33]. Contudo, diferencia-se ao realizar medições em ambiente com vegetação, em área urbana, em cinco frequências e duas alturas de antena, parâmetros também utilizados como parte da camada de entrada da RNA, e analisar a inclusão da identificação do ambiente, com o objetivo de avaliar a obtenção de um único modelo abrangente para todo o local estudado e verificar a capacidade de generalização da RNA para valores não utilizados no seu treinamento.

Na continuidade, este artigo apresenta a descrição do ambiente de medições e das rotas percorridas, na Seção II; as estatísticas de sinal, através da análise das distribuições relativas à variabilidade em pequena e grande escala, estão na Seção III; o cálculo da perda no percurso, a descrição de modelos usuais de previsão de sinal rádio em vegetação e sua aderência a *path loss*, estão na Seção IV. A descrição da arquitetura da rede neural escolhida bem como seu treinamento e sua aplicação, com os resultados finais, estão na Seção V, enquanto a Seção VI apresenta as conclusões, comentários e proposta de trabalhos futuros.

## II. AMBIENTE DE MEDIÇÕES E SISTEMA DE SONDAÇÃO

As medições ocorreram na Praça Nilo Peçanha, situada na Rua Passo da Pátria, S/N, São Domingos, Niterói, um ambiente com vegetação variada em altura e espécie. Algumas áreas com maior concentração de árvores, outras com pouca vegetação e algumas sem árvores (clareiras). A praça está rodeada por construções e ruas com moderada movimentação de veículos e pedestres, situação típica de um parque urbano. A Fig. 1 apresenta uma visão superior da praça, mostrando as duas rotas e suas geometrias, selecionadas para medição, que abrangem diferentes áreas da praça. A região comum às duas rotas, comprimento de 21,98 m, apresenta visada para a antena transmissora.

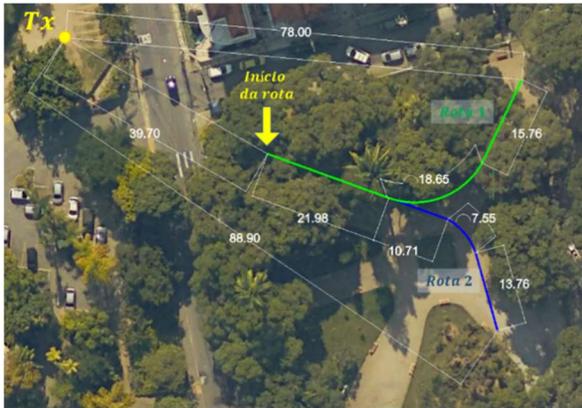


Fig.1. Vista aérea da praça destacando as rotas de medições [16].

As distâncias do ponto inicial e final da rota 1 à antena transmissora foram, respectivamente, 39,7 metros e 78 metros. Para a rota 2, tais distâncias foram 39,7 metros e 88,9 metros. A antena transmissora foi colocada na entrada do Campus Praia Vermelha da Universidade Federal Fluminense, fora da praça, devido às facilidades de fornecimento de energia e segurança, oferecidas pela própria universidade.

A velocidade média de deslocamento foi mantida praticamente constante em 1 m/s, de forma que o intervalo de tempo de duração das medições, em cada rota, fosse proporcional ao deslocamento do móvel.

O sistema de sondagem para medir os sinais CW (*Continuous Wave*) empregou os equipamentos, dispositivos e acessórios listados na Tabela I, com o sistema receptor montado sobre um carrinho [14] que se deslocava, percorrendo as rotas, enquanto as medidas eram capturadas.

TABELA I  
ESPECIFICAÇÕES DO SISTEMA TRANSMISSOR E RECEPTOR [16]

Equipamento/dispositivo	Especificações
Gerador vetorial de Sinal MG3700A, Anritsu	250 kHz a 6 GHz
Amplificador de potência ZHL-16W-Ganho: de 40 a 47dB para a faixa de 43+, Minicircuits	700-4000 MHz
Fonte Digital PS-5000, Icel	2 fontes de 0-30 V/ 3 A e 1 de 0 - 5V/3 A
Tx Antena OmniI-ATO-380- 6000, RFS	Ganho:1 dB/705 MHz, 5dB/1.79 GHz, 6 dB/2400, 3500, 4000 MHz
Cabo Anritsu, de 1 m	50 Ω (gerador p/ o Amplificador de Potência - PA)
Cabo R&S, de 1,7 m	50 Ω (PA p/ antena Tx)
Cabo Nacional, de 1 m	Cabo adicional (PA p/ antena Tx) para altura da antena Tx de 4,2 m
Antena Multi Band Omni MA-CQ27-1X, 380MHz-6GHz, MARS	Ganho:3 dB/705 MHz, 5dB/1.79 GHz, 6 dB/2400,3500, 4000 MHz
Rx Analisador de Sinal MS2692A, Anritsu	50Hz - 26,5GHz
Cabo Anritsu de 1 m	50 Ω (antena Rx p/analizador)

No dia da medição, o céu estava claro e não choveu. Havia uma circulação baixa de pedestres na praça e uma considerável circulação de veículos no seu entorno. Foram transmitidos e medidos, em tempos diferentes, os cinco sinais CW: 705, 1790, 2400, 3500 e 4000 MHz; em duas alturas de antena transmissora (Tx), em 1,7 m e 4,2 m; e uma antena de recepção (Rx) com uma altura fixa de 1,59 m.

## III. ESTATÍSTICAS DO CANAL SONDAÇÃO

Para cada frequência e altura de transmissão, foi medido o sinal recebido ao longo de cada rota, observando-se variabilidade devido, principalmente, ao multipercurso. Usando as especificações para cada combinação: rota (R1 ou R2), altura de Tx (H1 ou H2) e frequência (F1 a F5), montou-se a Tabela II, onde R refere-se à rota, H à altura de Tx e F, à frequência portadora CW. Como exemplo: R1H1F1 se refere a rota 1, na altura de Tx 1 (= 1,7 m) e frequência 1 (= 705 MHz). Um total de 20 configurações foram medidas.

TABELA II  
ESPECIFICAÇÕES DAS MEDIÇÕES REALIZADAS

Frequência (MHz)	Rota/Altura antena Tx			
	1/ H1	1/ H2	2/H1	2/H2
705	R1H1F1	R1H2F1	R2H1F1	R2H2F1
1790	R1H1F2	R1H2F2	R2H1F2	R2H2F2
2400	R1H1F3	R1H2F3	R2H1F3	R2H2F3
3500	R1H1F4	R1H2F4	R2H1F4	R2H2F4
4000	R1H1F5	R1H2F5	R2H1F5	R2H2F5

Com analisador de sinais, usado como analisador de espectro, configurado em *Span Zero*, foram realizadas as medições do sinal. Um *software* de captura, desenvolvido em Matlab, coletou o *trace* da medida, fornecendo 10.001 pontos de medição por varredura, que teve duração de 60 segundos e taxa de amostragem de 10.000 amostras/min (= 166,67 amostras/s).

