

Método de Análise e Ajuste por Redes Neurais de Modelos de Previsão de Atenuação por Chuvas em Enlaces Terra-Satélite

Gilson A. Alencar e Luiz P. Calôba

Resumo - Neste trabalho é apresentado um processo de análise e ajuste de modelos fenomenológicos complexos utilizados na predição da atenuação por chuvas em enlaces terra-satélite. O processo de análise consiste em dividir um modelo fenomenológico em vários módulos ou sub-modelos com o objetivo de identificar aqueles que mais contribuem para a imprecisão do modelo global. Em seguida os módulos mais críticos são ajustados por meio de redes neurais conectadas em paralelo com os mesmos. Este método foi aplicado no modelo UIT-R e os resultados se mostraram bastante satisfatórios.

Palavras Chave – Atenuação por chuvas, enlace terra-satélite, modelos fenomenológicos, redes neurais.

Abstract – In this work a new process to analyse and to adjust complex phenomenological models, used in the rain attenuation prediction in earth-space paths, is discussed. By the new process, a phenomenological model is split in several blocks or sub-models. The set of blocks is the global model. After this task, a method based on neural networks concepts is applied to identify the most critical blocks of global model. Concluded the identification, a neural network is placed in parallel with bad blocks to fix them by a training process. This method is applied to the ITU-R model in this work.

Index Terms – Rain attenuation, earth-space paths, phenomenological models, neural networks.

I. INTRODUÇÃO

A utilização de redes neurais na previsão da atenuação por chuvas em enlaces terra-satélite já vem sendo realizada com excelentes resultados [1,2]. Modelos neurais são muito eficazes, mas sendo numéricos têm contribuição limitada para o entendimento da fenomenologia do sistema representado, ao contrário dos modelos fenomenológicos. Desta forma, este artigo trata de uma nova técnica que utiliza conceitos de redes neurais para avaliar e fornecer subsídios para aprimorar os sub-modelos que compõem um modelo mais complexo. Será introduzido um novo tipo de modelo híbrido fenomenológico/neural que preserva o máximo possível o modelo fenomenológico e seus sub-modelos ao mesmo tempo que fornece a precisão numérica dos modelos neurais.

Gilson Alves de Alencar, Departamento de Engenharia Elétrica, Grupo de Neurocomputação, Universidade Gama Filho, Rio de Janeiro, Brasil, E-mail: galencar@ugf.br. Luiz Pereira Calôba, Laboratório de Processamento de Sinais, COPPE/EE/UFRJ, Rio de Janeiro, Brasil, E-mail: caloba@ufrj.lps.br.

II. INTERPRETAÇÃO NEURAL DOS MODELOS FENOMENOLÓGICOS

Modelos matemáticos consistem geralmente de um sistema não recursivo de equações que são aplicadas sucessivamente, gerando cada qual uma variável interna ao sistema. Cada equação tem, geralmente, um significado fenomenológico, e pode ser considerada como um sub-modelo integrante do modelo. Representando cada equação como um modelo ou bloco constrói-se o diagrama de blocos do modelo global. A Figura 1 ilustra o diagrama em blocos do modelo global constituído por vários sub-modelos. Tal estrutura pode ser interpretada como uma rede neural “feedforward”, onde as conexões entre os blocos se assemelham a sinapses de ganho unitário e os blocos como neurônios com função de excitação/ativação igual as equações que os representam (ϕ).




Fig 1: Diagrama em blocos do modelo global.

III. ERRO DOS BLOCOS

A menos que sua equação represente com suficiente precisão o sub-modelo fenomenológico, cada bloco é responsável pela introdução de um erro que comporá o erro da saída. A análise é iniciada com a classificação dos sub-modelos em função de sua importância para o erro na saída. Considere a saída do bloco j_i adicionada a uma sinapse c_i , conforme ilustrado na Figura 2, cuja função é corrigir o erro do bloco.

