

Utilização das Redes Neurais Artificiais na Adaptação de Modelos de Propagação em Ambiente Fechado

JULIANA MONTEIRO, MÁRCIO RODRIGUES, GLEYCE CALDEIRA E JOSIANE RODRIGUES.

Instituto de Estudos Superiores da Amazônia – IESAM, Belém-PA
E-mail: jsm@telecom.iesam-pa.edu.br, mrp@telecom.iesam-pa.edu.br,
gspc@telecom.iesam-pa.edu.br e josiane@prof.iesam-pa.edu.br.

Resumo - Neste artigo foi realizado um estudo sobre perdas de propagação em ambiente *indoor*. Para fazer este estudo, foi realizada uma campanha de medição em um prédio de 4 andares, típico de uma faculdade, situado no centro de Belém-PA. Alguns modelos presentes na literatura foram utilizados a fim de comparar os valores de perda predita com aquelas medidas durante a campanha. Aos modelos que apresentaram um erro de predição muito grande, foi adicionada uma rede neural artificial (RNA) como forma de adaptação dos modelos. Esse artifício melhorou significativamente o desempenho de tais modelos na predição da perda no prédio em estudo.

Palavras Chaves – Comunicações móveis, ambiente *indoor*, modelos empíricos de perda de propagação *indoor*, Redes Neurais Artificiais.

INTRODUÇÃO

A propagação do sinal rádio móvel em ambientes fechados (*indoor*) é influenciado por vários fatores, tais como: o tipo de material de construção do prédio, sua planta baixa, o *layout* da mobília, número de pisos e paredes entre o transmissor e receptor, entre outros. Portanto as perdas que ocorrem devido à reflexão, difração e transmissão são

dependentes das características de construção de cada prédio. Assim sendo, caracterizar as perdas em ambientes fechados não é uma tarefa fácil. Na tentativa de prever essas perdas foram desenvolvidos vários modelos empíricos que são descritos na literatura [1] - [2]. Para comparar o desempenho desses modelos foi realizada uma campanha de medição em um prédio de quatro andares, típicos de uma faculdade. Os valores da perda medida foram, então, comparados com aquelas previstas pelos modelos. Alguns modelos, entretanto, apresentaram um erro de predição muito grande. Isso se deve ao fato de os mesmos não possuírem um fator de ajuste. Na tentativa de adaptar esses modelos para o ambiente estudado, uma RNA foi somada aos mesmos, diminuindo dessa forma o erro de predição.

AMBIENTE E *SETUP* DE MEDIÇÃO

O prédio em estudo tem em sua estrutura paredes construídas de tijolo e lajes de concreto. As salas de aula possuem porta de madeira e janelas de vidro. Os corredores do bloco em que foi feita a campanha de medição possuem paredes revestidas de lajotas, janelas de vidro em toda sua extensão, e mede 44,5m, enquanto que o pé-direito do prédio mede 2,98m. A Figura 1 ilustra o referido corredor.



Figura 1 Corredor das salas de aula no prédio do IESAM.

O conjunto transmissor é formado por uma antena monopolo, a qual estava adaptada a um gerador de varredura, HP 83752A, e a um amplificador, como é mostrado na Figura 2. O equipamento receptor, ilustrado na Figura 3, é constituído por um protótipo de 5ª roda [3], capaz de medir a distância percorrida, além de um analisador de espectro, HP8593E, conectado a uma antena monopolo. Os sinais provenientes da 5ª roda e do analisador são enviados a um *notebook* através de uma placa conversora AD/DA.




