

Inversão do modelo SAIL para estimativa do índice de área foliar através de Redes Neurais Artificiais.

Rafaelle Silva Schimith¹
José Marinaldo Gleriani¹
Mauro Antonio Homem Antunes²
Jairo Rodrigues Silva¹
Cecília Félix Andrade¹

¹ Universidade Federal de Viçosa - DEF/UFV
36571-000 - Viçosa – MG Brasil
{rafaelle@yahoo.com, gleriani@ufv.br}

² Universidade Federal Rural do Rio de Janeiro - /UFRRJ
– Seropédica - RJ Brasil
mantunes@ufrj.br

Abstract. O objetivo desse trabalho foi obter os valores de IAF simulados com o modelo SAIL (Scattering Arbitrally by Inclined Leaves) com uma rede neural de retropropagação do erro. Apesar do coeficiente de determinação obtido (0,95) observou-se dispersões tendenciosas a equação linear obtida. Novas simulações assim como possibilidade de aplicação prática são discutidas

Palavras-chave: canopy reflectance model, SAIL, neural network, leaf area index.

1. Introdução

A partir do final do século XX, com o lançamento de inúmeros sensores orbitais, principalmente como programa EOS (Earth Observation System), existe um grande expectativa da comunidade científica com relação à potencialidade desses dados para extração de informações quantitativas dos alvos terrestres. Dentre os alvos terrestres – os dosséis vegetais – quantificados pelo parâmetro biofísico Índice de Área Foliar (IAF), tem sido um dos principais focos de pesquisa, pois esse parâmetro é essencial para modelos hidrológicos, de produtividade agrícola, de evapotranspiração, etc. Para extrair essas informações, novas ferramentas computacionais, como sistemas especialistas, algoritmos genéticos e redes neurais têm sido utilizados; tais ferramentas permitem análise realista e integrada desses dados que sofrem complexas interações antes serem registrados por sensores orbitais. As redes neurais têm sido utilizadas tanto para a modelagem da refletância espectral, como para inversão de modelos cuja complexidade e precisão são inversamente proporcionais à possibilidade de inversão. Assim, o foco desse trabalho é a inversão de simulações feitas com o modelo SAIL (Scattering Arbitrally by Inclined Leaves) utilizando uma rede de MLP (Multilayer Perceptrons) de retropropagação do erro.

2. Revisão Bibliográfica

A obtenção de dados quantitativos tem sido um dos desafios do sensoriamento remoto (Myneni, et al., 1995; Verstraete et al. 1996), embora os dados sejam meramente a “radiação eletromagnética medida a centenas de quilômetros” a comunidade científica está interessada em informações ambiciosas como seqüestro de carbono, produtividade agrícola, fluxo de energia, etc (Verstraete et al., 1996).

Nos últimos 30 anos, esforços em encontrar um parâmetro biofísicos que melhor quantificam o dossel vegetal, parâmetros como a percentagem de cobertura do solo, fitomassa úmida foram utilizados (Tucker, 1979; Holben, 1980), no entanto, o IAF e a APAR (Radiação Fotossintética Absorvida) são “parâmetros chave” de consenso na comunidade científica, pois são muito relacionados a refletância espectral (Baret et al., 1991), sejam pelas inúmeros usos do parâmetro (IAF) em diversos modelos de produtividade de ecossistemas (Running et al., 1989), ou pela razão anterior associada a versatilidade de situações (p.e: ângulo solares e aerossóis) com simples modelos de regressão lineares como fração absorvida da APAR - a f APAR (Myneni et al. 1995).

Quanto aos métodos de estimativa, muitos parâmetros biofísicos (PB) tem sido estimados via regressão com Índices de Vegetação (IV) através de relações do tipo $PB=f(IV)$, no entanto, apesar dos esforços em propor nossos índices, os melhores índices também são os mais influenciados por fatores não vegetativos (Daughtry et al., 2000; Danson et al., 2003), além de que as equações são válidas somente para um sensor ou família de sensores; específicas para uma dada geometria de aquisição, aerossóis entre outros fatores o que dificulta a generalização de equações obtidas para outras partes do globo (Vertraete et al., 1996; Walthall, 2004) simplificando muito a análise de um dado de natureza muito complexa (Myneni et al., 1995).

Myneni et al. (1995) após revisão dos fatores que interferem na resposta espectral de alvos vegetados apontam para novas ferramentas computacionais como algoritmos genéticos, sistemas especialistas, inversão de modelos e redes neurais. Tais ferramentas permitem uma integração mais detalha das características do alvo (arquitetura), e a geometria de aquisição entre outros. Fang et al. (2003) afirmam que além das redes neurais (RNA) as LUTs (“Look-up-table”) tem-se mostrados como promissoras ferramentas de análise. As LUT são bancos espectrais, onde para cada medida espectral existe uma comparação com medidas armazenadas, onde pelo menor valor da função de mérito, a solução é encontrada.