Para que o diagrama de blocos da Figura 1 represente perfeitamente o modelo fenomenológico, o valor nominal de c_i deve ser nulo para cada sub-modelo ou bloco.




Fig. 2: Bloco com sinapse de correção de erro.

O objetivo é medir a contribuição do erro de cada bloco na função objetivo a ser minimizada,

$$F = E(e_p) = \frac{1}{p} \sum_{p=1}^p e_p \quad (1)$$

$$e_p = e(y_p, \tilde{y}_p)$$

onde $E(\cdot)$ é a função valor esperado para todo par entrada-saída $p = 1, \dots, P$, $e(\cdot)$ é a função erro da saída, Φ é o valor da função para o par entrada-saída p , y_p é o valor desejado na saída e \tilde{y}_p o valor estimado com o modelo. Considerando o modelo como uma rede neural não convencional, o valor de c_i pode ser ajustado para o par p pelo método do gradiente descendente da função F em relação a um vetor \underline{c} de componentes \underline{c}_i . Assim

$$\Delta c_i(p) = -\mathbf{a} \frac{\partial e_p}{\partial c_i} \quad (2)$$

$$\frac{\partial e_p}{\partial c_i} = -\mathbf{a} \frac{\partial e_p}{\partial \tilde{y}} \frac{\partial \tilde{y}}{\partial z_i} \frac{\partial z_i}{\partial c_i} \quad (3)$$

$$\Delta c_i(p) = -\mathbf{a} \frac{\partial e_p}{\partial \tilde{y}} \frac{\partial \tilde{y}}{\partial z_i} = -\mathbf{a} \mathbf{d}_i \quad (4)$$

onde $\mathbf{a} > 0$, $\partial z_i / \partial c_i = 1$ e \mathbf{d}_i é conhecido como erro retropropagado da saída da rede até a saída z_i do bloco \mathbf{j}_i .

Como se trata de uma correção por gradiente descendente, para uma aproximação de primeira ordem de F e para $|\Delta c|$ constante, o valor de $\Delta c_i(p)$ calculado é o que minimiza a função objetivo. Por outro lado, quando $\Delta c_i(p)$ compensa completamente o erro introduzido por cada bloco, o erro na saída e, conseqüentemente, a função F , são mínimos. Logo, o erro da saída retropropagado \mathbf{d}_i é um parâmetro bastante adequado para avaliar a importância do erro de cada bloco na saída da rede. A correção clássica das sinapses de uma rede neural é feita por um valor fixo correspondente a média dos valores calculados para cada par entrada-saída,

$$\overline{\Delta c_i} = E_{v_p}[\Delta c_i(p)] \quad (5)$$

A correção pode ser feita de maneira simples com a adição de uma polarização na saída do bloco. No entanto, este procedimento é pobre e corrige apenas o erro médio na saída do bloco, que muito provavelmente já é pequeno, se o sub-modelo foi razoavelmente projetado. Neste caso, é mais conveniente corrigir o erro $\Delta c_i(p)$, que varia com cada par p . Uma medida adequada para a influência do erro de cada bloco no erro da saída é a variância de $\mathbf{d}_i(p)$, conforme expresso na Equação 6.

$$s_i^2 = E_{v_p}[\mathbf{d}_i^2(p)] - E_{v_p}[\mathbf{d}_i(p)]^2 \quad (6)$$

Uma vez calculadas as influências dos erros de cada bloco, s_i^2 , no erro da saída, são identificados os blocos críticos, isto é, aqueles com maior s_i^2 , maior influência. Estes blocos devem então ser modificados para melhorar a eficiência dos sub-modelos e, conseqüentemente, do modelo global.