A Fig. 2 exemplifica o sinal medido R1H2F2, na rota (R1), altura de antena (H2), na frequência F4, à medida que o sistema

de recepção se afastava da transmissão, e destaca a aderência do modelo log-distância, que será analisada na próxima seção.

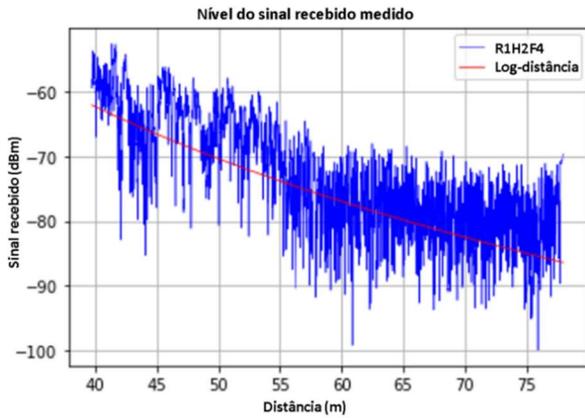


Fig. 2. Nível de sinal em R1H2F4 e modelo log-distância ajustado.

A potência recebida é modelada como uma combinação de *path loss*, desvanecimento (ou variabilidade) em grande e pequena escala [17]-[22]. Para a obtenção das estatísticas foi empregado o processo de setorização [4] e [18], dividindo o sinal medido em 30 setores e tomando a média local do sinal em cada setor para os 20 conjuntos de medidas, formando 30 setores em cada rota, como mostrado na Fig. 3.

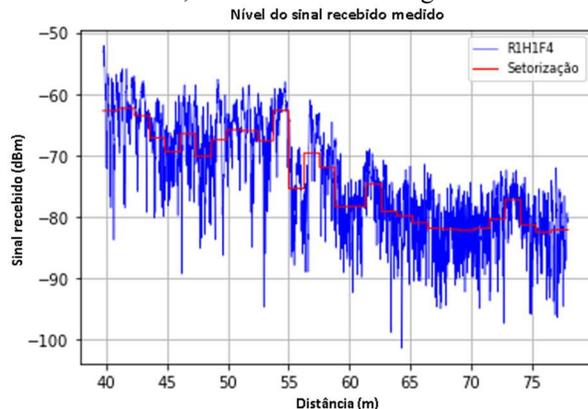


Fig.3. Exemplo de nível de sinal medido em R1H1F4: variação em pequena escala e setorização.

Em cada setor foi tomada uma média das amostras de modo a se obter um sinal de sombreamento (SO) como uma média local [18]. A partir de SO, foi obtida a curva de ajuste que representa o ganho de percurso (*path gain* – PG) ou, inversamente, a *path loss* (PL) [4], após calculado o balanço de potência com os dados do sistema, para cada frequência e altura de antena, ao longo da rota. Ao subtrair o SO do sinal medido, obtém-se apenas o sinal de variabilidade em pequena escala. Dos dados deste sinal, obtém-se o histograma e, através da utilização de algoritmos da biblioteca *SciPy* [19] para linguagem *Python*, determinam-se funções densidade de probabilidade (*probability density function*) f.d.p. que apresentam o melhor ajuste ao sinal de pequena escala verificado pela soma dos quadrados residuais (*residual sum of squares*– RSS). A Fig. 4 apresenta a PL das medições da rota 1,

onde pode ser verificada sua dependência com distância, frequência e altura de antena de transmissão.

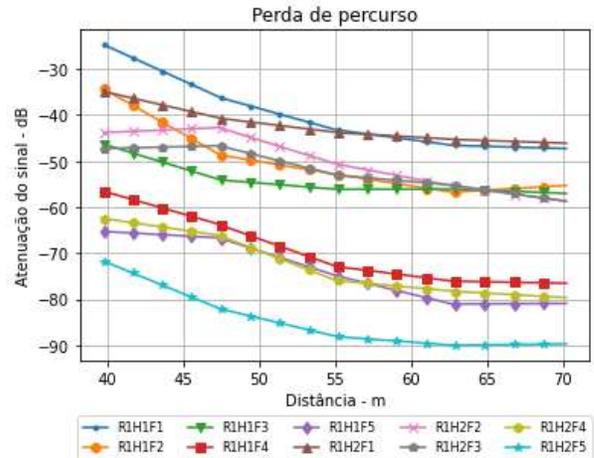


Fig.4. Perda de percurso para cada medição da rota 1.

Ao se subtrair SO de PL, obtém-se a variabilidade em grande escala, que conduz à f.d.p. de melhor ajuste de sinal. A f.d.p. normal, vista na Fig. 5, apresentou melhor ajuste à variabilidade do sinal em grande escala na maioria das rotas, seguida da lognormal em todos os conjuntos. É um resultado encontrado, usualmente, para este tipo de desvanecimento [20]-[22].

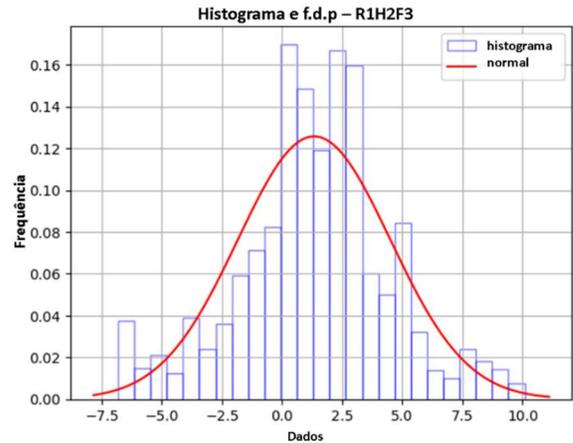


Fig.5. Histograma e f.d.p. ajustada à variabilidade em grande escala e f.d.p. de melhor ajuste (normal) para a rota para um setor típico: R1H2F3.

Para o desvanecimento em pequena escala, a f.d.p. normal foi a que apresentou o melhor ajuste em cerca de 38% de todos os 600 setores estudados. Na Tabela III estão os resultados para a medição R1H2F3, onde se verifica a f.d.p. Nakagami em 30% dos setores, a lognormal em 20%, a Rice com 9% e a Rayleigh com 3%. Observa-se assim, que o comportamento do canal é variado em vista de diferentes situações, entretanto, o sinal direto, mesmo quando atenuado pela vegetação, ainda chegava com forte nível, pois em apenas 3% dos setores tiveram ajuste à f.d.p. Rayleigh, indicando que os multipercursos eram dominantes.

