

**COMPARAÇÃO DA TÉCNICA DAS REDES NEURAIIS COM O ALGORITMO  
ESTATÍSTICO DA MÁXIMA VEROSSIMILHANÇA NA CLASSIFICAÇÃO DO USO DO  
SOLO UTILIZANDO IMAGENS ORBITAIS**

Selma Regina Aranha Ribeiro

Selma@geoc.ufpr.br

UNIOESTE/UFPR

Jorge Silva Centeno

Centeno@geoc.ufpr.br

UFPR – Universidade Federal do Paraná

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

# **COMPARAÇÃO DA TÉCNICA DAS REDES NEURAIS COM O ALGORITMO ESTATÍSTICO DA MÁXIMA VEROSSIMILHANÇA NA CLASSIFICAÇÃO DO USO DO SOLO UTILIZANDO IMAGENS ORBITAIS**

## **RESUMO**

Várias técnicas vêm sendo aplicadas na análise e classificação do uso do solo através de dados de sensoriamento remoto. O algoritmo da Máxima Verossimilhança, já consagrado, é uma técnica supervisionada de classificação que considera a ponderação das distâncias entre médias dos níveis digitais das classes e o pixel, utilizando parâmetros estatísticos, isto é, considera a distribuição normal para cada classe.

As Redes Neurais vem sendo utilizada com sucesso nas mais diversas áreas. É uma das técnicas da Inteligência Artificial que tem considerável potencial para a classificação de dados advindos de sensoriamento remoto. O presente trabalho tem como objetivo efetuar um estudo comparativo do desempenho dos métodos da Máxima Verossimilhança e das Redes Neurais para a classificação do uso do solo.

Resultados mostraram que a técnica da Inteligência Artificial (Redes Neurais), treinada com uma quantidade mínima representativa de cada classe e sem conhecimento nenhum sobre a distribuição estatística dos dados, possui desempenho superior que o método da Máxima Verossimilhança.

## **ABSTRACT**

Several techniques come being applied in the analysis and classification of the use of the soil through Remotely Sensed Data. The algorithm of the Maximum-Likelihood, already consecrated, it is a supervised technique of classification that considers the ponderation of the distances between averages of the digital levels of the classes and the pixel, using statistical parameters, that is, considers the normal distribution for each class.

The Artificial Neural Network come being used with success in the most several areas. It is one of the techniques of the Artificial Intelligence that has considerable potential for the classification of data from remote sensing. It is a group of programming techniques, that is to say algorithms, that it has as objective to solve certain problems imitating the man's intelligence. This automatic programming is executed through the adjustment among the interconnections (weights) associated to each neuron of the net, being a non parametric classifier.

The present work has as objective to make a comparative study of the acting of the methods of the Maximum-Likelihood and of the Artificial Neural Network for the classification of the use of the soil.

Results preliminaries showed that the technique of the Artificial Intelligence (Neural Network), with a representative minimal sized training sites of each class and without to know anything about the statistical distribution of the data, it possesses acting that the method of the Maximum-Likelihood.

## 1 INTRODUÇÃO

A identificação de feições capturadas por sensoriamento remoto nas fotografias aéreas é fotointerpretada através da habilidade do analista em diferenciar padrões utilizando seu conhecimento intuitivo e o de fotointerpretação sobre a área de estudo. O fotointérprete fica incapacitado de executar esta mesma função com as imagens orbitais, pois as imagens são multiespectrais e ele também não pode discriminar o limite da resolução radiométrica/espectral/espacial das mesmas. Portanto as imagens digitais necessitam de uma análise quantitativa através de sistemas computacionais, onde cada propriedade numérica de cada pixel da imagem é analisada individualmente. A metodologia para a análise quantidade das imagens digitais é intitulada de classificação digital de imagens

As imagens digitais apresentam potencial valioso em estudos de impacto ambiental, climáticos, subterrâneos, marítimos, da superfície terrestre, etc. Para o intérprete das imagens digitais uma das fases mais importantes é a da a classificação digital da cena, pois o resultado dela define a qualidade do trabalho executado.

Várias técnicas vem sendo empregadas para a análise e classificação de imagens orbitais, dentre as quais pode-se citar os métodos já consagrados de classificação como máxima verossimilhança. Pesquisas mais recentes tem utilizado das técnicas de Redes Neurais para reconhecimento de padrões e classificação de imagens orbitais associadas a dados auxiliares como geomorfologia, geologia e outros.

