

Redes Neurais Artificiais Aplicadas na Predição de Cobertura de Sinal Rádio VHF em Terreno Acidentado

Gilbert P. Ferreira, Ericson T. Bittencourt, Ângelo A.C. Canavitsas, Emanuel Costa, João M.M. da Silva e Leni J. de Matos

Resumo - Este artigo trata da utilização de Redes Neurais Artificiais (RNA) na predição de cobertura de sinal rádio em terreno acidentado na faixa de VHF. Partindo de medições realizadas em uma região suburbana, propiciando a propagação sob o mecanismo de difração, comparam-se as curvas de predição geradas a partir dos métodos recomendados pelo ITU (International Telecommunication Union), considerando a perda no espaço livre e por difração, com a curva gerada por uma RNA, mostrando melhor aderência desta última aos dados experimentais.

Palavras-Chave - Redes Neurais Artificiais, Perceptrons de múltiplas camadas, Predição de Cobertura, Propagação VHF, Difração.

Abstract— This article deals with Artificial Neural Networks (ANN) to predict radio signal coverage in irregular terrain on the VHF band. Starting from measurements carried out in a suburban area that favors the propagation under diffraction mechanism, the predictions are calculated by ITU models regarding the free space and diffraction loss and they are compared to the ANN model that shows better fit to the measurements.

Keywords - Artificial Neural Networks, Multilayer Perceptrons, Coverage Prediction, VHF Propagation, Diffraction.

I. INTRODUÇÃO

Com o recente aumento da demanda por telecomunicações e o surgimento de novas tecnologias para prover transmissões em alta velocidade, faz-se necessária uma utilização de eficientes programas para predição de cobertura, viabilizando a instalação de sistemas de telecomunicações sem fio em locais estratégicos, provendo a maior cobertura possível na região de interesse e garantindo acesso aos usuários das mais variadas regiões.

As recomendações do ITU [1] são utilizadas como base na predição de cobertura em VHF, entretanto, os modelos de predição recomendados para aplicação nessa faixa nem sempre são aderentes às medições realizadas em campo, aqui no Brasil. Isto acarretou na busca de outras formas de modelagem e, neste artigo, o objetivo é mostrar os primeiros resultados de uma série de estudos em andamento, de predições realizadas com o emprego das redes neurais artificiais, modelando o cenário de propagação em uma região acidentada, e comparando o resultado com os encontrados através da aplicação dos modelos ITU. Os

fenômenos associados à propagação, que são considerados neste estudo, são as atenuações causadas, principalmente, pela difração e atenuação pelo espaço livre [1].

O emprego de redes neurais artificiais vem crescendo, ao longo dos anos, nas mais diversas áreas do conhecimento. O problema de predição de cobertura do sinal rádio via rede neural, vem sendo empregado com resultados bastante interessantes [2-3], inclusive na faixa de VHF [4], e de UHF [5], em terreno acidentado.

A proposta neste artigo é o uso de RNA em cobertura de sinal rádio em terreno acidentado brasileiro na faixa de 150 MHz, sendo produto de um Projeto Final de Curso de Graduação de Engenharia de Telecomunicações da UFF [6].

O artigo é organizado em seis seções. A Seção II descreve o sistema, o ambiente e o resultado das medições; a Seção III aborda o treinamento de RNA e define uma primeira arquitetura de RNA empregada na predição; a Seção IV apresenta os gráficos comparando os dados obtidos das medições e cada modelo recomendado pelo ITU, dentre eles: *Deygout*, *Gume de Faca*, *Bullington* e *Epstein-Peterson* e, também, com o modelo de RNA proposto neste trabalho. A Seção V reúne as conclusões.

II. SISTEMA E AMBIENTE DE MEDIÇÕES

A. Local das Medições

As medições foram realizadas ao longo da Avenida Brasil, com o ponto de partida na Base Aérea de Santa Cruz (BASC)/ RJ. O local foi escolhido por ser uma região propícia à ocorrência de difração. Foi utilizada uma frequência livre na faixa reservada a uso exclusivo militar, a fim de evitar possíveis interferências.