Figura 2: Conjunto de equipamentos transmissores

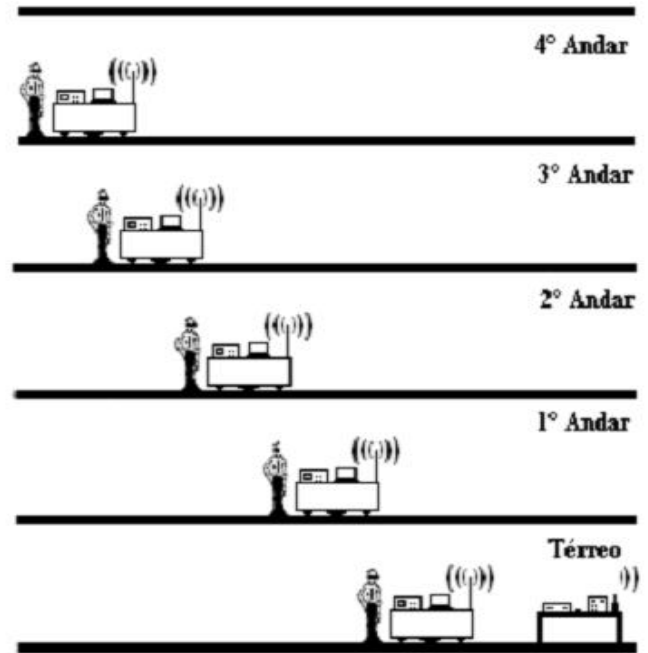


Figura 4: Representação da metodologia de coleta do sinal




Figura 3: Conjunto de equipamentos receptores

METODOLOGIA

O conjunto transmissor foi localizado no final do corredor do andar térreo gerando uma onda CW com potência de 21dBm e frequência de 850MHz. Para coletar o sinal, o conjunto receptor foi deslocado nos corredores do 1°, 2°, 3° e 4° andares, como ilustrado na Figura 4 [4].

MODELOS ESTUDADOS

Após o tratamento dos dados obtidos na campanha de medição, as perdas medidas foram comparadas com as perdas previstas pelos modelos. Neste artigo, foram utilizados os seguintes modelos de predição:

A. COST-231 [1]

Este modelo tem a particularidade de incorporar uma componente linear de perda, proporcional ao número de paredes penetradas, mais um termo de maior complexidade que depende do número de andares penetrados, produzindo uma perda que aumenta lentamente com o aumento do número do andar depois que o primeiro foi adicionado. Este modelo apresenta, normalmente, a melhor adaptação à perda medida devido aos fatores L_c e b , que são constantes empíricas que adaptam o modelo ao ambiente em estudo. A equação do modelo é mostrada a seguir:

$$L_T = L_F + L_c + \sum_{i=1}^w L_{wi} n_{wi} + L_f n_f^{((n_f+2)/(n_f+1)-b)} \quad (1)$$

Sendo:

L_F : perda no espaço livre para o percurso em linha de visada entre o transmissor e o receptor;

n_{wi} : número de paredes do tipo i , atravessadas pelo percurso direto;

w : número de tipos de paredes;

L_{wi} : perda de penetração para uma parede do tipo i ;

n_f : número de pisos atravessados pelo percurso;

b e L_c : constantes obtidas empiricamente;

L_f : perda por andar.

B. Seidel - Rappaport [2]

Este modelo é baseado no modelo do espaço livre e apresenta um fator de ajuste entre os andares, chamado de FAF.

$$L = -27,56 + 20 \log_{10}(f) + (20 - 10n) \log_{10}(d/d_0) + (10n) \log_{10}(d) + \text{FAF} \quad (2)$$

n: expoente de perda de propagação;
FAF: fator de atenuação entre andares;

C. ITU-R [1]

Neste modelo, a atenuação devido a obstáculos em um mesmo andar (paredes, colunas, etc) está incluída implicitamente no próprio fator de atenuação com a distância, e a perda devido ao piso está explicitada na equação a seguir:

$$L_T = 20 \log f_c + 10n \log r + L_f(n_f) - 28 \quad (3)$$

L_f(n_f): perda de penetração por piso.

D. Modelo do fator de Piso e Parede (WLL) [1]

Este modelo leva em consideração a atenuação sofrida pelo sinal ao atravessar obstáculos em um mesmo andar (estes obstáculos são paredes e colunas). Esta atenuação está relacionada à distância e é representada pela seguinte equação:

$$L = L_1 + 20 \log d + n_f a_f + n_w a_w \quad (4)$$

a_f e **a_w**: fatores de atenuação por piso e por parede, respectivamente, em dB.

L₁: perda em d=1.

RESULTADOS

A Figura 5 mostra os resultados medidos e preditos pelos modelos. A Tabela I apresenta os valores dos erros médios entre os dados medidos e preditos pelos modelos adotados, enquanto que a Tabela II apresenta o desvio padrão entre esses valores.