IV. ANÁLISE E CORREÇÃO DOS SUB-MODELOS

Um sub-modelo pode ser inadequado por duas razões principais: a equação que o representa é inadequada ou as entradas do bloco são insuficientes para determinar sua saída. Se o erro na saída de cada bloco crítico mantiver correlação significativa com qualquer uma de suas variáveis de entrada, isto significa que a equação do bloco ou sub-modelo não é adequada para representá-lo e, neste caso, necessita ser modificada. Se esta correlação não existe, provavelmente falta informação na entrada do bloco, que pode estar contida em outras variáveis. Quando a saída de um bloco é calculada estão disponíveis, além das suas variáveis de entrada, as variáveis de entrada da rede e outras variáveis internas, saídas de outros blocos, já calculadas anteriormente. Se algumas destas variáveis apresentam correlação significativa com o erro na saída do bloco em questão, então elas podem ser utilizadas como entradas adicionais ao bloco para reduzir o erro na saída do mesmo. É possível que o erro na saída do bloco seja causado pelas duas razões citadas anteriormente. Neste caso, as variáveis candidatas a entradas adicionais devem ser descorrelacionadas das variáveis de entrada do bloco que apresentam correlação significativa com o erro em sua saída. Estas variáveis descorrelacionadas devem então ser novamente testadas para verificar se mantém correlação significativa com o erro na saída do bloco. Caso positivo, as variáveis originais, não descorrelacionadas, devem ser aceitas como novas entradas do bloco. Este último passo, envolvendo a descorrelação, não é essencial, mas evita a adição de novas entradas que não trazem informação adicional ao bloco, e preserva o máximo possível os sub-modelos fenomenológicos.

O processo acima permite determinar os blocos críticos, que necessitam de correção, e eventuais variáveis adicionais que devem ser utilizadas como entradas. A correção para manter o modelo como fenomenológico deve ser feita alterando a equação dos sub-modelos críticos, o que não é uma tarefa fácil na maioria dos casos. Uma alternativa é utilizar um modelo híbrido fenomenológico/neural. Neste caso, uma rede neural é colocada em paralelo com cada bloco crítico.

A rede é alimentada pelas entradas do bloco que tem correlação com o erro na saída, caso o erro seja devido a equação inadequada, pelas entradas adicionais que tem correlação com a saída, caso o erro seja devido a falta de informação na entrada ou por ambos, caso o erro tenha ambas as causas.

As redes neurais auxiliares devem ser treinadas simultaneamente, imersas no modelo fenomenológico. Se o treinamento é feito por retropropagação do erro, para cada par entrada-saída p , o erro retropropagado da saída do modelo até a saída da rede neural auxiliar do módulo i é determinado por:

$$\mathbf{d}_i = \frac{\partial e_p}{\partial \tilde{y}} \frac{\partial \tilde{y}}{\partial z_i} \quad (7)$$

Daí para trás a retropropagação do erro dentro da rede ocorre de forma convencional. Como as entradas e as variáveis internas do modelo não são normalizadas, é recomendável normalizar cada uma delas para que apresentem média nula e excursão na faixa $(-1,+1)$, para garantir um treinamento numericamente robusto para a rede neural, evitando paralisia e problemas correlatos. Se o neurônio de saída das redes for linear, como é recomendável no caso de aproximadores, não é necessário normalizar a saída da rede, que pode alimentar diretamente a saída do sub-modelo.

V. ANÁLISE E AJUSTE DO MODELO UIT-R

Neste segmento do trabalho os métodos descritos na seção anterior serão aplicados na análise e ajuste do modelo UIT-R [3] e seus sub-modelos. Este modelo foi escolhido por ser o modelo de referência e comparação com os demais modelos apresentados na literatura.