B. Configuração do Sistema

Para a realização das medições, foram utilizados os seguintes equipamentos e antenas:

- Transmissor Montel MTAC1216F;
- Um Analisador de Espectro Anritsu MS2711D;
- Três *notebooks*;
- Dois aparelhos de GPS Garmin GPSMAP 76CSx; e
- Antena transmissora e receptora monopolo vertical com plano de terra.

Gilbert Ponciano Ferreira, Ericson Tannus Bittencourt, João Marcos Meirelles da Silva e Leni Joaquim de Matos, Departamento de Engenharia de Telecomunicações, Escola de Engenharia, Universidade Federal Fluminense, Niterói, RJ, Brasil; Ângelo Antônio Caldeira Canavitsas, Petrobras; Emanuel Costa, Cetuc-Puc/RJ; E-mails: gilbertpferreira@gmail.com, ericsonbt@yahoo.com.br, jmarcos@telecom.uff.br e lenijm@ig.com.br; canavitsas@petrobras.com.br; epoc@cetuc.puc-rio.br.

As especificações do sistema transmissor-receptor (Tx-Rx) montado, são:

- Frequência: 150 MHz;
- Modulação: FM;
- Raio Equivalente da Terra tomado como base: 8.500 km; [7]
- Localização da antena de TX: Latitude - S 22° 55' 59,3'' e Longitude - W 43° 42' 36,5'' (Santa Cruz);
- Altura da antena de Tx = 5m;
- Altura da antena de Rx = 3m;
- Potência de saída do transmissor: 40 Watts (46,02 dBm);
- Sensibilidade do analisador na recepção: - 30 dBμV;
- Perda nos cabos de transmissão: 2 dB;
- Perda nos cabos de Recepção: 0,5 dB;
- Ganho das antenas de transmissão e recepção (Polarização Vertical) ≈ 1 dBi; e
- Unidade das medidas: dBμV.

C. Medições

As medições foram realizadas em áreas suburbanas, caracterizadas por baixos prédios e suaves elevações, na faixa de 1 a 183 metros, nos períodos de Maio 2009 (Outono) e Agosto 2010 (Inverno), respectivamente, das 10h08min às 15h35min e 10h29min às 17h05min.

A antena receptora foi conectada diretamente ao analisador de espectro. Este, por sua vez, foi conectado ao notebook, junto com o GPS, onde eram sincronizados através dos horários dos equipamentos, que foram previamente pareados. A figura 1 mostra a antena receptora montada na viatura e os equipamentos empregados na recepção.




Fig. 1. Configuração dos equipamentos de medição.

Para cada ponto medido, a viatura encontrava-se parada, e era confirmado o envio da portadora com o operador do transmissor. Simultaneamente, era verificado o GPS para cadastramento de sua posição, que era confirmado por outro GPS para maior confiabilidade das medições. Por ser um processo com objetivos educacionais, as medições foram realizadas de forma manual, sem a automatização da captura dos dados.

Iniciadas as medições, foram percorridos cerca de 30 km pela Av. Brasil, onde foram medidos 72 pontos. Cada ponto medido foi inserido no Google Earth [8] para uma visão macro da região estudada, conforme mostrado na figura 2. Foram considerados dois pontos de referência.

Referência A: 22° 50' 33,44'' Sul / 43° 43' 51,66'' Oeste

Referência B: 22° 56' 14,08'' Sul / 43° 24' 13,40'' Oeste

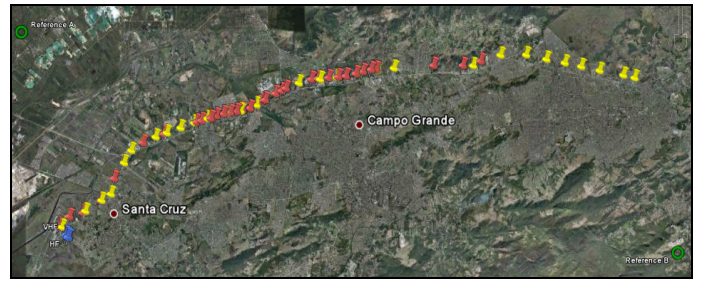


Fig. 2. Pontos inseridos no Google Earth ao longo da Av. Brasil, RJ.