TABELA III	
F.D.P. DE MELHOR AJUSTE PARA OS SETORES DA ROTA R1H2F3	
f.d.p.	Quantidade de melhor ajuste por RSS
Normal	16

Nakagami	8
Lognormal	4
Rayleigh	1
Rice	1
Total setores	30

#### IV. PATH LOSS E MODELOS DE PREDIÇÃO PARA AMBIENTES VEGETADOS

Com a perda de percurso obtida do nível médio da potência medida (em dBm) e dos parâmetros do sistema, foi avaliado o desempenho de modelos de predição em termos da *Root Mean Square Error* (RMSE). Para canais com vegetação, em geral, são encontrados na literatura modelos empíricos e exponenciais, alguns destes avaliados neste estudo.

##### A. Modelos de Predição de Sinal Rádio em Meios Vegetados

###### 1) Log-Distância

Dentre os modelos encontrados, o log-distância [22], em (1) é o de melhor ajuste, pois parte dos dados de medição para determinar a perda do sinal com a distância.

$$P_r(d) = P_r(d_0) + 10 \cdot n \cdot \log(d/d_0) \quad (1)$$

O modelo log-distância apresenta uma dependência linear com o logaritmo da distância relativa ( $\log(d/d_0)$ ), onde  $d$  é a distância entre Tx e Rx,  $d_0$  é a distância inicial de referência de Tx.,  $P_r(d)$  é a perda de sinal em  $d$ ,  $P_r(d_0)$ , é a perda no ponto de referência  $d_0$  e  $n$  é o coeficiente de perda (ou fator de atenuação), calculado por (2).

$$n = [P_r(d) - P_r(d_0)] / 10 \cdot \log(d/d_0) \quad (2)$$

###### 2) ITU-R

O modelo ITU-R, em (3), também conhecido como *Early ITU* [23], é empírico, desenvolvido pela ITU, em 1988, válido para frequências entre 200 MHz e 95 GHz e para distâncias entre Tx e Rx inferiores a 400 m. Sua equação fornece a perda em excesso (em dB), devido à vegetação, que deverá ser adicionada à perda no espaço livre para calcular a perda total.

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

onde  $A_{ITU-R}$  é a atenuação em excesso segundo o modelo,  $d$  é a distância que o sinal adentra na vegetação, ou seja, profundidade da vegetação (m), e  $f$  é a frequência de operação do sistema (MHz).

###### 3) FITU-R (Fitted ITU-R)

Para distâncias menores que 120 m, um modelo ajustado ao ITU-R foi proposto [24], onde a perda em excesso na vegetação, em dB, é calculada por (4) e (5), onde  $f$  é a frequência em MHz, e  $d$  é a profundidade da vegetação em m.

$$A = 0,39 \times f^{0,39} d^{0,2} \text{ com folhas} \quad (4)$$

$$A = 0,39 \times f^{0,18} d^{0,59} \text{ sem folhas} \quad (5)$$

###### 4) Weissberger

Weissberger desenvolveu o modelo de perda de propagação conhecido como exponencial modificado (MED), válido para ambientes com vegetação, com árvores que possuem folhagem seca em climas temperados [25]. Este modelo foi desenvolvido

para a faixa de frequências de 230 MHz a 95 GHz, e teve seus parâmetros empíricos determinados em campanhas de medições que utilizaram a faixa UHF (400-700 MHz). Neste modelo, a perda em excesso, em relação a perda no espaço livre ( $L_0$ ), ocasionada pela vegetação, é expressa em (6) e (7), onde são definidos:  $L(\text{dB})$  como atenuação em excesso (dB),  $d$  como distância que o sinal adentra a vegetação, ou seja, profundidade da vegetação (m), e  $f$  é frequência de operação do sistema (GHz).

$$L(\text{dB}) = 0,45 (f)^{0,284} d, \text{ para } d \leq 14 \text{ m} \quad (6)$$

$$L(\text{dB}) = 1,33(f)^{0,284} d^{0,588}, \text{ para } 14 \leq d \leq 400 \text{ m} \quad (7)$$

###### 5) Chen and Kuo

Elaborado no início da década de 90 por Chen e Kuo [26], para ambientes florestais, na faixa de 1 a 100 GHz, é fundamentado na teoria geométrica da difração, com o meio modelado através de 4 camadas: ar, copa, tronco de árvores e solo. Medições espaçadas de 10 m, com polarizações verticais e horizontais, foram realizadas e a perda na polarização vertical ( $L_v$ ) e horizontal ( $L_h$ ) estão em (8) e (9) respectivamente.

$$L_v = (0,001f + 0,2)d + 0,5f + 3, \text{ polarização vertical} \quad (8)$$

$$L_h = (0,001f + 0,2)d + 0,5f + 3, \text{ polarização horizontal} \quad (9)$$

###### 6) Espaço Livre

Conhecida como equação de Friis [20] para a perda de sinal em ambiente sem multipercurso e obstruções, a perda no espaço livre ( $L_0$ ), a ser somada nas perdas dos modelos exponenciais, é dada por (10), onde  $d$  é a distância entre as antenas transmissora e receptora, (km), e  $f$  é a frequência da portadora transmitida (MHz).

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

##### B. Perda no Percurso – Path Loss

O coeficiente de perda,  $n$ , foi calculado a partir de (2) para cada combinação possível da Tabela II. Os resultados obtidos estão na Tabela IV, para o total das 20 combinações.

Na Tabela V, estão os resultados comparativos da média dos coeficientes da rota 1 e da rota 2. O valor de  $n$  apresenta diminuição na média quando se altera da rota 1 (R1) para rota 2 (R2), passando de 7,27 para 5,13 para H1 e de 6,41 para 4,18 para H2. Na rota R1 temos mais obstrução de vegetação, como se vê na Fig. 1, e pouca área aberta ao longo do percurso, se comparada à rota R2, que apresenta maior área de clareira no seu caminho. Na análise de uma mesma rota, comparado H1 com H2, percebe-se que a média dos valores de  $n$  diminuem com o aumento da altura, passando de 7,27 para 6,41 para a R1 e de 5,13 para 4,18 para a R2. Isto indica que o aumento na altura de transmissão ocasiona um aumento do nível médio de potência recebida, o que vem confirmar as afirmativas encontradas nos modelos consagrados encontrados na bibliografia [22] e na portaria da Anatel [27].

TABELA IV  
COEFICIENTES DE PERDA PARA AS DIFERENTES COMPOSIÇÕES

Medição	Fator $n$		Medição	Fator $n$	
Altura H2	Rota 1	Rota 2	Altura H1	Rota 1	Rota 2

H1F1	8,96	6,44	H2F1	3,37	6,68
H1F2	7,36	7,26	H2F2	8,01	4,09
H1F3	2,46	4,14	H2F3	5,86	2,95
H1F4	9,10	3,14	H2F4	8,10	2,82
H1F5	8,45	4,65	H2F5	6,69	4,35

TABELA V  
RESULTADO COMPARATIVO DAS MÉDIAS DO COEFICIENTE

Medição	Rota 1	Rota 2	Diferença na rota
Média H1	7,27	5,13	2,14
Média H2	6,41	4,18	2,23

### C. Ajuste dos Modelos

Ao ajustar os níveis de sinal dos modelos citados nas vinte configurações, foi verificado que o modelo log-distância, como era de se esperar, apresentou o menor RMSE [11], conforme Tabela VI. Os modelos de Cheng and Kuo [26] e Weissberger [25], são mais otimistas, enquanto que os FITU-R [24] e Early ITU [23] são menos otimistas, mas todos são otimistas frente à atenuação real medida, conforme pode ser visto na Fig. 6.