A primeira etapa da implementação do método de ajuste consistiu em dividir o modelo UIT-R em módulos. No total, foram identificados 12 módulos, cada qual representando uma parte do equacionamento do modelo fenomenológico. A segunda etapa corresponde à avaliação da precisão de cada módulo e identificação daqueles que mais contribuem para a degradação do seu desempenho. Para a função objetivo,

$$e(p) = \left(\frac{y - \tilde{y}}{y} \right)^2 \quad (8)$$

onde y corresponde a atenuação medida e \tilde{y} a atenuação estimada, o erro retropropagado da saída do modelo até a saída da rede neural auxiliar do módulo i é determinado por

$$\mathbf{d}_i(p) = \frac{\partial e}{\partial \tilde{y}} \frac{\partial \tilde{y}}{\partial z_i} = -2 \left(\frac{y - \tilde{y}}{y^2} \right) \frac{\partial \tilde{y}}{\partial z_i} \quad (9)$$

A derivada $\partial \tilde{y} / \partial z_i$ pode ser calculada numericamente pela fórmula

$$\frac{\partial \tilde{y}}{\partial z_i} \equiv \frac{\tilde{y}(z_i + 10^{-6}) - \tilde{y}(z_i - 10^{-6})}{2 \cdot 10^{-6}} \quad (10)$$

A avaliação de cada módulo i quanto a sua precisão é feita com base no desvio padrão de \mathbf{d}_i obtido após a apresentação de todos os pares entrada-saída. Os módulos com desvio padrão de \mathbf{d}_i maiores contribuem mais significativamente para a degradação do desempenho do modelo UIT-R. Uma variação de \mathbf{d}_i mais elevada é um indicativo de baixa precisão do módulo. Conseqüentemente, os módulos com esta característica podem ser classificados como os mais críticos para o modelo. A avaliação do desempenho dos módulos foi conduzida de forma independente para diferentes valores de percentagem de tempo e foram utilizados dados para os conjuntos de treinamento e teste distribuídos por um processo estatístico [4]. A Tabela 1 mostra os resultados obtidos para o desvio padrão de \mathbf{d}_i para cada módulo e para os diferentes valores de percentagem de tempo. Cabe ressaltar que os conjuntos de dados utilizados nesta análise possuem experimentos com frequência na faixa de 11 a 20 GHz.

Analisando a Tabela 1 fica evidente que os módulos 5 e 9 são os mais críticos do modelo UIT-R. O módulo 5 corresponde ao fator de redução horizontal ($r_{0.01\%}$) e o módulo 9 ao fator de ajuste vertical ($v_{0.01\%}$) do modelo. A identificação de tais módulos como críticos está de pleno acordo com a análise física do problema [5,6]. O desvio padrão de δ do módulo 6 é nulo para todos os casos. Isto ocorre em virtude do módulo 6 corresponder a um ângulo. Pequenas variações neste ângulo não produzem alterações nos módulos posteriores e, com isto, a derivada numérica $\partial \tilde{y} / \partial z_6$ e o valor de δ se tornam nulos para os diferentes valores de percentagem de tempo. Os módulos 4 e 12 também apresentaram um valor significativo de desvio padrão para alguns valores de percentagem de tempo. No entanto, os módulos 5 e 9 se destacaram mais e foram selecionados para ajustar o modelo UIT-R. O ajuste de poucos módulos contribui para não alterar demasiadamente a estrutura original do modelo fenomenológico. Uma vez identificados os módulos mais críticos, o próximo passo consiste em ajustá-los.

Tabela 1: Desvio padrão de d_i , determinado para cada módulo e para diferentes valores de percentagem de tempo.

	1	2	3	4	5	6	7	8	9	10	11	12
0,001	0,2112	0,0888	0,1036	0,7848	1,2488	0,00	0,1497	0,0171	1,1632	0,1929	0,1539	1,1687
0,002	0,1749	0,0824	0,0948	0,680	0,9611	0,00	0,1252	0,0126	0,9255	0,1601	0,1420	0,6445
0,003	0,1681	0,0690	0,0828	0,6333	0,8235	0,00	0,1137	0,00	0,8081	0,1505	0,1254	0,4327
0,005	0,1489	0,0685	0,0807	0,5822	0,7361	0,00	0,1012	0,0078	0,7235	0,1287	0,1226	0,2144
0,01	0,1327	0,0605	0,0763	0,4902	0,8522	0,00	0,1078	0,0027	0,7833	0,1390	0,1073	0,00
0,02	0,1468	0,0723	0,0875	0,4565	1,1034	0,00	0,1327	0,0034	0,9416	0,1654	0,1084	0,2588
0,03	0,1667	0,0759	0,0965	0,4618	1,2989	0,00	0,1537	0,0033	1,0784	0,1875	0,1235	0,4442
0,05	0,1935	0,090	0,1176	0,4826	1,7215	0,00	0,1838	0,0031	1,3718	0,1487	0,1487	0,7594