As medições foram consolidadas em um banco de dados contendo localização, intensidade do sinal, distância, data das medições e grau de obstrução.

Para a elaboração do grau de obstrução, foi utilizado o software SIGAnatel [9], disponível gratuitamente no site da Anatel, e uma ferramenta de predição [10] para melhor visualização da topografia e morfologia do ambiente. Foram gerados os perfis do enlace, para cada ponto medido, e a avaliação foi feita de forma subjetiva, considerando como base obstruções da primeira zona de Fresnel [7]. Essa informação será utilizada como parâmetro de entrada na rede neural artificial.

Assim, foram adotados os seguintes graus de obstrução:

- Grau 0 – Visada direta;
- Grau 1 – Suaves Obstruções (radiovisibilidade);
- Grau 2 – Obstruções entre 60% e 95%; e
- Grau 3 – Obstruções maiores que 95%.

A figura 3 mostra um exemplo de um perfil de enlace com Grau 3 de obstrução.




Fig. 3. Exemplo de um perfil de enlace com obstrução de Grau 3.

Em alguns pontos do percurso não foi possível uma detecção do sinal devido à limitação da sensibilidade do analisador. Estes pontos podem ser observados na figura 4 e foram, portanto, desconsiderados, resultando na figura 5, ambas em escala dBm normalizada.




Fig. 4. Medidas realizadas.




Fig. 5. Medidas com os pontos de baixa intensidade descartados.

III. TREINAMENTO DA RNA

Partindo do estudo de redes neurais artificiais, as mesmas foram empregadas com o fim de modelar a predição do canal rádio sujeito à difração. Uma das características marcantes do uso das RNAs é, exatamente, a não necessidade da existência de um modelo matemático pré-existente. Para que seja eficiente, a RNA deve ser treinada de maneira adequada com vetores de entrada reais, de forma que a mesma adquira experiência. Quanto melhor a qualidade desses vetores e maior o seu treinamento, com cuidado para não saturar, a RNA tende a ficar cada vez mais funcional, até que comece a ter capacidade de tomar decisões com altas taxas de acerto, baseada nos padrões reconhecidos em seu treinamento.

Neste artigo, o treinamento da RNA foi realizado em *software* Matlab® [11], com a ferramenta específica chamada *Neural Network Fitting Tool*.

Para os parâmetros da RNA, foram escolhidos:

A. Tipo de rede:

Foi utilizada uma rede de múltiplas camadas *Multilayer Perceptron* (MLP) com algoritmo de treinamento *Backpropagation* [12] e *Levenberg-Marquardt* [13-14], já implementado no *Matlab*. O algoritmo usado no ajuste dos pesos da rede MLP é um fator relevante para o seu desempenho.

B. Estrutura da rede:

Após uma análise de arquitetura da MLP, foram utilizados 20 neurônios na camada escondida e 1 neurônio na camada de saída, conforme figura 6. São fornecidos dois dados de entrada, que são processados pela rede gerando uma única saída.




Fig. 6. Ilustrativo da rede MLP criada no *Matlab*.

C. Treinamento:

Para o treinamento da rede foram fornecidos dois parâmetros de entrada, distância em metros e o grau de obstrução, e um parâmetro de saída, a intensidade do sinal em dBm. Não foi utilizada a potência de transmissão como entrada para a rede, pois não houve variação deste parâmetro

que, sendo uma constante, poderia dificultar o processo de convergência da RNA.