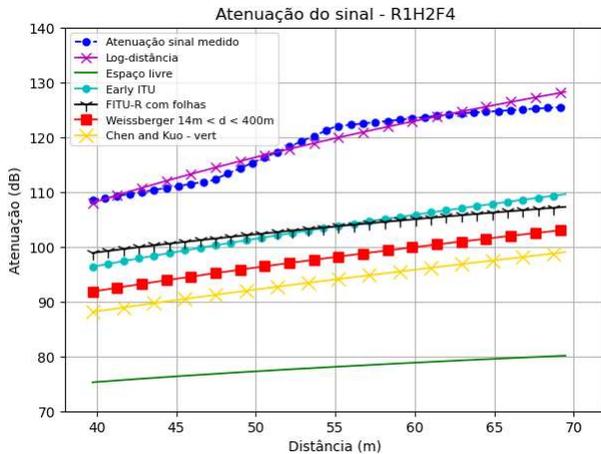


Fig.6. Comparação dos modelos aplicados na configuração R1H2F4.

Na Tabela VI estão os resultados do RMSE onde se observa menor valor para o modelo log-distância.

Uma alternativa na melhoria de predição da *path loss* é a modelagem utilizando uma RNA, a ser tratada na próxima seção. Foi escolhido o modelo log-distância, melhor ajustado, como parâmetro de referências para avaliação.

TABELA VI

VALOR DO RMSE EM RELAÇÃO A *PATH LOSS* OBTIDA DO SINAL MEDIDO

Rota de medição	Espaço livre	Log-Distância	Early ITU	FITU-R com folhas	Weissberger (14 < d < 400)	Chen and Kuo pol. Vert.
R1H1F1	15,27	1,71	4,22	4,87	4,58	3,79
R1H1F2	23,07	2,17	3,72	5,11	7,10	8,40
R1H1F3	25,85	1,38	3,56	4,02	8,07	10,66
R1H1F4	38,09	1,42	12,66	12,94	18,18	22,16
R1H1F5	40,93	1,33	14,39	14,28	20,22	24,71
R1H2F1	16,59	1,05	1,14	3,15	3,99	2,35
R1H2F2	22,05	1,38	2,46	3,93	5,87	7,20
R1H2F3	23,31	1,00	1,02	2,12	5,43	7,99
R1H2F4	41,02	1,33	15,53	15,69	21,08	25,08
R1H2F5	52,20	1,80	25,67	25,38	31,49	36,00

## V. REDE NEURAL ARTIFICIAL: APLICAÇÃO E RESULTADO

Para encontrar o melhor modelo de RNA para o ambiente estudado, foram feitos treinamentos e testes de várias

configurações de hiperparâmetros, tais como a quantidade de camadas ocultas, neurônios por camada e funções de ativação. Para cada configuração, o valor de RMSE foi calculado e comparado ao modelo de referência log-distância.

Para a construção da RNA, foram utilizadas bibliotecas *Scikit-Learn* [28] e *Keras* [29], escritas em *Python* (v.3.10.4) utilizando *IDE Spyder* (v.5.3.3) e bibliotecas *Numpy*, *Matplotlib* e *Pandas*. A arquitetura da rede adotada foi MLP (*Multilayer perceptron*) *feedforward backpropagation*, empregando o algoritmo de otimização *Adam* [30], formando uma RNA/MLP.

A estratégia de escolha da RNA, para servir como modelo de avaliação, foi a que apresentou o menor RMSE, com a menor arquitetura, em termos de quantidade de camadas ocultas e neurônios em cada camada, função de ativação de menor complexidade e que tenha apresentado um desempenho melhor que o modelo de referência sem sobre ajustamento (*overfitting*).

### A. Arquitetura da RNA

A arquitetura geral de uma RNA é composta de uma camada de entrada, camadas ocultas e uma camada de saída. Os dados da camada de entrada foram: a altura da antena, a frequência do sinal e a distância de Tx até cada ponto de Rx na rota. A camada de saída foi composta por apenas um neurônio, que será o sinal medido, do qual é obtida a *path loss*. Os neurônios, tanto da camada oculta como de saída, possuem funções de ativação com a finalidade restringir a amplitude do sinal de saída a um valor finito. A utilização de funções de ativação nas camadas ocultas permite o aprendizado de funções não lineares e mais complexas. Nestas camadas, foram avaliadas as funções de ativação: linear, *ReLU* e *sigmoide*. No neurônio de saída, como se desejava obter um número, foi utilizada a função de ativação linear [31].

Para o treinamento da RNA, os hiperparâmetros foram mantidos nos valores padrões das bibliotecas e, quando foi avaliada a necessidade de algum ajuste, estes foram anotados para fazer parte da especificação do modelo.

### B. Dados de Entrada e Treinamento das Redes

Os dados das amostras de entrada de cada rota de medição foram unidos e aleatoriamente misturados, formando dois conjuntos de dados, um para o treinamento do modelo de RNA para a rota 1 e outro para a rota 2.

A fase de treinamento da rede é quando ocorre a aprendizagem com a obtenção dos pesos e vieses (*bias*) para uma dada arquitetura e onde conjuntos de dados de entradas e suas respectivas saídas são usados para treinar a rede através do algoritmo. Inicialmente os dados foram separados em um conjunto de treinamento (60%) e outro de teste (40%). Após obtida uma arquitetura inicial de referência, com menor RMSE, foi feita uma validação cruzada com a técnica *k-fold* e verificação da ocorrência *underfitting* ou *overfitting*. Também foi feita uma avaliação da busca dos melhores hiperparâmetros e arquitetura em processo de *gridsearch*. Estas etapas foram realizadas diversas vezes de modo iterativo até que se obtivesse

a arquitetura e hiperparâmetros julgadas mais adequados dentro da estratégia de escolha da RNA.

Foram treinadas e avaliadas as RNA para os seguintes cenários: 1) modelo de RNA treinado com os dados da rota 1; 2) modelo de RNA treinado com os dados da rota 2; e 3) modelo de RNA treinado com os dados das rotas 1 e 2. Para cada modelo de RNA foram avaliados os resultados com a aplicação dos dados medidos das rotas 1 e 2 e calculado o RMSE. Também foi verificada a capacidade de generalização da RNA para valores não treinados.

