

## IDENTIFICAÇÃO DE ÁREAS DESFLORESTADAS NA AMAZÔNIA ATRAVÉS DE UMA REDE NEURAL ARTIFICIAL UTILIZANDO IMAGENS FRAÇÃO DERIVADAS DOS DADOS DO IR-MSS/CBERS

VIVIANE TODT DIVERIO  
ANTÔNIO ROBERTO FORMAGGIO  
YOSIO SHIMABUKURO

INPE - Instituto Nacional de Pesquisas Espaciais  
Caixa Postal 515 - 12201-970 - São José dos Campos - SP, Brasil  
{viviane, formagg, yosio}@ltid.inpe.br

**Abstract.** This paper show the classification obtained with a artificial neural network to mapping Brazilian Amazon areas. The new approach is based on fraction images generated by linear spectral mixture modeling and used like input to network.

**Keywords:** remote sensing, artificial neural networks, CBERS satellite, linear spectral mixture.

### 1. Introdução

Neste início do século XXI, observa-se um incremento no emprego de dados obtidos através de sensores remotos orbitais para fins de mapeamento, gerenciamento e monitoramento do meio ambiente. Isto deve-se, dentre vários fatores, à crescente preocupação com os Recursos Naturais, disponíveis no planeta, para que sejam utilizados de maneira sustentável tanto ambientalmente, quanto economicamente e socialmente.

Com o Programa CBERS (*China-Brazil Earth Resources Satellite*), cujo primeiro satélite, o CBERS-1, está em órbita desde 1999, os dois países envolvidos passam a dispor de um sistema completo de sensoriamento remoto competitivo e compatível com as necessidades internacionais atuais (INPE, 2002a). Em termos brasileiros e, também, com forte preocupação mundial, a Amazônia representa um território, de aproximadamente 5 milhões de quilômetros quadrados, que necessita ser constantemente monitorado devido à ação antrópica existente.

Por outro lado, desde meados da década de 80, as Redes Neurais Artificiais (RNA's) vêm sendo utilizadas como ferramenta de grande potencial para classificações de imagens multiespectrais obtidas por sensores a bordo de plataformas orbitais (Atkinson e Tatnall, 1997; Benediktsson et al., 1990).

Assim, dentro desse contexto, esse artigo mostra os resultados obtidos com o uso de uma Rede Neural Artificial Multinível com *BackPropagation* utilizada para a identificação de áreas desflorestadas na Amazônia. A inovação está na forma como os dados foram gerados e submetidos à rede que, por sua vez, em conjunto com imagens do sensor IR-MSS, apresentou resultados promissores sobre o uso dessa técnica, para mapeamento e monitoramento da região.

### 2. Rede Neural Artificial Multinível com *BackPropagation*

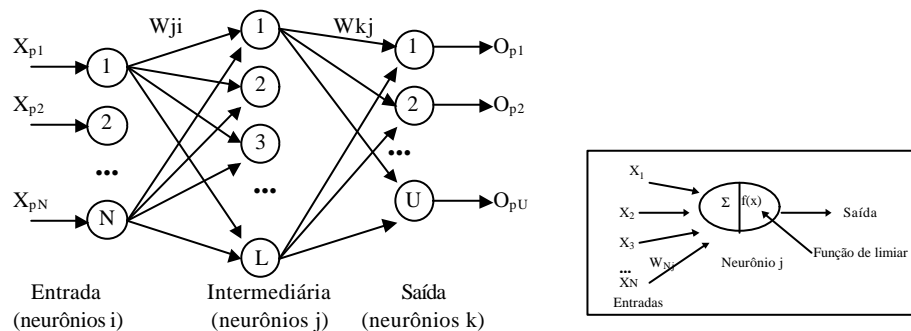
Uma Rede Neural é um conjunto de elementos processadores individuais (neurônios) com várias entradas e uma única saída, interconectados através de pesos sinápticos e agrupados sob as mais diversas topologias (**Figura 1**). Cada neurônio recebe nas suas entradas valores das saídas dos neurônios conectados a ele. Esses sinais de entrada (X) são multiplicados pelos respectivos pesos sinápticos das conexões (W) e somados, gerando um valor de ativação. O valor de saída do neurônio é resultado da comparação entre o seu valor de ativação e um determinado valor de limiar definido previamente (Todt, 1998).

