

Classificação do Uso do Solo Utilizando Redes Neurais e o Algoritmo MAXVER

Selma Regina Aranha Ribeiro¹ - Selma@geoc.ufpr.br

Jorge Silva Centeno¹ - Centeno@geoc.ufpr.br

¹UFPR – Universidade Federal do Paraná

Caixa Postal 19001 – 81531-990 – Curitiba – PR, Brasil

Abstract

The purpose of this study was the classification of land cover. The general procedure involved the classification from satellite image LandSat-TM, bands 5, 4 e 3 using a neural network and supervised classification maximum likelihood. The study area was in West of Paraná State, Itaipu Lake, Brazil. In this study the algorithm MAXVER given the poor classification results because the numbers of sample were small.

The neural network approach using backpropagation algorithm does offer advantages over conventional classification.

Keywords: remote sensing, neural network, maximum likelihood classification, supervised classification techniques, artificial intelligence.

Introdução

O reconhecimento e detalhamento do espaço físico territorial é de suma importância para qualquer trabalho seja ele obras de engenharia, arquitetura, conservação de solos, mapeamentos temáticos, e outros. O mapeamento da cobertura existente, uso atual, pode ser executado através de métodos de classificação de imagens de satélite. Neste contexto, a aplicação de métodos estatísticos tem ganho grande aceitação. Modelos estatísticos de classificação requerem, no entanto, hipóteses a respeito da distribuição das classes, condição que em alguns casos não é satisfeita. Pesquisas mais recentes tem utilizado das técnicas da Inteligência Artificial para reconhecimento de padrões e classificação de imagens orbitais associando estes dados a dados auxiliares como geomorfologia, geologia e outros.

O trabalho aqui apresentado, visa classificar uma imagem orbital através dos métodos da Máxima Verossimilhança e das Redes Neurais e comparar os seus desempenhos.

Revisão Bibliográfica

A classificação digital consiste em associar determinado “pixel” a determinada categoria ou classe por meio de critérios estabelecidos. A classificação tem como objetivo: ordenar, discriminar e categorizar.

Máxima Verossimilhança (MAXVER)

É o método de classificação supervisionado mais comum. Considera a ponderação das distâncias entre médias dos níveis digitais das classes e o pixel, utilizando parâmetros estatísticos, isto é, considerando a distribuição de probabilidade normal para cada classe.

Assume-se que um vetor de observação X_i pertence a classe ω_i se a probabilidade que associa este pixel à classe ω_i for maior do que a probabilidade que associa o pixel a qualquer outra classe.

$$X_i \in \omega_i, \text{ se } P(\omega_i | X_i) > P(\omega_j | X_i) \quad \text{para todo } \omega_i \neq \omega_j \quad (1)$$

A probabilidade é calculada por:

$$P(\omega_i | X_i) = P(X_i | \omega_i) P(\omega_i) / P(X_i) \quad (2)$$

Onde:

$P(\omega_i)$ – é a probabilidade da classe ω_i ocorrer na imagem;

$P(X_i | \omega_i)$ - a probabilidade de um pixel da classe X_i pertencer a classe ω_i e

$P(X_i)$ - probabilidade do pixel X_i ocorrer na imagem.

O valor de $P(X_i | \omega_i)$ é geralmente obtido assumindo-se a distribuição normal para as classes. Por isso, as estimativas da média e da matriz variância-covariância são fundamentais.

Redes Neurais (RN)

As RN são uma linha de pesquisa da Inteligência Artificial, que visa investigar a possibilidade de simulação de comportamentos inteligentes através de modelos baseados no funcionamento do cérebro humano. São compostas por unidades de processamento simples operando em paralelo. Estas unidades de processamento foram inspiradas no sistema biológicos dos neurônios.