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

Primeiramente, foram calculados os valores do RMSE em cada ponto ao longo da rota, entre as potências previstas pelo modelo log-distância (LD) e as potências médias recebidas do sinal medido. Em seguida, para cada configuração de RNA foram calculados os valores de RMSE entre as potências previstas pelo modelo da RNA e as potências médias recebidas do sinal medido. A comparação final foi feita entre os valores de RMSE dos modelos da RNA e LD.

**D. Resultados**

No treinamento da RNA, foram utilizados todos os dados de entrada de ambas as rotas e traçados os gráficos comparativos entre a saída do modelo da RNA e a previsão do modelo LD.

O modelo de RNA que apresentou o melhor resultado, menor RMSE, em relação ao modelo LD, foi o modelo treinado com dados da rota e avaliados com as medições individuais na mesma rota. A Tabela VII mostra os resultados para o modelo treinado com dados da rota 1 e avaliado com estes mesmos dados e os percentuais de melhoria de previsão com o emprego da RNA em relação ao modelo LD.

TABELA VII

RMSE DO RESULTADO DO MODELO DA RNA TREINADA COM ROTA 1 E DO MODELO LD PARA MEDIÇÕES DA ROTA 1

Medição	Arranjo	RMSE RNA	RMSE LD	% de melhoria
R1H1F1	[8, 5]	0,83	1,71	51,5%
R1H1F2	[8, 5]	1,36	2,17	37,3%
R1H1F3	[8, 5]	0,75	1,38	45,7%
R1H1F4	[8, 5]	0,33	1,42	76,8%
R1H1F5	[8, 5]	1,03	1,33	22,6%
R1H2F1	[8, 5]	0,46	1,05	56,2%
R1H2F2	[8, 5]	1,13	1,38	18,1%
R1H2F3	[8, 5]	0,44	1,00	56,0%
R1H2F4	[8, 5]	1,04	1,33	21,8%
R1H2F5	[8, 5]	0,92	1,80	48,9%

A arquitetura final foi: três entradas; duas camadas ocultas com 8 e 5 neurônios em cada camada (arranjo); e uma saída, o nível de potência esperado para a distância ao Tx. Desses resultados, pode ser constatada a melhoria de previsão com a utilização da RNA, em relação ao modelo LD, dependendo de altura de antena e da frequência. Os demais hiperparâmetros no modelo são apresentados na Tabela VIII. Na Fig. 7, tem-se o gráfico comparativo do conjunto de medidas da rota R1, R1H1F1, aplicado na rede treinada na mesma rota. Pelo fato de a RNA ter sido treinada com dados da rota R1, era esperado que seu comportamento fosse muito próximo aos da medição.

TABELA VIII

RELAÇÃO DE HIPERPARÂMETROS

Hiperparâmetros	Valor	Hiperparâmetros	Valor
<i>activation</i>	ReLU	<i>learning_rate_init</i>	0.00025
<i>batch_size</i>	auto	<i>tolerance</i>	0.001
<i>epsilon</i>	1,00E-08	<i>max_fun</i>	15000
<i>hidden_layer_sizes</i>	[8, 5]	<i>max_iter</i>	20000
<i>learning_rate</i>	<i>adaptive</i>	<i>solver</i>	Adam

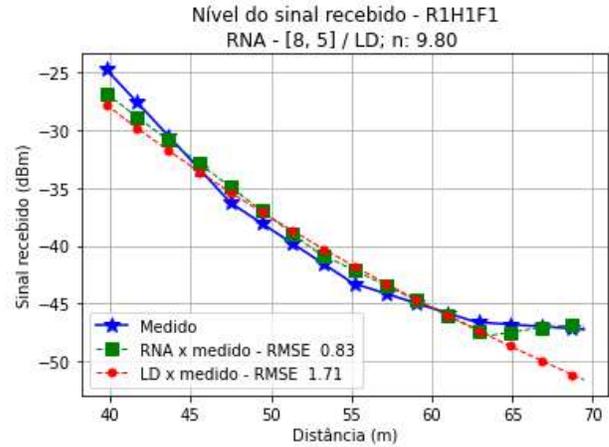


Fig. 7. Comparação entre os dados de saída da RNA com os obtidos nas medições de R1H1F1 e com a previsão dada pelo modelo LD.

A aplicação dos dados da rota 2 no modelo obtido com o treinamento dos dados da rota 1 é visto na Fig. 8. Pode ser verificado que o resultado foi muito inferior ao obtido com os dados da rota 1 aplicado ao modelo treinado com os dados desta mesma rota 1.

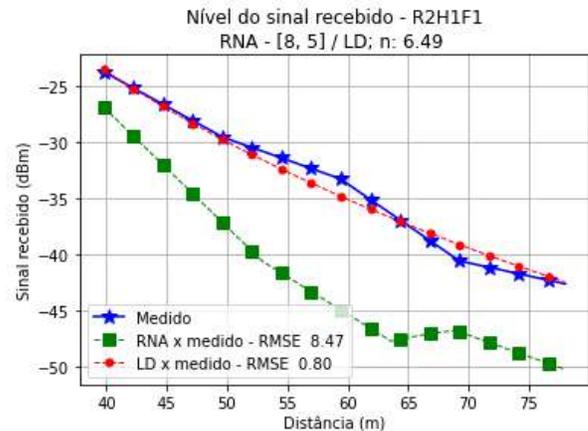


Fig. 8. Comparação entre os dados de saída da RNA com os obtidos nas medições de R2H1F1 e com a previsão dada pelo modelo LD.

Num segundo cenário, o modelo foi treinado com os dados da rota 2 e avaliados para os mesmos dados da rota 2. Também houve melhoria com a aplicação da RNA, exceto para a rota R2H2F4, conforme apresentado na Tabela IX. Estes resultados foram obtidos com os mesmos hiperparâmetros da Tabela VIII, exceto a tolerância (*tolerance*), alterada para 0,00175.

A avaliação do modelo treinado para a rota 2 com os dados da rota 1, da mesma forma, não apresentou resultados satisfatórios, como era de se esperar.

TABELA IX

RMSE DO RESULTADO DO MODELO DA RNA TREINADA COM ROTA 2 E DO MODELO LD PARA MEDIÇÕES DA ROTA 2

Medição	Arranjo	RMSE RNA	RMSE LD	% de melhoria
R2H1F1	[8, 5]	0,57	0,80	29,5%
R2H1F2	[8, 5]	1,16	2,90	59,9%
R2H1F3	[8, 5]	0,72	0,88	18,4%
R2H1F4	[8, 5]	0,95	2,90	67,2%
R2H1F5	[8, 5]	1,23	3,28	62,5%
R2H2F1	[8, 5]	0,31	0,97	67,9%
R2H2F2	[8, 5]	0,94	1,08	13,2%
R2H2F3	[8, 5]	1,03	1,17	11,3%
R2H2F4	[8, 5]	2,07	1,71	-20,9%
R2H2F5	[8, 5]	0,92	1,03	10,6%

Num terceiro cenário, um modelo foi treinado com os dados das rotas 1 e 2. Inicialmente, considerando os mesmos hiperparâmetros da Tabela VIII. Como não houve melhoria em relação ao modelo LD, foi feita a inclusão da identificação da rota, como quarto parâmetro de entrada, representando a segmentação do ambiente com classificação R1 ou R2, de acordo com a rota. Neste caso, houve melhoria na aderência para algumas rotas, sendo mais significativas para a rota 2, conforme apresentado na Tabela X e exemplo de uma rota mostrado na Fig. 9.