Para o processo de ajuste foram conectadas redes neurais em paralelo com os módulos mais críticos. Para isto, foi necessário identificar as variáveis a serem usadas na entrada de cada rede de ajuste de tais módulos. Esta identificação foi feita com base na correlação entre o erro na saída do módulo que está sendo ajustado e as saídas dos módulos predecessores, além das entradas necessárias ao cálculo da atenuação por chuvas, tais como: frequência, polarização, altura da estação, ângulo de elevação e taxa de precipitação. A correlação entre as variáveis foi analisada para cada valor de percentagem de tempo. No entanto, os primeiros estudos foram conduzidos para 0,01% do tempo, que contém um grande número de dados. As observações realizadas a partir desta análise foram estendidas aos outros valores de percentagem de tempo. A Tabela 2 mostra os valores obtidos a partir da correlação de Pearson para os módulos 5 e 9.

Tabela 2: Valores de correlação para os módulos 5 e 9 determinados para 0,01%.

0,01%	Módulo 5 (Z_5)	Módulo 9 (Z_9)
Frequência	0,007	0,007
Polarização	0,0	0,057
Elevação	-0,105	-0,048
Latitudo	-0,296	-0,346
Alt. Estação	-0,245	-0,239
Chuva	0,125	0,147
Z_1	0,098	0,128
Z_2	0,208	0,177
Z_3	0,197	0,162
Z_4	0,119	0,128
Z_5	-0,201	-0,207
Z_6	-0,025	0,024
Z_7	0,151	0,119
Z_8	0,222	0,225
Z_9	-0,064	-0,09
Z_{10}	0,127	0,085
Z_{11}	0,192	0,180
Z_{12}	0,279	0,239
Total de Dados: 165		

Na Tabela 2 a primeira coluna corresponde aos parâmetros do enlace (frequência, polarização, altura da estação, ângulo de elevação, latitude e chuva) e as saídas dos módulos do modelo UIT-R.

Como usual, foi adotado um nível de confiança de 95% para aceitação da correlação, correspondendo a dois desvios padrões, 2σ , da correlação entre dois conjuntos randômicos de mesma dimensão, $P = 165$, conforme a Equação 11.

$$2s_r = \frac{2}{\sqrt{P}} = 0,156 \quad (11)$$

Com base neste valor e nos dados da Tabela 2 foi elaborada a Tabela 3, que mostra as variáveis com correlação significativa com os erros retropropagados até as saídas dos módulos 5 e 9, e já disponíveis quando do cálculo destes módulos.

Tabela 3: Variáveis de forte correlação com os erros retropropagados até as saídas dos módulos 5 e 9.

Módulo 5 (Z_5)	Módulo 9 (Z_9)
Latitude	Latitude
Altitude	Altitude
Z_2	Z_2
Z_3	Z_3
-	Z_5
-	Z_8

Na Tabela 3 as variáveis em negrito-italico são as entradas dos módulos e as demais são variáveis disponíveis que possuem uma relação física com os módulos em questão. A existência de entradas do bloco correlacionadas com o erro retropropagado até a sua saída mostra que a equação representativa do mesmo pode ser aprimorada.

Para cada bloco, as variáveis disponíveis foram então descorrelacionadas das variáveis de entrada que apresentaram correlação significativa com o erro em sua saída. A des correlação foi feita por uma rede neural específica segundo um processo descrito na referência [7].