A rede tem a capacidade de aprender por indução, a partir de um conjunto de treinamento. Durante essa etapa, os pesos sinápticos são ajustados de acordo com procedimentos matemáticos específicos, tais como: otimização discreta, minimização de erros, *clusterização* de vetores, entre outros, que determinam como será realizado o treinamento, ou aprendizado, da Rede Neural. No final desse processo, o conhecimento adquirido do conjunto de treinamento será representado pelo conjunto de pesos da rede.

Haykin (2001) cita e descreve o funcionamento de alguns modelos de Redes Neurais, tais como os Mapas Auto-Organizáveis, *Perceptrons* de Múltiplas Camadas e Redes Recorrentes. Dentre eles, o modelo Multinível com *BackPropagation* (*Perceptrons* de Múltiplas Camadas), utilizado em aplicações de Sensoriamento Remoto, tem apresentado resultados promissores quando comparado aos métodos comumente utilizados para a classificação de imagens multiespectrais (Heermann e Khazenie, 1992; Engel, 1992; Nunes, 1995).

Esse modelo, apresentado por Rumelhart et al.(1986), é capaz de resolver problemas de reconhecimento de padrões complexos, através de funções que mapeiam valores de entrada da rede com valores de saída desejados. A rede apresenta três ou mais camadas de neurônios: uma camada de entrada (*input layer*), uma ou mais camadas intermediárias (*hidden layer*) e uma camada de saída (*output layer*). A sua topologia é totalmente interconectada para frente (*feedforward*), não existindo conexões retro-alimentadas, e onde nenhuma conexão passa diretamente por sobre uma outra mais a frente (**Figura 1**).

O número de neurônios das camadas de entrada e de saída é definido de acordo com o problema ao qual a rede tentará solucionar. Entretanto, não existe uma regra que defina o número de neurônios intermediários, ou até mesmo o número de camadas intermediárias, de maneira que isto deve ser definido de forma intuitiva. Inicialmente, se o número de neurônios definido for muito alto, isto pode fazer com que apenas alguns neurônios especializem-se em características úteis. Porém, se o contrário ocorrer e o número de neurônios for insuficiente, pode acontecer da rede não conseguir aprender os padrões desejados.



**Figura 1 - RNA Multinível com *BackPropagation* (esq.) e o Modelo de um Neurônio Formal (dir.).**  
**Adaptação: Freeman e Skapura (1991)**

Outra característica desse modelo é o aprendizado supervisionado baseado em duas fases: propagação e adaptação. O treinamento ou aprendizado supervisionado (*supervised-learning*) consiste em fornecer à rede um conjunto de estímulos (padrões de entrada) e a saída desejada correspondente. Inicialmente, o primeiro padrão de entrada é propagado até a saída (fase de propagação). Após, na fase de adaptação, um sinal de erro na saída é computado e transmitido de volta para cada neurônio da camada intermediária que contribuiu para a saída obtida. Desta forma, cada neurônio da camada intermediária recebe somente uma parte do erro total, conforme a contribuição relativa que o neurônio teve na saída gerada. Este processo repete-se, camada por camada, até que cada neurônio da rede receba o seu erro

correspondente. Daí o nome *BackPropagation*, pois o aprendizado baseia-se na propagação retrógrada do erro para níveis superiores da rede. Em seguida, os pesos existentes nas conexões entre os neurônios são atualizados de acordo com o erro recebido pelo neurônio associado. Esta regra de aprendizado é uma generalização da Regra LMS (*Least Mean Square Error*), também conhecida como Regra Delta.

O processo de aprendizado, com as devidas alterações de pesos, permanece até o momento em que a saída obtida pela Rede Neural, para cada um dos padrões de entrada, seja próxima o bastante da saída desejada, de forma que a diferença entre ambas seja aceitável. Essa diferença é obtida através do cálculo do Erro Médio Quadrado. Considera-se diferença aceitável aquela que for menor ou igual a um erro previamente estipulado, em geral 1% ou 0.5%. Em Haykin (2001), Todt (1998) e Freeman e Skapura (1986) pode-se obter uma descrição detalhada do algoritmo de *BackPropagation*, além de dicas que poderão orientar o leitor durante a etapa de treinamento da rede.