Foram considerados que 60% de todos os dados de entrada seriam utilizados para treinamento da rede. Além disso, 15% dos dados foram usados para a validação do treinamento, que é a verificação da capacidade de generalização da rede. Os outros 25%, foram para o teste final da rede, analisando seu desempenho.

Foram feitos alguns treinamentos para que a rede pudesse ajustar seus pesos e apresentasse um bom desempenho com alta taxa de acerto.

IV. RESULTADOS

Para calcular a cobertura de sinal recebido, foram utilizadas as recomendações da ITU [1], que fornecem alguns métodos para estimar a atenuação de sinal no percurso com difração. Foi utilizado o banco de dados de topografia da Anatel, onde são gerados arquivos em formatos de texto, com informações de altura a cada 90 metros (*SRTM - Shuttle Radar Topography Mission*).

Os métodos do ITU recomendados e aqui empregados para predição de sinal foram: *Deygout*, Gume de Faca, *Bullington* e *Epstein-Peterson*. Nessa mesma ordem, estão nas figuras 7 a 10, as predições com cada um desses modelos, juntamente com os dados experimentais, para fins de comparação. Observa-se, nessas figuras, que os quatro modelos empregados se mostram otimistas em relação aos valores medidos.




Fig. 7. Comparação entre o método de *Deygout* e os valores medidos.




Fig. 8. Comparação entre o método de Gume de Faca e os valores medidos.




Fig. 9. Comparação entre o método de Bullington e os valores medidos.

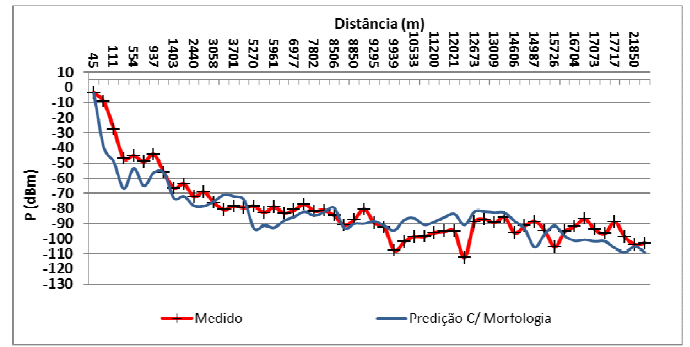


Fig. 12. Comparação entre a ferramenta de predição com morfologia e os valores medidos.




Fig. 10. Comparação entre o método de Epstein Peterson e os valores medidos.




Fig. 13. Comparação entre o resultado com menor desvio padrão dos treinamentos da RNA e os valores medidos.

Além dos métodos do ITU, foi utilizada uma ferramenta de predição comercial [10], que utiliza o método Gume de Faca como base em seus cálculos e que pode incluir os dados de morfologia do terreno, além de outros ajustes. A figura 11 mostra o ajuste dos valores resultantes dessa predição aos valores experimentais. Observa-se, como nos casos anteriores, que o modelo é otimista no caso em que não se aplica a morfologia do ambiente nos cálculos de predição.

Na figura 14, são mostradas as curvas de predição que forneceram, dentre todas as calculadas, o menor desvio relativo aos dados experimentais e observa-se que a predição pelo modelo de redes neurais foi a de melhor ajuste aos valores experimentais.

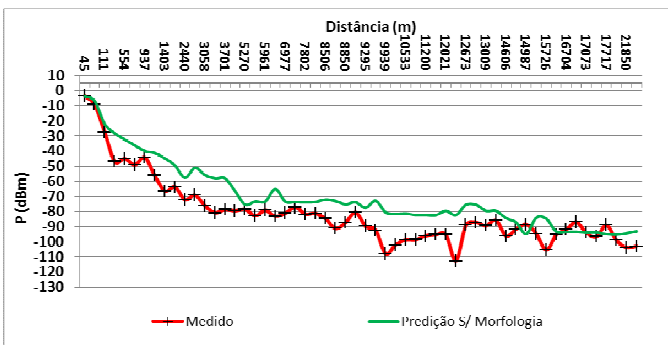


Fig. 11. Comparação entre a ferramenta de predição sem morfologia e os valores medidos.




