

INPE-5478-PRE/1777

**REDES NEURAIAS NA CLASSIFICAÇÃO DE USOS DO SOLO EM
IMAGENS DE SATÉLITES**

Maria Suelena S. Barros

**INPE
São José dos Campos
1993**

**SECRETARIA DA CIÊNCIA E TECNOLOGIA
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

INPE-5478-PRE/1777

**REDES NEURAIIS NA CLASSIFICAÇÃO DE USOS DO SOLO EM
IMAGENS DE SATÉLITES**

Maria Suelena S. Barros

**Aceito para apresentação no Simpósio Brasileiro de
de Pesquisa Operacional-SOBRAPO,
Salvador, Bahia, nov.1992.**

**INPE
São José dos Campos
1993**

CDU: 519.8:528.711.7

PALAVRAS-CHAVE: Redes Neurais; Classificação do uso do Solo; Imagens de Satélite.

REDES NEURALS NA CLASSIFICAÇÃO DE USOS DO SOLO EM IMAGENS DE SATÉLITES.

Maria Suelena Santiago Barros, Valter Rodrigues e
Maria Conceição de Andrade Amorim

Instituto Nacional de Pesquisas Espaciais
Caixa Postal 515
12 201 São José dos Campos, SP

RESUMO

Analisa-se neste trabalho o potencial do uso de redes RPE (Retropropagação do erro), como uma potente abordagem, embora não totalmente compreendida, para a classificação de usos do solo em imagens de satélite, quando há várias classes, não muito bem delineadas, para serem identificadas. São mostrados alguns resultados de classificação e discute-se a importância, na fase de aprendizagem, do tamanho da área de treinamento, do número de classes e do número de ciclos de aprendizagem.

ABSTRACT

This work analyses the potential of Backpropagation Networks' use as a powerful approach, although not completely understood, to land-cover classification in satellite images when there are many not well separated classes to be identified. Some classification results are shown and the importance of the training sites, the number of classes and learning cycles in the training phase are discussed.

1- INTRODUÇÃO

Modelos de redes neurais para classificação de dados de sensoriamento remoto tem sido já usados por vários autores (Hepner et alli, 1990). A principal vantagem do uso de redes neurais em tarefas de classificação é a sua característica de poder tratar com dados, independentemente do conhecimento "a priori" da sua distribuição estatística. Além disso, a rede dispõe do potencial de ponderar cada uma das fontes de dados de entrada, segundo a importância de cada classe da classificação.

Um dos modelos de redes neurais mais conhecidos e usados em problemas de classificação é o de Retropropagação do Erro (RPE). Neste trabalho são apresentados alguns resultados para a classificação de usos do solo usando-se este modelo. Neste estudo o modelo utilizado basea-se numa estrutura monolítica,

1 Os autores agradecem ao Prof. Josef Skrzypek, UCLA, por permitir o uso do simulador UCLA-SFINX (Structure and Function in Neural Connections).

na qual todos os dados de entrada e todas as classes concernentes são apresentados numa única arquitetura da rede.

2- A APRENDIZAGEM DAS CLASSES.

Uma rede neural consiste de nós chamados neurônios e de ligações entre estes neurônios simulando atividades sinápticas. Em um modelo formal do neurônio, os seus valores de saída são computados via uma função, não linear limitada, da soma ponderada das suas atividades de entrada. Estes valores de entrada são os valores de saída de outros neurônios.

O modelo de RPE tem 3 ou mais camadas de processamento: uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída.

Cada nó apresenta um valor de ativação, representado pela seguinte equação:

$$o_i = f\left[\left(\sum_j w_{ij} x_j\right) - \theta_i\right]$$

onde:

- o_i é o valor do i -ésimo neurônio;
- f é uma função não linear;
- w_{ij} são os pesos simuladores da relação sináptica dos neurônios j com o neurônio i ;
- x_j , $j = 1, 2, \dots, N$ são as entradas do nó i ;
- θ_i é um limiar, representando um valor acima do qual o neurônio i pode ser excitado pela combinação linear das suas entradas.

Para classificação, usualmente uma rede RPE opera como um identificador de classes que recebe um conjunto de vetores de entrada e ativa cada nó de saída, associando-o a cada um desses vetores de entrada, numa fase de aprendizagem.