### 3. Área de Estudo

Como área de estudo para o presente trabalho, foi selecionada a imagem órbita 175 /ponto 110 do sensor IR-MSS (*Infra-Red Multispectral Scanner*), do satélite CBERS-1, obtida em 29 de julho de 2000 que cobre cerca de 14.400 km<sup>2</sup> na região de Porto Velho, Estado de Rondônia, entre as latitudes 07<sup>o</sup> 50" e 09<sup>o</sup> 03" S e entre as longitudes 64<sup>o</sup> 10" e 62<sup>o</sup> 52" O. Essa área foi escolhida por representar significativamente os padrões de desflorestamentos ocorridos na Amazônia brasileira. É caracterizada, também, pela presença do rio Madeira, que atravessa a cena no sentido nordeste/sudoeste, pela Represa Samuel e pela existência de algumas áreas florestais e de outras sem fisionomia florestal predominante (como o cerrado).

### 4. Materiais e Métodos

Conforme citado no item 3, os dados utilizados nesse trabalho foram obtidos do satélite CBERS-1, sensor IR-MSS. Esse satélite está em uma órbita sol-síncrona e cruza o Equador sempre às 10:30 h da manhã, hora local, provendo assim as mesmas condições de iluminação solar para tornar possível a comparação de imagens adquiridas em dias diferentes. Encontra-se a uma altitude nominal de 778 km, completando 14 revoluções por dia. Isto permite que uma determinada área seja imageada a cada 26 dias (resolução temporal).

A câmara de Varredura no Infravermelho (IR-MSS) opera em quatro faixas espectrais, estendendo o espectro de observação do CBERS até o infravermelho termal: B1 (banda pancromática / 0,50 – 1,10 µm); B2 (infravermelho médio / 1,55 – 1,75 µm); B3 (infravermelho médio / 2,08 – 2,35 µm); B4 (infravermelho termal / 10,40 – 12,50 µm), produzindo imagens numa faixa de 120 km, com 80 m de resolução espacial nominal para as três primeiras bandas e 160 m para a banda termal (INPE, 2002a).

A metodologia adotada consistiu das seguintes etapas: definição e execução do Modelo Linear de Mistura Espectral, experimentos com a Rede Neural Multinível com *BackPropagation* e análise qualitativa dos resultados obtidos. As próximas seções mostram como cada uma dessas etapas foi realizada.

#### 4.1. Modelo Linear de Mistura Espectral

O modelo de mistura foi concebido a partir do princípio básico (e aplicável para as resoluções espaciais dos sensores atuais) de que um determinado *pixel* de uma cena representa a radiância média refletida ou emitida pelos alvos da superfície terrestre. Dessa maneira, para um *pixel* do sensor IR-MSS que equivale, nominalmente, a 80 m x 80 m, pode-se assumir o princípio de que o mesmo é o resultado da mistura (integração) de basicamente três tipos de

uso da terra: vegetação, solo e sombra (ou água). Assim, o modelo baseia-se em obter o quanto cada componente contribui na formação de cada *pixel* da cena em cada uma das bandas consideradas através da seguinte equação (Moreira, 2001):

$$R_i = a * \text{vegetação}_i + b * \text{solo}_i + c * \text{sombra}_i + e_i$$

onde  $R_i$  representa a reflectância de um determinado *pixel* na banda  $i$ ;  $a, b$  e  $c$  são as proporções a serem estimadas;  $\text{vegetação}_i$ ,  $\text{solo}_i$  e  $\text{sombra}_i$  são as respostas espectrais dos componentes de vegetação, solo e sombra;  $e_i$  é o erro para a banda  $i$ . Esse modelo é baseado no método dos Mínimos Quadrados de tal forma que as proporções sejam obtidas minimizando a soma dos quadrados dos erros para cada banda (INPE, 2002b).