Fig. 14. Comparação entre os métodos de menor desvio padrão.

Foram feitas análises quantitativas dos valores obtidos para cada método, conforme mostrado nas tabelas 1 e 2.

Para os resultados da figura 12, aplicou-se o mesmo software [10], mas com a inclusão da morfologia do ambiente. Observa-se um melhor ajuste que os anteriores.

Após o cálculo da predição com os métodos citados anteriormente, foi utilizada a RNA para a predição dos níveis de sinal. O gráfico com o resultado dessa predição, onde se obteve o menor desvio padrão dos treinamentos da rede, juntamente com os dados experimentais, é mostrado na figura 13.

TABELA I. GRAU DE CORRELAÇÃO

		Correlação
1	RNA	0,9734
2	DEYGOUT	0,9367
3	SEM MORFOLOGIA	0,9340
4	BULLINGTON	0,9007
5	COM MORFOLOGIA	0,8898
6	GUME DE FACA	0,8820
7	EPSTEIN-PETERSON	0,8693

Como pode ser observado na tabela 1, todos os modelos tiveram um alto grau de correlação com os valores medidos, onde somente a RNA apresentou correlação maior do que 95%

TABELA II. TESTE DO CHI-QUADRADO

		Aderência do ChiQuadrado	Coefficiente de Contingência
1	COM MORFOLOGIA	4288,1	0,999998477
2	RNA	4154,5	0,999998378
3	BULLINGTON	3694,6	0,999997949
4	DEYGOUT	3597,9	0,999997837
5	SEM MORFOLOGIA	3547,7	0,999997775
6	EPSTEIN-PETERSON	3485,7	0,999997696
7	GUME DE FACA	3460,5	0,999997662

Na tabela 2 são apresentados o teste do Chi-Quadrado e o coeficiente de contingência de cada modelo baseados nos valores medidos. Apesar do alto grau de correlação com os valores medidos, a RNA apresentou a 2ª maior aderência ao teste Chi assim como o coeficiente de contingência, mostrando seu alto desempenho na predição dos valores.

V. CONCLUSÕES

De acordo com os dados mostrados neste artigo, percebe-se que os métodos da ITU-R não se adequaram bem à região estudada ou não apresentaram os fatores de correção para o tipo de topografia brasileira, porém apresentando margens aceitáveis [1]. Estes métodos se mostraram otimistas perante as medidas realizadas, não sendo suficientes para projetar um radioenlace, pois valores esperados estarão acima do valor real, gerando sombra em parte da região a ser coberta pelo sinal. Por outro lado, observa-se que ao utilizar um conjunto de recomendações e métodos que foram utilizados na ferramenta de predição, os resultados se mostraram bem mais próximos dos experimentais.

A Rede Neural Artificial MLP, treinada com os dados obtidos nas medições, mostraram um resultado bastante positivo para a predição, se adequando bem aos dados, na maioria dos pontos analisados. São, portanto, uma boa alternativa para a predição de cobertura de sinal na faixa de VHF. É importante ressaltar que as RNAs necessitam ser alimentadas com valores prévios para sua utilização, sendo fundamental saber se a região a ser coberta já foi estudada anteriormente para calibração e posterior uso.

Algumas ferramentas de *software* no mercado apresentam resultados teóricos bem próximos aos resultados experimentais, quando acompanhadas de informações de morfologia do terreno, o que as tornam bastante atrativas. Em princípio, uma RNA pode parecer desvantajosa em relação a uma ferramenta destas, uma vez que a RNA necessita de dados experimentais e estes, por sua vez, necessitam ser medidos em campo previamente. Em geral, entretanto, para as principais ferramentas, as informações de morfologia são comercializadas à parte e possuem um alto custo de investimento, devendo ser calibradas com testes em campo, chamados de *drive tests*.