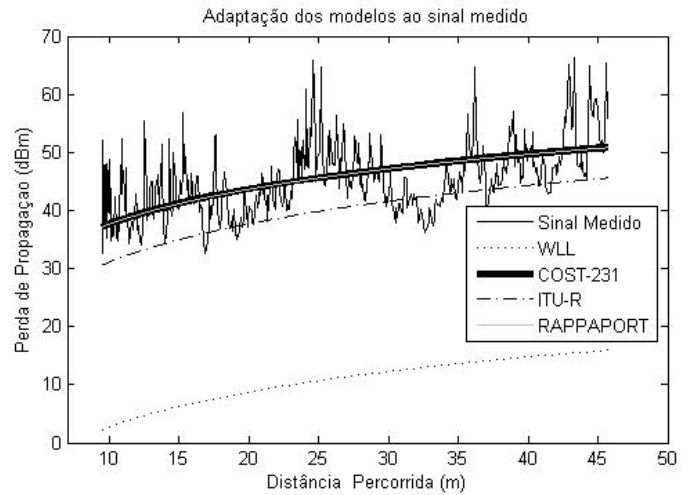


Figura 5. Comparação entre os modelos e o sinal medido.

	COST-231	ITU-R	WLL	SEIDEL-RAPPAPORT
1º Andar	4,62	13,51	6,57	4,62
2º Andar	4,034	4,09	27,76	4,04
3º Andar	4,26	6,36	34,88	4,26
4º Andar	4,53	13,99	64,95	4,53
Erro Médio	4,36	9,49	33,54	4,36

Tabela 1: Erro Médio em cada andar (dBm)

	COST-231	ITU-R	WLL	SEIDEL-RAPPAPORT
1º Andar	5,71	14,69	7,63	5,71
2º Andar	5,19	5,25	28,24	5,19
3º Andar	5,44	8,05	35,30	5,44
4º Andar	5,56	15,06	65,18	5,56
Desvio Padrão Médio	5,47	10,76	34,09	5,47

Tabela 2: Desvio Padrão em cada andar (dBm)

Da Figura 5 e das Tabelas 1 e 2, é possível observar que os modelos que apresentaram melhor resultados foram o COST-231 e o Seidel-Rappaport. Observe que os mesmos encontram-se sobrepostos na Figura 5. Esse resultado era esperado, pois tais modelos apresentam constantes de ajuste como o **b** e o **L_C** para o COST-231 e o **FAF** para o Seidel-Rappaport. Os modelos ITU-R e WLL, como não possuem fatores de ajuste, apresentaram uma pior predição com erros médios de 9,49 dBm e 33,54 dBm, respectivamente.

Na tentativa de melhorar o desempenho dos modelos ITU-R e WLL foi implementada uma Rede Neural Artificial (RNA) [3].

IMPLEMENTAÇÃO DE UMA RNA

Para uma melhor adaptação dos modelos propostos foi utilizado uma rede do tipo *backpropagation*, com 3 camadas com 40, 20 e 1 neurônio em cada camada. O vetor de entrada foi a distância e o erro entre as medidas e os modelos, o vetor de saída, chamado de alvo da rede.

A metodologia utilizada foi a seguinte: o primeiro andar foi utilizado como rota de treinamento e os outros andares são as rotas de teste da RNA. A subtração do modelo original com a RNA originou o denominado modelo híbrido. A Figura 6 apresenta o resultado do treinamento da rede para o modelo ITU-R. A Figura 7 apresenta os resultados do 4º andar (rota de teste) para o ITU-R.

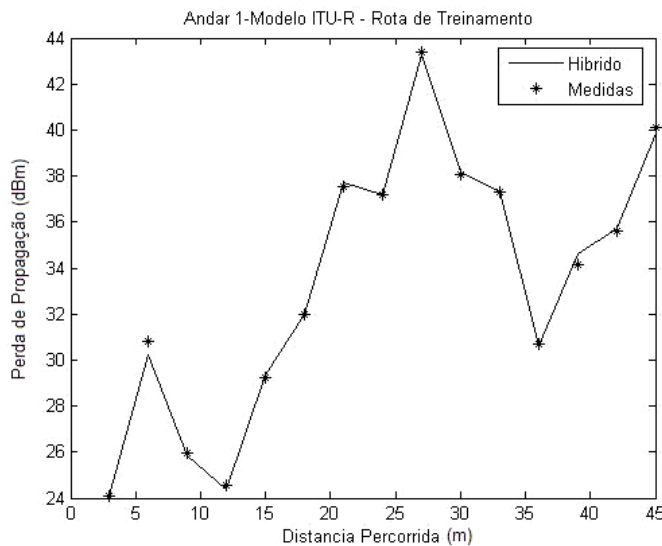


Figura 6. Treinamento da RNA para o modelo ITU-R.

Como os sistemas baseados em uma Rede Neural Artificial têm como objetivo oferecer um método alternativo para solucionar problemas relacionados à otimização de sistemas, a RNA tenta adaptar-se melhor aos valores do sinal para cada distância entre transmissor e receptor. Veja resultados da Figura 6.