As redes neurais têm sido utilizadas na obtenção de parâmetros biofísicos de diferentes maneiras. Abuelgasim et al. (1998) utilizaram as redes de perceptrons de multicamadas para modelagem direta e inversa de dosséis florestais. Na modelagem direta os parâmetros estruturais, assinaturas espectrais, e geometria de aquisição foram utilizadas para modelar a refletância bidirecional. Na modelagem inversa a refletância bidirecional anteriormente modelada, as assinaturas espectrais e a geometria de aquisição modelaram a saída da rede com três parâmetros: densidade, forma e altura do dossel.

Gong et al. (1999) utilizaram m rede MLP para inverter parâmetros simulados pelo “Coupled Atmosphere and Canopy” (CAC) em 64 ângulos de visada. A inversão foi realizada para a obtenção de um único parâmetro (LAI), dois parâmetros LAI e τ_{ae} (profundidade óptica de aerossóis) e até cinco parâmetros IAF, τ_{ae} , R_s (refletância do solo) e Distribuição angular de folhas (μ e ν). Com o aumento do número de parâmetros existiu um aumento de um para 17% no erro relativo entre os dados simulados e os recuperados.

Segundo Kimes et al (1998), os modelos são sistemas não lineares e complexos que possuem soluções inversas por métodos numéricos computacionalmente morosos principalmente quando aplicados em grandes áreas numa base pixel a pixel. Por isso, os modelos precisam ser simplificados para uma precisa inversão, no entanto, a redução dos parâmetros ou a simplificação da função de transferência radiativa, o que leva a resultados pouco precisos do que modelos completos. Com precisa inversão e em razoável tempo computacional as redes neurais artificiais têm-se mostrado promissoras.

O propósito deste trabalho foi simular com o modelo SAIL (“Scattering by Arbitrarily Inclined Leaves”) (Verhoef, 1984), uma grande variedade de cenários e utilizar uma rede MLP para a inversão do modelo para a obtenção do índice de área foliar (IAF).

3. Materiais e Métodos

Com o uso do modelo SAIL fez-se a simulação de diferentes cenários para um dossel vegetal. Embora não tenha sido simulado espécies diferentes (os valores de transmitância e a refletância da folha foram mantidos constantes), simulou-se 51 valores de IAF, com o valor inicial de 0,05, o segundo de 0,1 e depois incrementos sucessivos de 0,1 até o valor final 5. Optou-se por suas duas arquiteturas de dossel (planófila e erectófila), cuja frequência cumulativas são ilustradas na **Figura 1**.

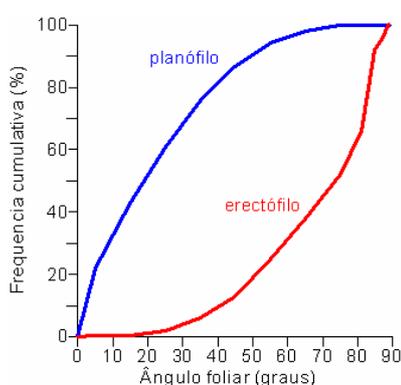


Figura 1 – Frequência cumulativa de duas distribuições angulares utilizadas na simulação.

Foram simulados sete ângulos azimutais solares (0, 30, 60, 90, 120, 150 e 180°) e três ângulos zenitais (0, 30 e 60°), totalizando 21 ângulos solares. Todas as visadas foram simuladas a nadir.

Para as bandas TM/Landsat 1, 2, 3 e 4 utilizou-se dois tipos de solos – alta e baixa refletância (**Figura 2**). Todos esses parâmetros de entrada totalizaram 4284 cenários.

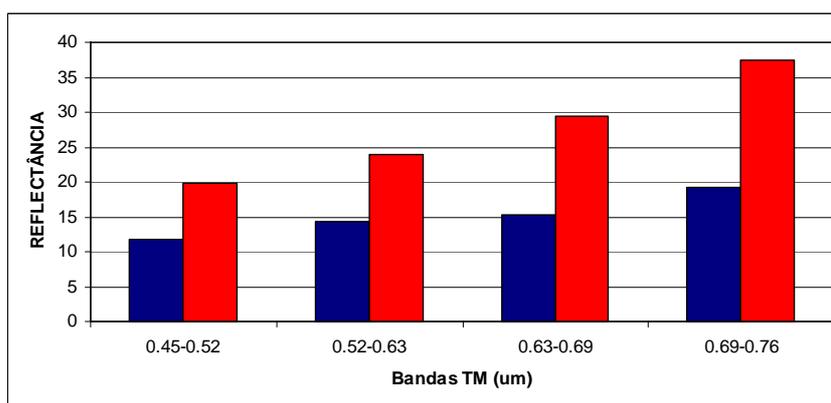


Figura 2 – Solo de alta (vermelho) e baixa refletância (azul) utilizados no modelo.