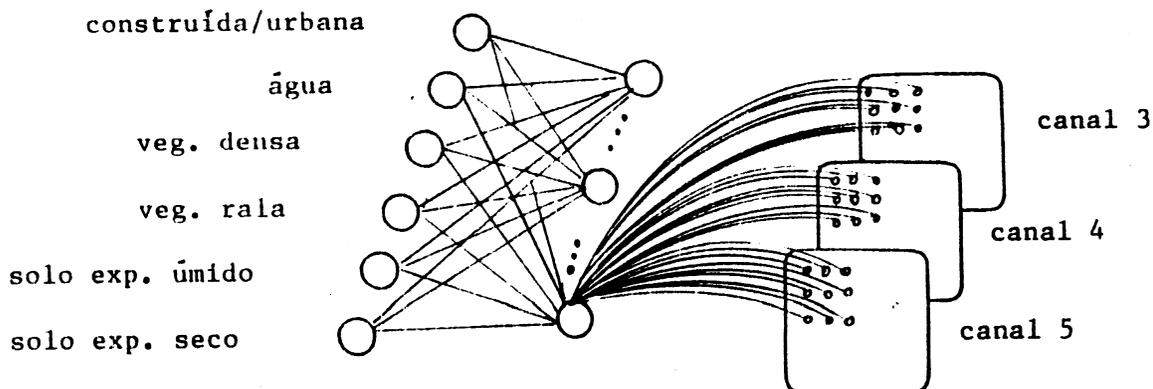


Fig. 1 - Esquema da rede neural monolítica

Nesta fase de aprendizagem, através da RPE pode-se modelar fronteiras de decisão complexas para separar classes emaranhadas. Num classificador de uma estrutura monolítica, como mostrado na figura 1, os nós de saída são associados um a um a cada classe.

Um nó de saída é ativado cada vez que a entrada x da rede pertence à classe associada. Os nós de saída são ativados através de uma função ponderada das saídas dos nós da camada escondida precedente. A regra de decisão é seleccionar aquela classe correspondente ao nó de saída com o maior valor de ativação.

O algoritmo de aprendizagem do tipo supervisionada determina para cada possível entrada um vetor de saída. A função do algoritmo de aprendizado é escolher o melhor valor dos pesos tal que os valores de saída forneçam a indicação da classe correta, quando se está na fase de classificação.

Deste modo, todas as classes são consideradas no processo de aprendizagem. Cada classe é rotulada uma de cada vez e o mesmo conjunto total de pesos da rede, após cada ciclo de aprendizagem, tem que adaptar seus valores às características de todas as classes.

3- RESULTADOS E DISCUSSÕES.

O resultado da classificação foi obtido usando uma imagem TM- Landsat, da área de São José dos Campos, SP, nos canais 3, 4 e 5. Cada canal apresenta uma imagem de [512x512] pixels. São consideradas 6 classes básicas para a classificação: construída/urbana, água, vegetação densa e vegetação rala, solo exposto úmido e solo exposto seco.

Foram escolhidas áreas de treinamento de [3X3] pixels. Neste tamanho a água fica bem definida, isto é, homogênea, pois a área de treinamento consegue ser inserida mesmo nos rios de pequena largura que atravessam a região e nas pequenas lagoas. Sugere-se um estudo para definir o melhor tamanho de amostra que seja

representativo de áreas urbanas, dada a grande variabilidade espectral e textural existente neste tipo de ocupação do solo.

Outro fato que merece considerações refere-se à perfeita escolha do número e dos locais onde as áreas de treinamento são aplicadas, porque uma das dificuldades na convergência do algoritmo RPE refere-se ao tempo gasto na aprendizagem. Este tempo é função da qualidade dos dados (amostras para aprendizagem) na entrada da rede.

A arquitetura RPE definida considera 27 nós de entrada (3 camadas de entrada codificando os 3 canais espectrais da imagem (cada um contendo [3x3] nós de entrada); uma camada escondida com 10 nós e uma camada de saída com 6 nós (um para cada classe).

O processo de treinamento teve como critério de parada a qualidade dos resultados, o que foi verificado visualmente através das imagens classificadas. A parada do treinamento se deu após 1500 ciclos de aprendizagem. Experimentalmente observou-se que; após este número de ciclos, usualmente o erro atinge menos de 20% do erro inicial. As imagens classificadas, figura 2, mostram as áreas construídas/urbanas e água.