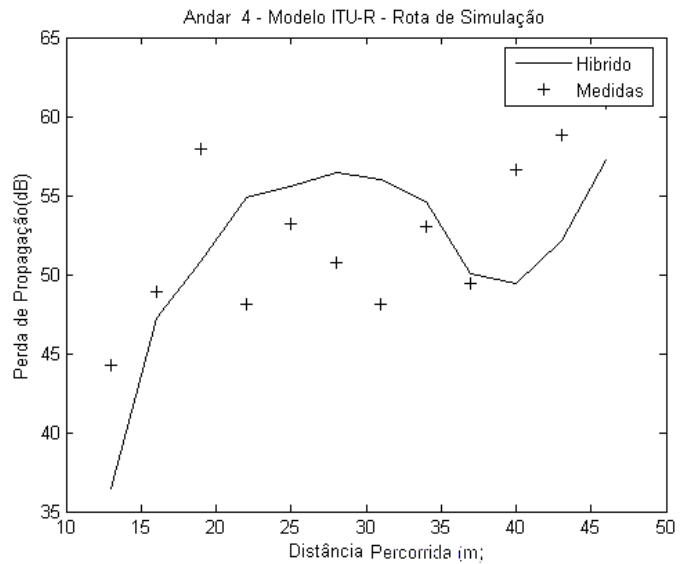


Figura 7. Simulação da RNA para o modelo ITU-R

Com os pesos sinápticos calculados na rota de treinamento, a RNA foi testada nos outros andares, melhorando assim, os valores do erro médio e do desvio padrão para os modelos que tiveram estes valores mais elevados. As Tabelas 3 e 4 mostram esses valores otimizados após serem tratados por uma RNA.

	ITU-R	WLL
1º Andar	0,52	1,35
2º Andar	3,52	3,14
3º Andar	6,24	5,47
4º Andar	4,91	3,26
Erro Médio	3,80	3,30

Tabela 3: Erro Médio Em (dBm) para o modelo híbrido.

	ITU-R	WLL
1º Andar	0,9628	1,9609
2º Andar	2,2214	1,9801
3º Andar	3,6277	3,3985
4º Andar	2,7362	2,5959
Desvio Padrão Médio	2,3870	2,4838

Tabela 4: Desvio Padrão em (dBm) para o Modelo Híbrido

Após a subtração com a RNA, modelo híbrido, os modelos ITU-R e WLL apresentaram um erro médio de 3,8 e 3,3, respectivamente.

CONCLUSÕES

Os modelos COST-231 e Seidel-Rappaport foram os que mais se adaptaram ao ambiente considerado, haja vista que ambos possuem constantes empíricas que permitem aos modelos se adaptarem aos ambientes de medição. Aos modelos ITU-R e WLL, que não possuem em sua formulação nenhuma constante empírica, apresentaram um erro médio de 9,49 dBm e 33,54 dBm, respectivamente. Para adaptar esses modelos, obtendo assim uma melhor predição, foi incorporado aos mesmos uma RNA, tendo como resultado o chamado modelo híbrido. Os erros médios para esses modelos foram, então, de 3,8 dBm e 3,3 dBm, respectivamente, representando, dessa forma, uma melhoria de predição de 50,96% e 90,16%, respectivamente. A rede neural artificial mostrou-se, portanto, muito eficiente na melhoria do desempenho de modelos de predição.

AGRADECIMENTOS

Os autores agradecem à Amazônia Celular S/A e à Universidade Federal do Pará-UFPA, por terem cedido alguns equipamentos para a realização desta pesquisa, ao Instituto de Estudos Superiores da Amazônia-IESAM, por ter cedido espaço físico e aos colegas que estiveram presentes nas campanhas de medições e auxiliaram no desenvolvimento do trabalho, Brenda Pereira, Simone Fraiha, Hermínio Gomes, Regiane Barbosa e Gervásio Cavalcante.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] R. S. Saunders, *Antennas and Propagation for Wireless Communication Systems*. Ed. Wiley. 1999
- [2] T. S. Rappaport, *Wireless Communications – Principles and Practice*, Prentice Hall PTR, 2ª ed. 2002
- [3] J. C. Rodrigues, *Adaptação de modelos de propagação para ambientes indoor utilizando redes neurais artificiais*, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Pará, Belém 2002.
- [4] R. N. S. Barbosa, *Novo modelo semi-empírico para estimativa da perda de propagação indoor para comunicações móveis*, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Pará, Belém 2005.