A Tabela 4 mostra a correlação entre as novas variáveis disponíveis, obtidas a partir da descorrelação, e o erro na saída dos módulos 5 e 9. As saídas Z_3 em relação ao módulo 5 e Z_8 em relação ao módulo 9 não aparecem na Tabela 4 porque já são entradas dos módulos. O limite de confiança continua a ser 0,156. A partir deste valor e da Tabela 4 foi montada a Tabela 5, com as variáveis selecionadas para fazerem parte das entradas das redes neurais responsáveis pelo ajuste dos seus respectivos módulos. Observando os valores da Tabela 4 nota-se que as variáveis disponíveis depois de descorrelacionadas das variáveis de entrada dos módulos 5 e 9 continuaram apresentando uma forte correlação com o erro retropropagado nas saídas dos mesmos. Para a variável Z_5 , módulo 9, o valor de correlação ficou abaixo do limite de confiança e, conforme exposto na seção anterior, esta variável não deve ser aceita como entrada do referido módulo. Esta mesma análise foi conduzida para outros valores de percentagem de tempo e as variáveis disponíveis apresentaram um comportamento similar ao da análise para 0,01% do tempo.

Tabela 4: Correlação entre as novas variáveis disponíveis e o erro na saída dos módulos 5 e 9.

0,01%	Módulo 5 (Z_5)	Módulo 9 (Z_9)
Latitude	-0,354	-0,296
Altitude	-0,235	-0,222
Z_2	0,219	0,186
Z_3	-	0,231
Z_5	-	-0,153

A existência de variáveis que não integravam as entradas dos módulos indica que não era fornecida toda a informação necessária para o cálculo de suas saídas. Na Tabela 5 foram incluídas as variáveis elevação e Z_7 , que não aparecem na Tabela 3. Estas variáveis foram aceitas como entradas das redes neurais responsáveis pelo ajuste dos módulos 5 e 9 por terem apresentado significativa correlação com o erro retropropagado em suas saídas, mesmo depois de descorrelacionadas, quando a análise foi estendida para outros valores de percentagem de tempo. Desta forma, as variáveis listadas na Tabela 5 foram utilizadas para treinar as redes neurais de ajuste dos módulos 5 e 9 para os valores de percentagem de tempo que se estendem de 0,001 a 0,05%. Analisando detalhadamente as expressões dos módulos 5 e 9 observa-se que suas variáveis de entrada possuem uma relação muito estreita com o comportamento físico de tais módulos.

Tabela 5: Variáveis selecionadas como entradas das redes neurais de ajuste dos módulos 5 e 9.

Módulo 5 (Z_5)	Módulo 9 (Z_9)
Latitude	Latitude
Altitude	Altitude
Elevação	Z_2
Z_2	Z_3
Z_3	Z_7
-	Z_8

A etapa final do processo de ajuste do modelo corresponde ao treinamento das redes neurais conectadas em paralelo com os módulos mais críticos. A estrutura adotada para estas redes é idêntica à da rede neural discutida na referência [7] tendo como diferença, apenas, o número de neurônios da camada intermediária e as variáveis de entrada. Após vários testes, verificou-se que dez neurônios na camada intermediária de cada uma das redes eram suficientes para produzir um bom treinamento. O ajuste do modelo UIT-R se dá pelo treinamento simultâneo das duas redes neurais conectadas em paralelo com os módulos 5 e 9 que têm os valores de suas sinapses corrigidos pela regra de aprendizagem descrita em [7]. Os resultados pertinentes ao modelo ajustado e os comentários sobre o seu desempenho serão apresentados na próxima seção.

VI. RESULTADOS

Para avaliar o desempenho do modelo híbrido fenomenológico/neural foi utilizado o mesmo fator de demérito empregado para avaliar os modelos de predição, o erro relativo RMS. Neste trabalho, o erro rms foi determinado para todo o conjunto de dados (treinamento mais teste) e para o conjunto de teste somente, tanto pelo modelo UIT-R quanto para o modelo híbrido e para diferentes valores de percentagem de tempo. Deve-se ressaltar que o conjunto de teste não é utilizado para ajustar as sinapses das redes auxiliares durante o processo de aprendizagem. As Tabelas 6 e 7 mostram os valores do erro rms obtidos para os dois conjuntos de dados citados. Observando estas tabelas nota-se claramente que o erro rms para o modelo híbrido ficou em torno dos 20%. Para o modelo UIT-R original apresentou valores entre 20 e 40%. Na maioria dos casos, acima dos 30%.