Assim, a primeira etapa desse trabalho foi a decomposição das bandas 1, 2 e 3 do sensor IR-MSS nas componentes de vegetação, solo e sombra (gerando três imagens fração correspondentes) através do método dos Mínimos Quadrados com Restrições. Após a aplicação desse método, as proporções estimadas de cada componente foram normalizadas para o intervalo de 0 a 255. Para isso, esses valores de proporção entre 0.0 e 1.0 foram escalonados para os contadores digitais entre 100 e 200, permitindo que os valores maiores do que 1.0 e menores do que 0.0 também pudessem ser representados.

Todo esse processo foi executado através da opção Imagem/Modelo de Mistura do *software* SPRING (Sistema de Processamento de Informações Geo-referenciadas), versão 3.6.02, sendo a etapa que antecedeu ao processo de classificação que será descrito a seguir.

## 4.2. Experimentos

Após a preparação dos dados pelo Modelo de Mistura, iniciou-se o processo de classificação das imagens de satélite através de uma Rede Neural Multinível com *BackPropagation*. Essa rede (onde considera-se a topologia, o algoritmo de aprendizado e a etapa de reconhecimento) foi implementada, em linguagem de Programação C padrão, por Todt (1998) e utilizada para a identificação de espécies vegetais na região de Santo Amaro, ao sul do Brasil. Nessa pesquisa, a mesma foi adaptada para que pudesse ser treinada a identificar áreas de desmatamento, áreas de floresta nativa, áreas sem cobertura florestal (cerrados e áreas em regeneração) e água.

A camada de entrada da rede neural foi composta por três neurônios de entrada (um para cada imagem fração gerada pelo modelo de Mistura) e a camada de saída foi formada com quatro neurônios (cada neurônio representando uma das classes temáticas citadas anteriormente). A saída é exclusiva de tal modo que a rede, ao receber um impulso de entrada ao qual ela realmente aprendeu, apenas um neurônio (ao da classe temática correspondente) deve responder. Caso haja confusão no aprendizado de um padrão de entrada, nenhum neurônio de saída ultrapassa o limiar de ativação ou mais de um neurônio de saída é ativado simultaneamente. Em ambas as situações, o padrão é atribuído à uma classe dita desconhecida.

Esse processo consistiu de duas etapas: a etapa de aprendizado e a etapa de reconhecimento. Na etapa de aprendizado, vários experimentos foram executados com diferentes quantidades de neurônios dispostos em uma única camada intermediária, considerando vários coeficientes de aprendizado e distintos números de iterações. A **Tabela 1** mostra os experimentos realizados e o erro médio obtido para cada um deles.

**Tabela 1 – Experimentos realizados e parâmetros para a Rede Neural**

<i>Teste</i>	<i>Iterações</i>	<i>Coef.aprend.</i>	<i>Neur.interm.</i>	<i>EMQ</i>
01	50.000	0.01	10	0.326285
02	50.000	0.01	30	0.303287
03	200.000	0.01	100	6.000000
04	50.000	0.01	6	0.393845
05	50.000	0.01	60	6.000000
06	50.000	0.01	40	0.334581
07	50.000	0.05	40	6.000000
08	50.000	0.05	3	0.477386
09	50.000	0.05	2	0.582943
10	50.000	0.05	1	0.904028
11	50.000	0.5	40	2.000000
12	50.000	0.2	40	0.533329
13	50.000	0.35	40	1.550000
14	500.000	0.2	40	0.666000

Para todos os testes acima, a rede neural foi treinada com um conjunto de 240 *pixels* (60 por classe) intercalados com o propósito de que a rede aprendesse todos os padrões e não se especializasse em nenhum deles. A **Figura 2** mostra parte do arquivo de treinamento utilizado. A primeira linha é composta pelo número de iterações, erro aceitável e coeficiente de aprendizado. A segunda linha contém o número de neurônios da camada de entrada, da camada intermediária e da camada de saída. A terceira linha possui o número de amostras para treinamento e o número 1 indica que a saída da rede é exclusiva. Após o sinal separador (#), seguem os valores de cada *pixel* de cada componente do Modelo Mistura (vegetação, solo e sombra) normalizados entre -1 e 1, visto que a função de ativação dos neurônios empregada foi a Tangente Hiperbólica. Entretanto, os pesos iniciais da rede foram gerados aleatoriamente dentro do intervalo [0;1].

```

500000 0.001 0.2
3 40 4
240 1
#
0.631 -0.341 -0.169 1
-0.114 0.004 0.239 2
0.325 -0.035 -0.169 3
-0.247 0.529 -0.161 4

```

**Figura 2 – Arquivo de treinamento para a Rede Neural**

A etapa de reconhecimento consistiu na leitura do arquivo de pesos, ajustados na fase de treinamento, e a introdução de cada um dos *pixels* dos componentes do modelo Mistura à entrada da rede neural para que a mesma fizesse a classificação de toda a área de estudo, juntamente com o número de linhas (1684) e de colunas (1792) da cena.