Utilizou-se 30% dos dados para treinamento de uma rede MLP, treinada com o algoritmo de retropropagação do erro com taxa de aprendizagem (η) de 0,2. A rede foi treinada com apenas 400 épocas para evitar sobre-treinamento. Para a arquitetura da rede, fez a opção da entrada por variáveis *dummy* (zero – planófilo; um - erectófilo) uma vez obtém boa plasticidade da rede para diferentes espécies Gorgens (comunicação pessoal).

Em ambiente SNNS (Zell et al., 1998), criou-se a rede com a arquitetura 13-7-1, mesmo fazendo-se a opção do ângulo zenital e azimutal de visada com valores zero, manteve-se as duas entradas, pois as redes têm a flexibilidade de inserção de futuros parâmetros (Kimes et al., 1998) e visadas direcionais podem ser simuladas. Todos os dados de entrada e saída foram normalizados para o valor máximo de 0,9 e os valores de saída foram reescalados para o intervalo 0,05 a 5. A rede foi treinada com entrada de dados aleatória. A **Figura 3** ilustra a rede utilizada e dos dados de entrada.

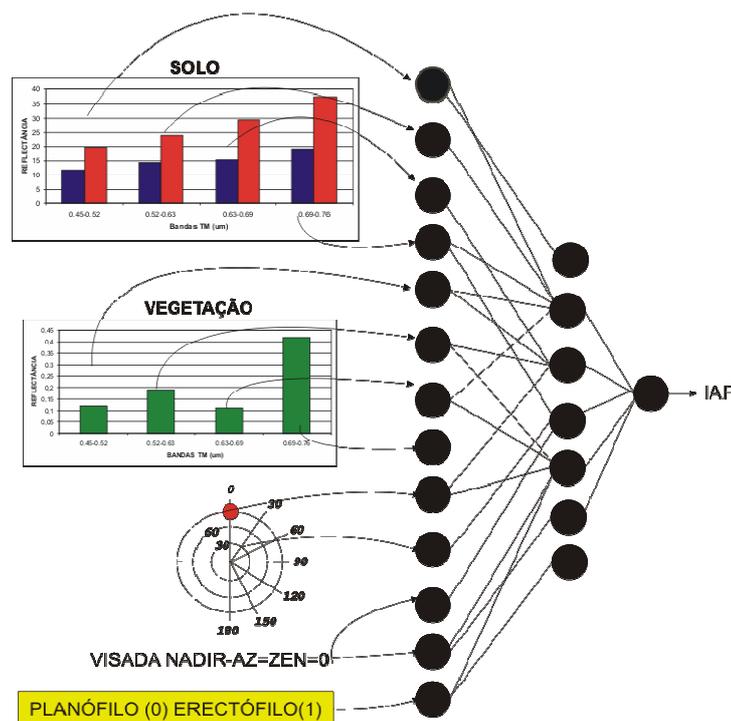


Figura 3 – Arquitetura da rede utilizada e parâmetros de entrada.

4. Resultados e Discussão

O resultado da estimativa da RNA é ilustrado na **Figura 4** com a correspondente equação de regressão. Os valores estimados via RNA apresentaram um coeficiente de determinação de 0,95.

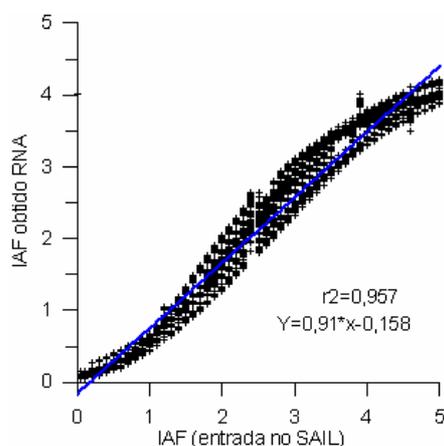


Figura 4 – IAF obtido via RNA *versus* simulação com modelo SAIL.