TABELA X

RMSE DO RESULTADO DO MODELO DA RNA TREINADA COM ROTA 1 E 2 E DO MODELO LD PARA MEDIÇÕES DA ROTA 2 – [8, 5]

Medição	Arranjo	RMSE RNA	RMSE LD	% de melhoria
R2H1F1	[8, 5]	0,77	0,80	4,7%
R2H1F2	[8, 5]	1,30	2,90	55,0%
R2H1F3	[8, 5]	0,72	0,88	17,8%
R2H1F4	[8, 5]	1,27	2,90	56,3%
R2H1F5	[8, 5]	1,28	3,28	60,9%
R2H2F1	[8, 5]	0,72	0,97	26,2%
R2H2F2	[8, 5]	1,82	1,08	-68,2%
R2H2F3	[8, 5]	2,42	1,17	-107,8%
R2H2F4	[8, 5]	2,04	1,71	-19,1%
R2H2F5	[8, 5]	0,51	1,03	50,5%

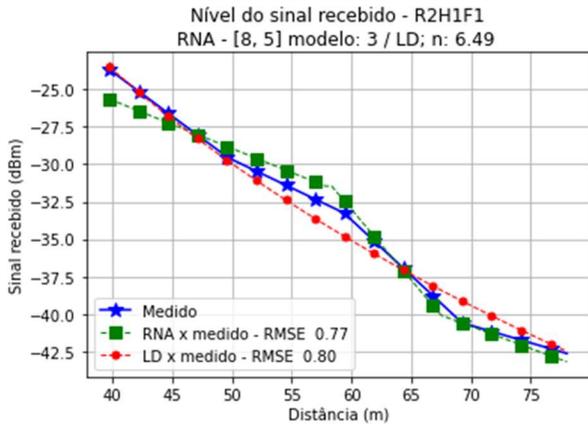


Fig. 9. Modelos treinado com dados das rotas 1 e 2 e avaliado para a rota R2H1F1.

Para avaliar a possibilidade de um melhor desempenho, a arquitetura de RNA foi alterada para: 4 entradas (mesmo da arquitetura anterior), arranjo das camadas ocultas com 11 e 7 neurônios e uma saída, mantendo os mesmos hiperparâmetros da Tabela VIII. Esta alteração na quantidade de neurônios nas camadas ocultas mostrou melhoria no desempenho, tanto para

aplicação do modelo para os dados da rota 1 quanto para a rota 2, conforme resultado mostrado na Tabela XI e Fig. 10.

TABELA XI  
RMSE DO RESULTADO DO MODELO DA RNA TREINADA COM ROTAS 1 E 2 E DO MODELO LD PARA MEDIÇÕES DA ROTA 2

Medição	Arranjo	RMSE RNA	RMSE LD	% de melhoria
R2H1F1	[11, 7]	0,56	0,80	30,0%
R2H1F2	[11, 7]	0,59	2,90	79,5%
R2H1F3	[11, 7]	0,86	0,88	1,8%
R2H1F4	[11, 7]	1,20	2,90	58,7%
R2H1F5	[11, 7]	1,36	3,28	58,4%
R2H2F1	[11, 7]	0,41	0,97	58,3%
R2H2F2	[11, 7]	0,52	1,08	52,1%
R2H2F3	[11, 7]	0,40	1,17	66,0%
R2H2F4	[11, 7]	0,97	1,71	43,3%
R2H2F5	[11, 7]	1,43	1,03	-38,9%

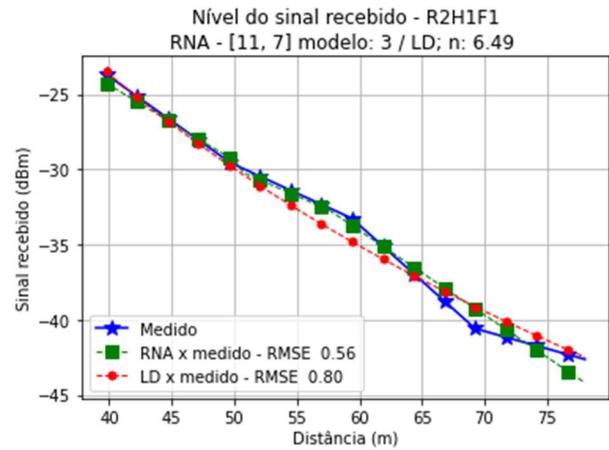


Fig. 10. Modelos treinados com dados das rotas 1 e 2, avaliado para a rota R2H1F1.

Outra análise feita foi a verificação da capacidade da RNA em generalizar resultados para outras frequências e alturas de antena. Os melhores resultados foram obtidos quando os novos valores estavam entre os limites treinados. A Fig.11 mostra um dos exemplos calculados para altura (H) de 3,7 m, não utilizada em treinamento, e frequência (F) de 4 GHz (tracejado em preto).

## VI. CONCLUSÕES E TRABALHOS FUTUROS

Este artigo apresenta os resultados de medições realizadas em uma praça com vegetação, visando caracterizar o canal de rádio móvel nesse ambiente. Foram avaliadas as estatísticas de desvanecimento, tanto lento quanto rápido, e determinada a perda de percurso (*path loss*). Através de comparações com modelos empregados para esse tipo de canal, constata-se que o modelo log-distância possui melhor aderência, evidenciada por um menor RMSE, uma vez que esse modelo utiliza o parâmetro  $n$ , derivado das próprias medições.

No entanto, é possível buscar melhorias em relação a esse modelo, e o uso de RNA se mostra uma alternativa viável para a modelagem desse tipo de canal. Dessa forma, RNA do tipo MLP *feedforward backpropagation* foram desenvolvidas. A estratégia para modelar RNA envolveu a seleção daquela com menor RMSE em comparação ao modelo de referência, considerando também a menor arquitetura em termos de

quantidade de camadas ocultas e número de neurônios nessa camada.