### 4.3. Pós-classificação

A etapa final consistiu em uma análise qualitativa para selecionar a melhor classificação digital obtida dentre os 14 experimentos realizados com a rede neural. Essa escolha foi feita comparando-se qualitativamente os mapas temáticos gerados com um mapa previamente confeccionado para servir de verdade terrestre. Essa, por sua vez, foi criada através da classificação das bandas originais (1, 2 e 3), do sensor IR-MSS, pelo método ISOSEG, seguido de um cuidadoso processo de edição matricial que refinou e melhorou a classificação

de maneira que a mesma pudesse ser utilizada como verdade terrestre para o classificador neural.

Por fim, a imagem classificada pela rede neural (teste número 12) foi importada como TIFF, no SPRING, convertida para o modelo Temático e refinada pelo processo de pós-classificação (adotou-se peso e limiar iguais a 3).

A próxima seção apresenta e discute os resultados obtidos para cada teste realizado e os avalia com relação a exatidão obtida.

## 5. Resultados e Conclusões

A etapa de reconhecimento da rede neural, executada em cada um dos testes previamente citados, gerou 14 (catorze) mapas temáticos. Desse total, apenas, 4 (quatro) mostraram-se mais próximos do mapa adotado como verdade terrestre. Analisando-se, visualmente, os mapas gerados, verifica-se que as melhores classificações foram obtidas com os testes 01, 02, 06 e 12. E, dentre esses, o teste 12 mostrou uma maior exatidão ao ser comparado tanto com a verdade terrestre quanto com a composição colorida obtida com as bandas originais 1,2 e 3 do sensor IR-MSS (**Figura 5**). A **Figura 3** mostra a verdade terrestre adotada e a **Figura 4** apresenta o resultado do teste 12 obtido com a rede neural. Para ambos os casos adotou-se a seguinte convenção: cor laranja para áreas desflorestadas, cor verde para áreas de florestas, cor rosa para áreas sem fisionomia florestal predominante (o que inclui áreas de cerrado) e cor azul para água. Nota-se que no mapa temático gerado pela rede neural existe, ainda, a classe desconhecida que está sendo representada pela cor branca.

Observa-se que, para este tipo de aplicação, o EMQ (erro médio quadrado) indica o quanto a rede neural aprendeu dos padrões que lhe foram repassados durante a fase de aprendizado, porém um menor EMQ não significa, necessariamente, um melhor resultado na classificação final. Existe um "ponto ótimo" onde a classificação da rede estará mais próxima da verdade terrestre, porém isto nem sempre é simples de ser definido. Um número excessivo de iterações (teste 14) e de neurônios intermediários (testes 3 e 5) e um valor inadequado para o coeficiente de aprendizado (testes 11 e 13) podem fazer com que haja convergência da rede até certo ponto e que, em determinado momento, o EMQ não mais se altere, estagnando em valores altos e indicando um aprendizado insatisfatório dos próprios padrões de entrada. Porém, quando isto ocorre existe uma alta probabilidade de que o resultado final da classificação também seja insatisfatório. Salienta-se que o teste 11, apesar de possuir 40 neurônios intermediários, o alto valor utilizado como coeficiente de aprendizado fez com que a rede não identificasse nenhuma das classes consideradas. Já o teste 10, que utilizou apenas um neurônio intermediário, gerou um mapa com duas classes (desconhecida e floresta).