A dispersão dos pontos aponta para subestimação e sobreestimação dos valores e novas simulações devem ser feitas excetuando-se as mudanças de arquitetura de dossel ou tipo de solos par analisar o parâmetro crítico na estimação. A opção da entrada da arquitetura via variável *dummy* (0 – 1) ao contrário de se utilizar mais uma dezena de neurônios para entrada dos valores de frequência acumulada para cada arquitetura.

A precisão de um modelo aponta para complexidade e grande números de parâmetros, já a “inversibilidade” aponta para a simplicidade e redução de parâmetros (Jacquemoud et al. 1995; Kimes et al., 1998). Muitos estudos relatam inversão de modelos pela minimização da função de mérito. A inversão descrita nesse trabalho utiliza, com exceção da refletância e transmitância foliar, que foi assumida constante (uma espécie) os mesmos parâmetros de entrada utilizados no modelo SAIL. Um dos questionamentos a serem levantados é se a inversão de modelos via rede é possível. Os ângulos zenitais e azimutais solares são obtidos via arquivos descritores das cenas, a maioria dos sensores (TM, ETM+, CCD/CBERS) fazem visadas a nadir e, finalizando, tanto a arquitetura como o tipo de solo envolvem um conhecimento *a priori* (espécies) cultivadas em uma determinada região, e a consultas via banco de dados georreferenciados em SIG.

Agradecimento

Os autores agradecem o apoio da FAPEMIG

Referências

- Abuelgasim, A. A.; Gopal, S.; Strahler, A. H. Forward and inverse modelling of canopy directional reflectance using a neural network. **International Journal of Remote Sensing**, v.19, n.3, p.453-471, 1998.
- Baret, F., Guyot, G. Potentials and limits of vegetation indices for LAI and APAR assessment. **Remote Sensing of Environment**, v.35, n.1, p.161-173, 1991.
- Danson, F.M.; Rowland, C.S.; Baret, F. Training a neural network with a canopy reflectance model to estimate crop leaf area index, **International Journal of Remote Sensing**. v.24, n.23, p.4891-4905, 2003.
- Daughtry, C.S.T.; Walthall, C.L.; Kim, M.S.; Colstoun, E.,B.; McMurtrey III, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance, **Remote Sensing of Environment**. v.74, n.1, p.229-239, 2000.
- Gong, P.; Wang, D.X.; Liang, S. Inverting a canopy reflectance model using a neural network, **International Journal of Remote Sensing**, v.20, n.1, p.111-122, 1999.
- Gorgens, E. B. (comunicação pessoal).
- Holben, B.N.; Tucker, C.J.; Fan, C-J. Spectral assessment of soybean leaf area and leaf biomass. **Remote Sensing of Environment**. v.46, n.5, p.651-656, 1980.
- Kimes, D.S.; Nelson, R.F.; Manry, M.T.; Fung, A.K. Attributes of neural networks for extracting continuous vegetation variables from optical and radar measurements. **International Journal of Remote Sensing** v.19, n.14, p.2639-2663, 1998.
- Myneny, R.B.; Maggion, S.; Iaquina, J.; Privette, J.L.; Gobron, N.; Pinty, B.; Kimes, D. S.; Verstraete, M.M.; Williams, D.L. Optical remote sensing of vegetation: Modeling, Caveats, and Algorithms. **Remote Sensing of Environment**, v.51, n.1, p.169-188, 1995.
- Running, S.W.; Nemani, R. R.; Peterson, D.L.; Band, L. E.; Potts, D.F.; Pierce, L.L.; Spanner, M.A. Mapping regional forest evapotranspiration and photosynthesis by coupling satellite data with ecosystem simulation, **Ecology**, v.70, n., p.1090-1101, 1989.
- Tucker, C.J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**. v.8, n.2, p.127-150, 1979.
- Verstraete, M.M.; Pinty, B.; Myneni, R.B. Potential and limitations of Information extraction on the terrestrial biosphere from satellite remote sensing. **Remote Sensing of Environment**, v.58, n.1, p.201-214, 1996.

Verhoef, W. Light scattering by leaf layers with applications to canopy reflectance modeling: The SAIL model, **Remote Sensing of Environment**, v.48, n.2, p.119-126, 2004.

Walthall, C. L.; Dulaney, W.; Anderson, M.; Norman, J.; Fang, H.; Liang, S. A comparison of empirical and neural network approaches for estimating corn and soybean leaf area index from Landsat ETM+ imagery. **Remote Sensing of Environment**, v.92, n.3, p.465-474, 2004.

Zell, A.; Mamier, G.; Mache, M.V.N.; Hübner, R.; et al. **SNNS – Stuttgart Neural Network Simulator v.4.2**, User Manual, University of Stuttgart/ University of Tübingen, 1998, 338p.