Os parâmetros de aprendizagem foram: taxa de aprendizagem = 0,8 e Momentum = 0.

Observou-se durante a fase de aprendizagem que no início existia uma confusão entre os padrões água e vegetação densa. Tal fato obrigou a mais tempo de aprendizagem.

Munida de um grande número de informações a rede demorou significativamente na fase de aprendizagem, dispendendo cerca de 2 semanas numa metodologia de ajustes, o que implicou em aprendizagem e testes alternadamente.

A rede capacitou-se a distinguir bem a vegetação úmida da beira dos rios, porém não conseguiu distinguir a presença de sombras, o que parece ser uma tarefa bastante difícil devido a similaridade de informações espectrais entre sombras e outras classes.

No entanto, os resultados da classificação dos usos do solo demonstrou que a abordagem de redes neurais é robusta em termos de variabilidade das informações para a discriminação pretendida.

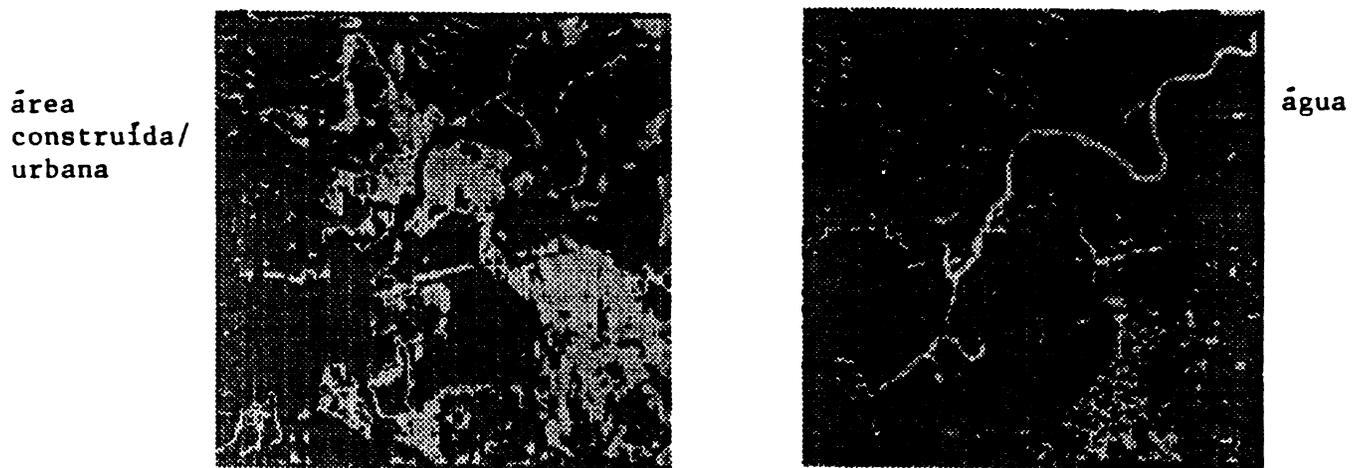


Fig. 2 - Resultado da Classificação: área construída/urbana e água, aparecem em branco.

Os resultados, sendo bastante motivadores, sugerem estudos sobre o número máximo de classes necessárias para uma melhor classificação de usos do solo, sem chegar-se a níveis de sub-classes, o que é pretendido numa segunda fase.

4- REFERÊNCIAS BIBLIOGRÁFICAS

Barros, M.S.S.; Amorim, M.C.A.; Rodrigues, V.. Satellite imagery and exogenous data integration by a neural network in automatic land-cover classification. Aceito para apresentação no International Symposium on Optical Applied Science and Engineering da International Society for Optical Engineering, San Diego, California, USA, 19 -24 jul. 1992.

Hecht-Nielsen, R. Neurocomputing. Addison-Wesley Publishing Co, 1990.

Hepner, G.F. Logan, T. Ritter, N. Bryant, N. Artificial Network classification using a minimal training set: comparison to conventional supervised classification. Photogrammetric Engineering and Remote Sensing, 56 (4), pp. 469-473, 1990.