Dos testes realizados, verificou-se que os parâmetros mais adequados foram: 50.000 iterações, coeficiente de aprendizado 0.01 e 0.2 e um número de neurônios intermediários cerca de dez vezes o número de neurônios de entrada, em vista da complexidade apresentada pelos padrões de entrada. Analisando-se, visualmente, os resultados do teste 12, observa-se que a rede conseguiu identificar com boa exatidão as áreas de desflorestamentos, de florestas, de não florestas e de água. Classes que apresentaram confusão e que não puderam ser corretamente identificadas pela rede neural foram atribuídas à classe desconhecida. Nota-se, entretanto, que a maior confusão ocorreu entre as áreas de desflorestamento e de não florestas (cerrado).

O modelo de rede neural utilizado nessa pesquisa é bastante simples se comparado com outros modelos existentes na literatura. Entretanto, conclui-se que o mesmo apresentou resultados promissores ao ser utilizado em conjunto com os componentes do Modelo Linear de Mistura Espectral. Em parte, isto poderia ser explicado pelo fato de que o modelo de mistura pode ser utilizado de maneira a reduzir o número de informações das bandas originais

para um conjunto de três bandas que contenham as informações mais relevantes sobre os alvos considerados. E, por sua vez, essa redução do espaço de atributos pode facilitar o aprendizado da rede neural.

Por fim, como continuidade dessa pesquisa, sugere-se uma cuidadosa análise quantitativa dos mapas gerados e o emprego de uma nova banda, à entrada da rede, capaz de separar/identificar melhor as áreas desflorestadas das áreas sem fisionomia florestal dominante. Nesse caso, seria indicado averiguar-se sobre o emprego de outros sensores, como o CCD (do CBERS-1) ou o ETM (do satélite LANDSAT-7), em conjunto com o sensor IR-MSS.




Figura 3 – Verdade Terrestre




Figura 4 – Classificação Digital pela RNA (Teste 12)




Figura 5 – Composição colorida. B3 (R), B2(G), B1 (B). Equalização do Histograma.

## Referências

Atkinson, P.M.; Tatnall, A.R.L. Neural networks in remote sensing. *International Journal of Remote Sensing*, v.18, n.4, p.699-709, 1997.

Benediktsson, J.A.; Swain, P.H.; Ersoy, O.K. Neural Network Approaches versus Statistical Methods in Classification of Multisource Remote Sensing Data. *IEEE Trans. on Geoscience and Remote Sensing*, v.28, p.540-552, Julho, 1990.

Engel, P.M. Inteligência Artificial e Redes Neurais em Prospecção Ambiental e Sensoriamento Remoto. In: *Simpósio de Aplicações da Informática em Biologia, InfoBio'93, I, Campinas, 1993. Proceedings*. Campinas: [S.n.], 1993. p. 24-25.

Freeman, J.A.; Skapura, D.M. *Neural Networks, Algorithms, Applications, and Programming Techniques*. New York: Addison Wesley, 1991.

Haykin, S. *Redes Neurais: Princípios e Prática*. Porto Alegre: Bookman, 2001.

Heermann, P.D.; Khazenie, N. Classification of Multispectral Remote Sensing Data Using a Back-Propagation Neural Network. *IEEE Trans. Geosci. Remote Sensing*, v. 30, n. 1, p. 81-88, 1992.

INPE, 2002a. *Monitoramento da Floresta Amazônica Brasileira por Satélite*. Disponível em: <<http://sputnik.dpi.inpe.br:1910/col/dpi.inpe.br/lise/2002/06.12.13.16/doc/Pag-05.htm>>. Acesso em: 04 Novembro 2002.

INPE, 2002b. *Teoria: Processamento de Imagens*. Disponível em: <<http://www.dpi.inpe.br/spring/teoria/mistura/mistura.htm>>. Acesso em: 08 Novembro 2002.

Moreira, M.A. *Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação*. São José dos Campos: INPE, 2001.

Nunes, R.V. *Uma Abordagem Neural para Tratamento de Imagens Multiespectrais*. Porto Alegre: CPGCC-UFRGS, 1995. 106p. (Trabalho Individual)

Rumelhart, D.E.; Hinton, G.E.; Williams, R.J. Learning representations of back-propagation errors. *Nature (London)*, v. 323, p. 533-536, 1986.

Todt, V. *Avaliação do desempenho de Classificadores Neurais para Aplicações em Sensoriamento Remoto*. Porto Alegre: CEP SRM-UFRGS, 1998. (Dissertação de Mestrado).