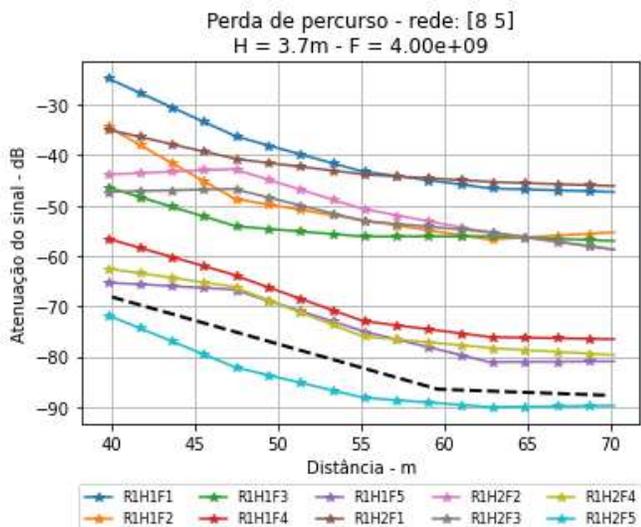


Fig. 11. Exemplo de cálculo com modelo de RNA para altura não utilizada em treinamento.

Foram conduzidas várias rodadas de treinamento e testes das RNA, realizando ajustes nos hiperparâmetros. Concluiu-se que é possível obter uma RNA eficiente para prever o nível de potência do sinal de rádio móvel em parques com vegetação, quando comparado ao modelo log-distância aplicado ao mesmo conjunto de dados.

A aplicação de um modelo de RNA treinada em uma rota e calculada para as amostras de outra rota revelou que essa aplicação não pode ser imediatamente generalizada, considerando as entradas da RNA e os dados utilizados. Foi constatado que para a utilização de um único modelo em todo o ambiente do parque, seria necessário realizar o treinamento com ambas as rotas e incluir a identificação da rota como uma das entradas da RNA. Ao manter os mesmos hiperparâmetros, observou-se uma melhoria no desempenho, que foi ampliada com o aumento da quantidade de neurônios nas camadas ocultas: 11 na primeira camada e 7 na segunda.

Assim, por meio deste estudo, foi possível concluir que uma RNA/MLP pode ser empregada na modelagem desse tipo de ambiente. Entretanto, mesmo com a comprovada eficácia da rede, é necessário realizar novas medições em campo. Isso inclui a aplicação de dados coletados em diferentes locais, tanto no mesmo ambiente quanto em outros, ajustes nos tipos de parâmetros de entrada, consideração de variações no número de camadas e neurônios, entre outros ajustes nos hiperparâmetros, com o objetivo é aprimorar a compreensão da influência de cada hiperparâmetro, otimizar a previsão do sinal e aperfeiçoar a capacidade de generalização da RNA, com novos conjuntos de dados de entrada e do sistema.

Em trabalhos futuros, outras arquiteturas de RNA, como a *long short-term memory* (LSTM), um tipo de rede neural recorrente amplamente utilizado em séries temporais, também devem ser avaliadas. Além disso, é importante considerar o estabelecimento de padrões e metodologias para a simulação desses ambientes.

REFERÊNCIAS

- [1] C. Tavakoli, K. Sarabandi, and F. T. Ulaby, "Horizontal propagation through periodic vegetation canopies", *IEEE Transactions on Antennas and Propagation*, vol. 39, no. 7, pp. 1014–1023, 1991.
- [2] N. Savage, D. Ndzi, A. Seville, E. Vilar, and J. Austin, "Radio wave propagation through vegetation: Factors influencing signal attenuation", *Radio Science*, vol. 38, no. 5, 2003.
- [3] N. Z. Rahman, K. G. Tan, A. Omer, T. A. Rahman, and A. W. Reza, "Radio Propagation Studies at 5.8 GHz for point-to-multipoint applications incorporating vegetation effect", *Wireless Personal Communications*, vol. 72, no. 1, pp. 709–728, 2013.
- [4] H. L. Bertoni, *Radio propagation for Modern Wireless Systems*. Upper Saddle River, NJ: Prentice Hall PTR, 2000.
- [5] M. O. Al-Nuaimi and R. B. L. Stephens, "Measurements and prediction model optimization for signal attenuation in vegetation media at centimeter wave frequencies", *IEE Proceedings - Microwaves, Antennas and Propagation*, vol. 145, no. 3, p. 201, 1998.
- [6] K. Low, "UHF measurement of seasonal field-strength variations in forests", *IEEE Transactions on Vehicular Technology*, vol. 37, no. 3, pp. 121–124, 1988.
- [7] S. S. Seker and A. Schneider, "Experimental characterization of UHF radio wave propagation through forests", *IEE Proceedings H Microwaves, Antennas and Propagation*, vol. 140, no. 5, p. 329, 1993.
- [8] R. K. Tewari, S. Swarup, and M. N. Roy, "Radio wave propagation through Rain Forests of India", *IEEE Transactions on Antennas and Propagation*, vol. 38, no. 4, pp. 433–449, 1990.
- [9] B. R. Mello, P. A. Pinna, M. S. Dias, F. J. Fonseca, and L. J. Matos, "Measurements in vegetation and modeling of a Radio Mobile Channel in an Urban Park", *2014 International Telecommunications Symposium (ITS)*, 2014.
- [10] J. C. Silva, G. L. Siqueira, and P. V. 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, pp. 179–187, 2018.
- [11] L. Matos, D. Magalhães, V. Paes, R. Moreira, J. Teixeira, P. Castellanos, and C. Coelho, "Cobertura de Sinal Rádio Móvel em Ambiente com vegetação na frequência de 850 MHz", *Anais de XXXVII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais*, 2019.
- [12] B. S. L. Castro, "Modelo de propagação para redes sem fio fixas na banda de 5,8 GHz em cidades típicas da região amazônica", in *Proceedings of the 2010 IEEE Latin-American Conference on Communications*, Medellín, Colômbia, 2010, pp. 1-6.
- [13] E. S. Leão, F. J. B. Fonseca, L. J. Matos, *Análise Estatística da Variabilidade do Sinal Rádio Móvel Medido em Ambiente de Vegetação*, in *MOMAG 2012 - 15º Simpósio Brasileiro de Micro-ondas e Optoeletrônica e 10º Congresso Brasileiro de Eletromagnetismo*, João Pessoa, Paraíba, 2012.
- [14] D. B. Magalhães, N. P. Carvalho, F. J. B.; Fonseca, p. V. G. Castellanos, and L. J. Matos. *Análise de Cobertura de Sinal Rádio Móvel em Ambiente com Vegetação na Faixa 700 - 4000 MHz*, in *MOMAG 2020 - 19º Simpósio Brasileiro de Micro-ondas e Optoeletrônica e 14º Congresso Brasileiro de Eletromagnetismo*, Niterói, Rio de Janeiro, 2020.
- [15] M. B. Moura, D. C. Vidal, C. Schueler, L. J. de Matos, and 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 (IJCNN)*, 2018, pp. 1-7.
- [16] G. P. Ferreira, L. J. de Matos, and J. M. Silva, "Improvement of Outdoor Signal Strength Prediction in UHF Band by Artificial Neural Network", in *IEEE Transactions on Antennas and Propagation*, vol. 64, 2016, pp. 5404-5410.
- [17] F. Hlawatsch and G. Matz, "Wireless Communications Over Rapidly Time-Varying Channels", in *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Prague, Czech Republic, 2011, pp. 3852-3855, doi: 10.1109/ICASSP.2011.5946995.
- [18] W. C. Y. Lee, "Mobile Cellular Telecommunications Systems", in *1989 IEEE International Conference on Systems, Man, and Cybernetics*, Cambridge, MA, USA, 1989, pp. 236-240, doi: 10.1109/ICSMC.1989.73287.
- [19] P. Virtanen et al., "SciPy 1.0: fundamental algorithms for scientific computing in Python", *Nature Methods*, vol. 17, pp. 261-272, 2019, doi: 10.1038/s41592-019-0686-2.
- [20] M. D. Yacoub, *Foundations of Mobile Radio Engineering*. Routledge, 2019.