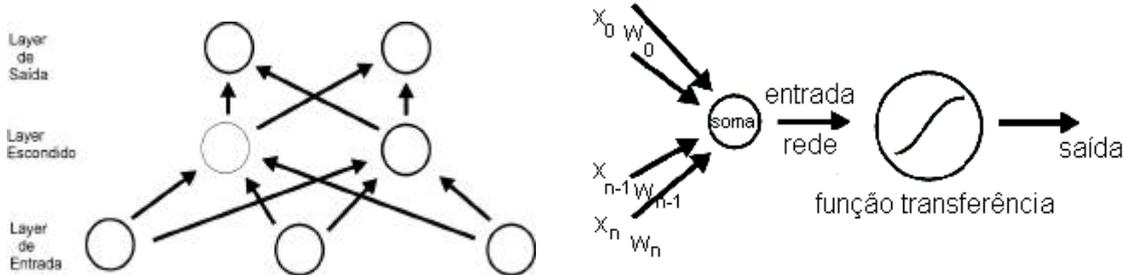
O funcionamento de um neurônio biológico pode ser modelado como sendo um circuito binário que possui várias entradas que são combinadas através de uma soma ponderada (corpo celular), gerando a entrada efetiva do neurônio que por sua vez determinará o repasse desse estímulo a outros neurônios da rede, se o estímulo for excitatório (1), isto é, ultrapassar um limiar.

Para incitar o comportamento das sinapses, os terminais de entrada do neurônio artificial têm pesos cujos valores podem ser maiores ou menores que zero, dependendo das sinapses serem inibitórias ou excitatórias. O neurônio dispara quando a soma dos impulsos que ele recebe ultrapassa o limiar de excitação. A ativação do neurônio é feita através da função de ativação que aciona ou não a saída, em função do valor da soma ponderada das entradas. (BRAGA, A .P. ET AL, 2000)

Uma RN é composta por vários neurônios distribuídos em camadas. A primeira camada é chamada de camada de entrada e tem a função de armazenar os dados de entrada na rede. As camadas intermediárias denominadas de camadas escondidas são os “pensamentos”, onde ocorrem os processamentos da rede. A última camada é definida como de saída. A

quantidade de neurônios por camadas e o número de camadas por rede é chamada de arquitetura da RN (Figura 1).

FIGURA 1 - ARQUITETURA DAS RN E ESQUEMA DAS ENTRADA COM PESOS, SOMA PONDERADA, FUNÇÃO DE TRANSFERÊNCIA E SAÍDA



Pode-se modelar o funcionamento de um neurônio como a geração de um impulso de saída a partir da soma ponderada dos sinais que a ele chegam. (Equação 1)

$$y = f(w, x) \quad (1)$$

$$y = f(S_i) \quad (2)$$

$$S_i = \sum_{j=1}^n w_{ij} x_j \quad (3)$$

Onde:

- x_i é o impulso de entrada;
- w_{ij} o peso atribuído a entrada j do neurônio i ;
- f função de transferência ;
- n número de impulsos de entrada;
- y impulso de saída e
- S_i nível de ativação

Uma soma ponderada destes impulsos, através dos pesos w_{ij} , origina um valor de saída $y = f(S_i)$, como esquematizado na Figura 2. Se este valor for muito pequeno, ele é desconsiderado, senão um impulso unitário é gerado e passado ao seguinte neurônio.

A função de transferência utilizada neste estudo foi a sigmoide: $f(x) = \frac{f_{\text{máx}}}{1 + e^{-x}}$ (logsig - MatLab 4.0)

O fluxo dos sinais da RN pode ser para frente (feedforward) ou recorrente. Na feedforward os neurônios estão organizados em camada e a informação se desloca em um único sentido. Na recorrente a rede é totalmente conectada e cada neurônio está conectado a todos os outros.

A RN pode ser treinada para resolver o problema da classificação multiespectral, este treinamento significa ajustar a sua matriz de pesos (W) de forma que o vetor de saída

(y) coincida com um certo valor desejado para cada vetor de entrada (X). Também pode-se fazer um paralelo com o neurônio biológico e dizer que o aprendizado é um ajuste sináptico.