Neste trabalho, foi possível fazer alguns conjuntos de medidas para treinar a RNA a um custo muito inferior ao que seria investido junto a estas ferramentas de *software* e, ainda, obtendo resultados com maior acurácia. Isto mostra que o uso de RNA para a previsão de cobertura é, certamente, uma ferramenta valiosa. Novos estudos estão em andamento, e um deles visa investigar a qualidade das previsões em função da quantidade de dados necessários e da qualidade destes, objetivando encontrar um conjunto de requisitos mínimos sobre os dados experimentais sem comprometer, significativamente, os resultados e auxiliando, portanto, no planejamento e na viabilidade econômica do levantamento de dados experimentais.

Como proposta para trabalhos futuros, sugere-se que sejam realizados estudos mais detalhados e comparativos da adequação ou não dos métodos ITU-R, a aplicação das RNAs em outros tipos de ambientes, análise do comportamento em outras faixas de frequências e variação da potência de transmissão. Deve ser estudada a aplicação de outros modelos de RNAs com outros algoritmos de convergência, analisar quais parâmetros de entrada para a rede apresentam maior importância para redução do erro de predição, gerando uma possível utilização mista das recomendações com as RNAs.

AGRADECIMENTOS

Ao comando da Base Aérea de Santa Cruz pelo apoio técnico e infraestrutura prestada. Em especial, ao Sgt. Pablo Arraes do 1º/1º GCC e à Eng. M.Sc. Valdileide Freire de Araújo, do DECEA, pela participação nos testes.

REFERÊNCIAS

- [1] Recomendação 526-11, “*Propagation by Diffraction*”, ITU-R, 2011.
- [2] SStocker, K.E., Gschwndtner B.E., Landstorfer F.M., “*Neural network approach to prediction of terrestrial wave propagation for mobile radio*”, IEE proceedings-H, Vol. 140, No. 4, pp. 315-320, August 1993.
- [3] Milovanovic, B., Stankovic, Z., Stosic, A., *Prediction of The Electromagnetic Field Strength Level Using Neural Model*, 6th International Conference on Telecommunication in Modern Satellite, Cable Broadcast Service. TELSIKS, vol. 2, pp. 457-460, 2003.
- [4] Balandier, T., Caminada, A., Lemoine, V., Alexandre, F., *170 MHz Field Strength Prediction in Urban Environment Using Neural Nets*, Personal, 6th IEEE International Symposium on Indoor and Mobile Radio Communications, vol. 1, pp. 120-124, 1995.
- [5] Neskovic, A. Neskovic, N. and Paunovic, D. “*Macrocell Electric Field Strength Prediction Model Based Upon Artificial Neural Networks*”, IEEE Journal on Selected Areas in Communications, vol. 20, no. 6, August 2002.
- [6] Ferreira, G. P. Bittencourt, E. T. “*Medições na Faixa de VHF e utilização de Redes Neurais Artificiais para Predição de Cobertura.*”, UFF, 2011.
- [7] Blaunstein, N., *Radio Propagation in Cellular Networks*, Artech House, 1999.
- [8] Google Earth, *Software*, versão 2011.
- [9] SIGAnatel, *Software*, versão 2011.
- [10] Celplanner, *Software*, versão 11.06.
- [11] Matlab, *Software*, versão 2010.
- [12] Rumelhart, D. E., Hinton, G. E., and Williams, R. J. *Learning representations by backpropagating errors*. Nature, 323:533–536, 1986.
- [13] Levenberg, K. *A method for the solution of certain non-linear problems in least squares*. Quarterly Journal of Applied Mathematics, II(2):164–168, 1944.
- [14] Hagan, M. T. and Menhaj, M. B. *Training feedforward networks with the mar-quardt algorithm*, IEEE Transactions on Neural Networks 5(6) pages 989-993, 1994.