- [21] S. R. Saunders and S. R. Simon, "Antennas and Propagation for Wireless Communication Systems", in 1999 IEEE International Conference on Personal Wireless Communications, New Delhi, India, 1999, pp. 1-5, doi: 10.1109/ICPWC.1999.807292.
- [22] J. D. Parsons, "The Mobile Radio Propagation Channel", in 1991 IEEE 41st Vehicular Technology Conference, St. Louis, MO, USA, 1991, pp. 3-8, doi: 10.1109/VETEC.1991.144435.
- [23] International Radio Consultative Committee (CCIR), "Influences of terrain irregularities and vegetation non troposphere propagation", CCIR Report, pp. 235-236, Geneva, 1986
- [24] International Telecommunication Union (ITU), Attenuation in Vegetation, ITU-R Recommendation 833-7. Geneva, 2021
- [25] M. A. Weissberger, "An initial critical summary of models for predicting the attenuation of radio waves by trees", Electromagnetic Compatibility Analysis Center Annapolis MD, Tech. Rep., 1982.
- [26] H.-Y. Chen and Y.-Y. Kuo, "Calculation of radio loss in forest environments by an empirical formula", Microwave and Optical Technology Letters, vol. 31, no. 6, pp. 474-480, 2001, doi: 10.1002/mop.1402.
- [27] ANATEL, "Resolução nº 759, de 19 de janeiro de 2023", Agência Nacional de Telecomunicações, Brasília, DF, Brasil, 2023.
- [28] Pedregosa, F. et al., 2011. Scikit-learn: Machine learning in Python. Journal of machine learning research, 12(Oct), pp.2825-2830.
- [29] F. Chollet et al., "Keras," GitHub, 2015. [Online]. Available: <https://github.com/fchollet/keras>.
- [30] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization", arXiv preprint arXiv:1412.6980, 2014. [Online]. Available: <https://arxiv.org/abs/1412.6980>.
- [31] S. Haykin, Redes Neurais: Princípios e Prática. Bookman Editora, 2007.
- [32] E. Ostlin, H.-J. Zepernick, and H. Suzuki, "Macrocell path-loss prediction using artificial neural networks", IEEE Transactions on Vehicular Technology, vol. 59, no. 6, pp. 2735-2747, 2010.
- [33] Y. Zhang, J. Wen, G. Yang, Z. He, and J. Wang, "Path loss prediction based on machine learning: Principle, method, and data expansion", Applied Sciences, vol. 9, no. 9, p. 1908, 2019.



**Pedro Armando Vieira** was born in Rio de Janeiro, RJ, Brazil, in 1968. He graduated in Electrical Telecommunications Engineering from the General Roberto Lisboa Faculty of Engineering in 1993. In 2010 he received a Master's degree in Telecommunications Engineering from the Fluminense Federal University (UFF). He was telecommunications engineer and consultant at Petrobras for more than 20 years. He is currently a PhD student at the Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações (PPGEET) at UFF and professor at the Instituto Federal Fluminense where he has been teaching since 1996. His research interests include measurement, simulation of propagation and characterization of mobile radio communication channel, project and implementation of a telecommunications system. He is a senior member of the IEEE.



**Leni Joaquim de Matos** was born in Rio de Janeiro, RJ, Brazil, in 1954. He graduated in Telecommunications Engineering from the State University of Rio de Janeiro (UERJ), in 1977, by the Military Institute of Engineering (IME) and, in 2005, the title of Doctorate by the Pontifical Catholic University of Rio de Janeiro, PUC-Rio, both in Brazil. Since

1980 it has been dedicated to higher and postgraduate education. She is currently a researcher at the Fluminense Federal University (UFF), Brazil. Research interests include: Antennas and Propagation in the mobile radio channel and underwater acoustic channel, involving characterization, modeling and simulation. She is a member of the IEEE and SBMO.



**Pedro V. Gonzalez Castellanos** was born in Cúcuta, NdeS, Colombia. He received the degree of Information Systems Engineer from Francisco de Paula Santander University in 2001. In 2003, he received the MSc and in 2008 the DSc degrees from the Center for Telecomm. Studies (CETUC) at Pontifical Catholic University Rio de Janeiro (PUC/RJ), in Brazil. Since 2015, he is a professor and researcher at Fluminense Federal University (UFF), Brazil.



**Leonardo Henrique Gonsioroski** was born in Rio de Janeiro, RJ, Brazil on October 22, 1975. He received the B.S. degree in Electrical Engineering at Universidade Federal do Maranhão (UFMA), São Luís, Brazil, in 1998. In 2002, he received the MSc degree at the Instituto Militar de Engenharia (IME) and in 2013 the DSc degrees from the Center for Telecomm. Studies (CETUC) at Pontifícia Universidade Católica do Rio de Janeiro (PUC/RJ), in Brazil. He is currently a professor and researcher at the Universidade Estadual do Maranhão (UEMA). He is coordinator of the Grupo de Estudos em Tecnologias da Informação e Comunicações (GETICOM) and is member of the Academia Maranhense de Ciências (AMC). His research interests are radio wave propagation, digital television terrestrial broadcasting systems, mobile cellular and broadband radio access systems.



**Edson Cataldo** was born in 1967, in Rio de Janeiro, Brazil. He graduated in Telecommunications Engineering from Universidade Federal Fluminense (UFF), in 1988, where he also received a Master's degree in Mathematics, in 1993. In 2000, he obtained a Doctorate in Mechanical Engineering from the Pontifical Catholic University of Rio de Janeiro, PUC-Rio, Brazil. He completed the Postdoctoral internship at Paris-Est University, France, in 2006, and the Senior Postdoctoral internship, in 2015, at the same university. He teaches at UFF and is a research productivity fellow from CNPq, Brazil. His interests are in Modeling and Simulation, acting in: probabilistic models, voice production and signal processing.