O algoritmo para treinamento da RN mais conhecido é o “backpropagation”. Autores como LOGAN, T., ET AL, 1997, BENNEDIKTISSON J. A ., ET AL, 1991 e GONG, P., 1996 utilizaram deste algoritmo para treinar a rede para a classificação de imagens orbitais. É um treinamento supervisionado, considerado uma generalização da Regra Delta para RN feedforward, com duas ou mais camadas. O objetivo da Regra Delta é determinar um conjunto de pesos (W) que minimize o erro quadrático sobre determinado número de amostras de treinamento. A obtenção de um ponto mínimo é alcançado através de um processo de iteração local, utilizando um conjunto de amostras. A Regra Delta é computacionalmente complexa e quando o tamanho da amostras é grande, o tempo de aprendizado pode se tornar longo.(BENNEDIKTISSON, J. A . ET AL, 1991)

Os autores ARAKI, 1998 e PAOLA, J. D. ET AL, 1997 utilizaram as redes neurais para classificação da cobertura do solo e concluíram que o desempenho da rede é melhor que dos algoritmos convencionais de classificação.

Materiais e Métodos

A área em questão, Bacia do Passocué, faz parte da Bacia do Paraná Três, situada na região Oeste do estado do Paraná entre as latitudes Sul 23⁰ 59' 00” e 24⁰ 41' 45” e longitudes Oeste 53⁰ 54' 30” e 54⁰ 37' 21”. O uso do solo nesta região é caracterizado por culturas anuais e pastagens. Ao redor do Lago de Itaipu - Binacional, desde a sua implantação, existe uma faixa de reflorestamento da vegetação, de domínio da represa, denominada de faixa de proteção.

Seleção das amostras

A partir da imagem orbital Landsat – TM, bandas 5, 4, e 3, foram selecionadas 25 amostras para cada classe nas três bandas. A seleção das amostras foi baseada no mapa do uso do solo do ano de 1997, na escala 1:50.000, fornecido pela Usina Itaipu - Binacional.

Os níveis de cinza da imagem orbital foram coletados das classes: cultura, água (lago), faixa de proteção ao redor do Lago de Itaipu, pastagem, solo exposto 1, área urbana, solo exposto 2 e nuvem. O software utilizado para a leitura dos “pixels” foi o SPRING 3.3.

Classificação MAXVER

O software SPRING 3.3 permite a escolha das amostras, através da digitalização na tela de áreas que representem a reflectância da classe desejada. O usuário deve ter o cuidado para que as amostras sejam homogêneas e representantes da classe a ser separada.

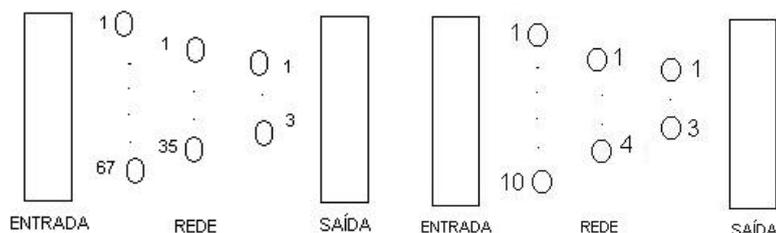
Classificação RN

A partir das amostras selecionadas de cada classe foi gerada uma matriz de reflectância dos níveis de cinza das oito classes e das respectivas três (3) bandas. Esta matriz foi introduzida como matriz de entrada de dados no Laboratório Matemático- MatLab 4.0. Para cada classe assumiu-se um valor numérico, de 1 a 8 e estes definiram o vetor de valores (classes) esperados.

A arquitetura da RN mais apropriada foi definida experimentalmente. Foram testados no MatLab 4.0 redes com 1, 2, e 3 camadas, sendo que os melhores resultados foram obtidos usando três camadas.

A partir deste passo inicializou-se os testes com a finalidade de definir as funções de transferência e números de neurônios por camada. O algoritmo utilizado foi o “backpropagation” com as variações Momento e Levenberg- Marquardt (LVQ). As Figuras 2 exemplificam as arquiteturas das RN para as variações Momento e LVQ.