Tabela 6: Erro relativo RMS para o conjunto total de dados.

	UIT-R	UIT-R Ajustado
0,001 %	37,55	20,91
0,002 %	32,39	20,44
0,003 %	30,17	22,88
0,005 %	27,78	18,54
0,01 %	29,19	20,69
0,02 %	30,97	23,94
0,03 %	32,07	21,57
0,05 %	34,81	22,83

Tabela 7: Erro relativo RMS para o conjunto de teste.

	UIT-R	UIT-R Ajustado
0,001 %	24,69	22,18
0,002 %	22,51	17,43
0,003 %	28,10	23,63
0,005 %	20,92	16,61
0,01 %	28,46	22,75
0,02 %	26,93	24,46
0,03 %	27,38	22,29
0,05 %	25,62	22,50

VII. CONCLUSÕES

Os resultados alcançados pelo modelo híbrido fenomenológico/neural mostraram a eficiência do processo de análise e ajuste empregado no modelo UIT-R. O erro rms para o modelo ajustado ficou próximo, e algumas vezes, abaixo dos 20% quando analisado para o conjunto total de dados. Para o modelo UIT-R o erro rms ficou acima dos 30% para a maioria dos valores de percentagem de tempo na mesma análise. Desta forma, com o método de ajuste foi possível melhorar a precisão do modelo UIT-R original e identificar corretamente os módulos mais críticos. O método aqui descrito é genérico e os mesmos procedimentos podem ser aplicados para ajustar qualquer modelo fenomenológico.

REFERÊNCIAS

- [1] G. A. Alencar, L. P. Calôba e M. S. Assis, "Performance Investigation of an Artificial Neural Network Used to Predict Radiowave Attenuation by Rain in Earth-Space Paths", URSI Commission F International Triennial Open Symposium on Wave Propagation and Remote Sensing, Aveiro, Portugal, Setembro, 1998.
- [2] G. A. Alencar, L.P. Calôba e M.S. Assis, "Efeito da Chuva Sobre o Desempenho de Terminais VSAT na Transmissão de Dados por Satélite nas Bandas Ku e Ka", XIX Simpósio Brasileiro de Telecomunicações, Setembro, 2001, Fortaleza-CE.
- [3] UIT-R, "Propagation Data and Prediction Methods Required for the Design of Earth-Space Telecommunications Systems", Rec. 618-7, Genebra, 1994.
- [4] G. A. Alencar e L.P. Calôba, "Pré-Processamento de Dados de Baixa Estatística e Sua Aplicação na Previsão por Redes Neurais da Atenuação por Chuvas em Enlaces de Comunicação Via Satélite", XVIII Simpósio Brasileiro de Telecomunicações, Setembro, 2000, Gramado-RS.
- [5] Costa, A.T. e Assis, M.S., "Rain Height Behavior in Low Latitude Areas", Open Symposium on Propagation and Remote Sensing, URSI Commission F, Garmisch-Partenkirchen, Alemanha, Fevereiro, 2002.
- [6] Costa, A.T., "Análise da Atenuação por Chuva em Regiões Tropicais e Equatoriais Aplicada ao Problema do Desempenho de Comunicações por Satélite em Banda Ka", Tese de Mestrado, Instituto Militar de Engenharia, 2002.
- [7] G. A. Alencar, "Previsão de Atenuação por chuvas em Enlaces Terra-Satélite Utilizando Redes Neurais Artificiais", Tese de Doutorado, Universidade Federal do Rio de Janeiro, Março, 2003.