FIGURA 2 - ARQUITETURA UTILIZADA PARA A VARIAÇÃO MOMENTO-LVQ



Foram realizados testes considerando três conjuntos de classes distintas:

CASO 1: cultura, água, faixa de proteção, pastagem, solo exposto 2, área urbana, seis classes; utilizando a variação Momento e LVQ.

CASO 2: cultura, água, faixa de proteção, pastagem, solo exposto 2, cinco classes; utilizando a variação Momento.

CASO 3: cultura, água, faixa de proteção, pastagem, solo exposto 1, área urbana e nuvem, 7 classes; utilizando a variação Momento.

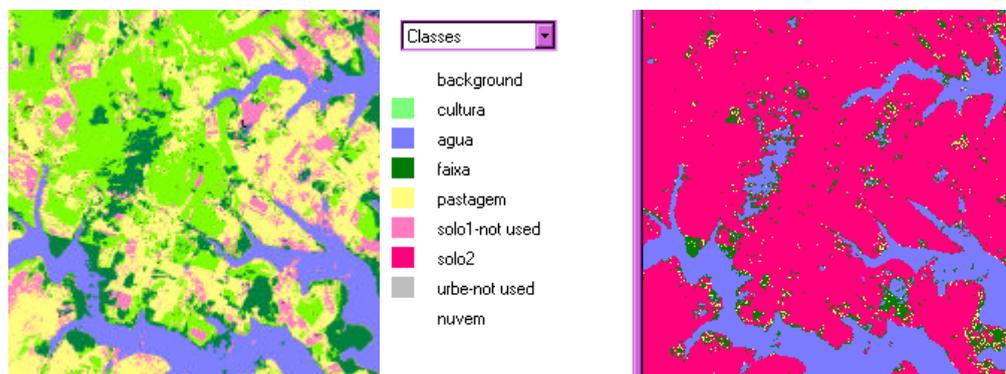
Em cada conjunto, a confusão entre as classes é diferente.

Resultados

A área da classe “água”, por ser facilmente diferenciada das outras classes não varia significativamente em todos os três casos testados (Figura 3). Já as classes como “cultura” ou “pastagem” são fortemente influenciadas pela definição inicial das classes. Isto se justifica pelo fato destas classes ficarem espectralmente próximas de outras classes, o que gera confusão na hora de classificar os “pixels”.

A presença de “nuvens e suas sombras”, na área de estudo, é um fator de perturbação significativo, pois estas classes não são totalmente uniformes. Por exemplo, na região de penumbra ocorre alta mistura entre a “sombra” e a cobertura do solo.

FIGURA 3 – IMAGENS CLASSIFICADAS RN E MAXVER



A Figura 3 acima mostra um exemplo das classificações com RN e MAXVER. Nota-se que utilizando o método das RN as classes foram bem classificadas; as classes “nuvem” e “sombra de nuvem” não foram selecionadas para o treinamento e nota-se que foram classificadas como “faixa de proteção”. Com o método MAXVER, a imagem não foi bem classificada, a classe “solo exposto 2” substitui as classes “pastagem” e “culturas”, a classe “água” foi a melhor classificada para esta imagem, apesar de estar misturada com a classe “nuvem” que não foi selecionada como amostra. O fato da classe “água” ter sido bem classificada na imagem, ocorreu pela homogeneidade das amostras, isto é, essa está bem separadas espectralmente das demais classes.

A classificação utilizando as RN é em todos os exemplos superior. Vale a pena salientar que a classificação através do algoritmo MAXVER pode ser melhorada utilizando-se mais amostras e que nos testes foram usadas as mesmas amostras para ambos os métodos para fins de comparação.

Os algoritmos das RN requerem menor número de amostras, devido a esse fato foi constatado um melhor desempenho na série de testes apresentados.

Existe uma gama de opções para se definir uma arquitetura das RN e os resultados obtidos com cada uma delas são também variados. Algumas limitações são estabelecidas pelo software, neste caso o MatLab 4.0, portanto não se pode experimentar todas as opções.

As RN também “sofrem” o efeito da presença das “nuvens” e suas “sombras”, o que gera confusão de maneira similar tal qual a ocorrência já citada no método estatístico (MAXVER).

Em função dos resultados obtidos, pode-se apontar as seguintes vantagens no uso da RN:

- poder da RN de generalização é de grande importância na classificação das imagens orbitais;

- não é necessário assumir hipóteses a respeito da distribuição das classes “a priori”;
- uma pequena quantidade de amostras é suficiente para efetuar para o treinamento, isto é, não necessita de uma quantidade considerável de “pixels” para a caracterização das classes;
- com as mesmas amostras o desempenho das RN foi melhor que a da classificação convencional MAXVER, como citado por BENEDIKTSSON J. A . ET AL,1991 e
- em todas as situações as RN classificaram melhor as imagens que o classificador convencional MAXVER.

Como desvantagens:

- a definição da arquitetura da RN (número de camadas, número de neurônios por camadas e função de transferência) é uma tarefa resolvida através da tentativa e erro.
- Aumentando-se o número de amostras o tempo de convergência do treinamento da rede aumenta.

Conclusão:

A comparação dos resultados da classificação usando o método estatístico da MAXVER e o algoritmo das RN comprovam que, quando se dispõe de um número pequeno de amostras, o uso das RN é mais eficiente. Isto se justifica pelo fato dos métodos estatísticos requerem um maior número de amostras para calcular uma estimativa confiável dos parâmetros da distribuição das classes

A classificação MAXVER requer mais amostras e pode gerar melhores resultados, que os obtidos nas classificações deste trabalho, com uma quantidade maior de amostras.

Os teste realizados confirmam a viabilidade do uso das RN para a classificação de imagens orbitais. Esta abordagem por não necessitar de hipótese a respeito da distribuição das classes permite utilizar as RN para classificação do uso do solo e unidades de paisagem através imagens orbitais. Com isto as RN podem ser usadas como ferramenta para integrar dados auxiliares, como por exemplo informações derivadas do Modelo Numérico do Terreno e outros mapas temáticos, na análise de uma imagem, sem perder a informação espectral da mesma.

A associação de dados de diferentes origens (auxiliares) na classificação digital é importante pois complementam a análise de maneira similar a análise visual onde o intérprete com sua experiência sobre o local de estudo possui a habilidade de diferenciar visualmente os diferentes tipos de relevo, a rede de drenagem e outros. Tal complementação de informações seria inviável na classificação utilizando os métodos estatísticos convencionais.

Referências Bibliográficas

- ARAKI, H., 1998. **Classificação de imagens multiespectral com redes neurais**: revisão bibliográfica e alguns experimentos. Seminário PÓS- Graduação, UFPR, Curitiba.
- BENEDIKTSSON, J. A .; SWAIN, P. H.; ERSOY, O . K., 1991. **Neural network approaches versus statistical methods in classification of multisouse remote sensing data**. IEE Transactions on Geoscience and Remote Sensing. v.28 n.4, p. 540-552.
- BRAGA, A .P. ; LUDEMIR, T. B. ; CARVALHO, A . C. P. F., 2000. **Redes neurais artificiais – teoria e aplicações**. Rio de Janeiro. LTC Livros Técnicos e Científicos Editora S. A , p. 237.
- GONG, P., 1996. **Integrated analysis of spatial data from multiple sources: using evidential reasoning and artificial neural network techniques from geological mapping**. Photogrammetric Engineering & Remote Sensing, v. 62, n. 5, p. 513-523.
- LOGAN, T.; RITTER, N.; BRYANT N., 1997. **Artificial neural network classification using a minimal; training set: comparison to conventional supervised classification**. Photogrammetric Engineering & Remote Sensing. v. 56, n. 4, p. 1285-1294.
- PAOLA, J. D. ; SCHOWENGERDT,R. A ., 1997. **The effect of neural–network struture on a multispectral land–use/land–cover classification**. Photogrammetric Engineering & Remote Sensing, v.63, n.5, p.535–544.