## 2 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  $\omega_i$  se a probabilidade que associa este pixel à classe  $\omega_i$  for maior do que a probabilidade que associa o pixel a qualquer outra classe.

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

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  $\omega_i$  ocorrer na imagem;

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

### 3 REDES NEURAIS (RN)

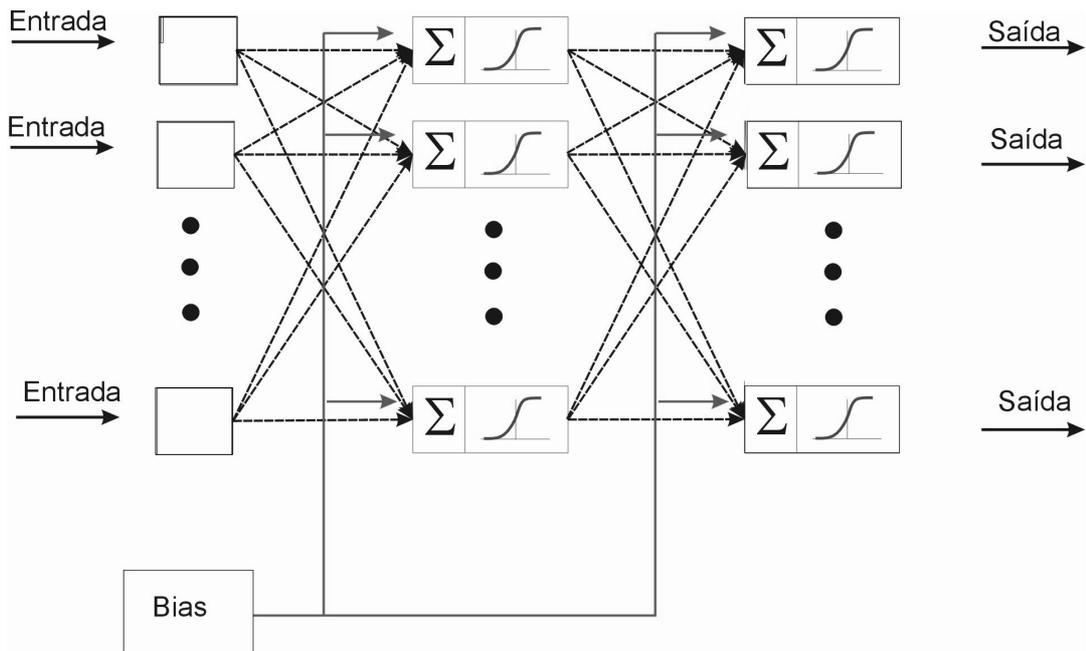
A Inteligência Artificial pode ser definida como um conjunto de técnicas de programação que procura resolver problemas em informática, através de programas, algoritmos, imitando o comportamento humano. Algumas das técnicas da Inteligência Artificial são os Algoritmos Genéticos, a Lógica Fuzzy, os Sistemas Especialista e as Redes Neurais.

As Redes Neurais pode ser definida como unidades (neurônios interconectados) que trabalham em paralelo para “classificar e generalizar” dados de entrada em “classes” de saída. A interconexão entre os neurônios (unidades) é ponderada e a partir de dados de entrada, os pesos que representam a associação entre os neurônios são ajustados. Após o ajuste, para cada conjunto de dados apresentado à rede na primeira camada de neurônios (camada de entrada) a rede propaga sinais para as seguintes camadas, em função dos pesos pré-deperminados. A atividade de uma unidade influencia no nível de ativação de outras unidades da rede, assim sucessivamente até que a saída seja atingida. A magnitude da rede é determinada por um processo de treinamento iterativo o qual tenta através da repetição “aprender” a saída correta para cada amostra treinada. O processo envolve a modificação dos pesos entre as unidades até que a rede esteja apta para caracterizar os dados de treinamento com a precisão desejada.

A técnica das Redes Neurais é uma alternativa para a construção de um sistema computacional para a classificação da cobertura e uso do solo. (GONG, et al, 1996)

A estrutura das Redes Neurais faz com que seja muito fácil a incorporação de dados auxiliares ou informações espaciais na classificação digital do uso e cobertura do solo. (POLA, et all, 1997)

Uma Rede Neural com sua capacidade própria de aprendizado e organização é uma promissora técnica para estabelecer tarefa que envolvem o conhecimento humano.( KAO, 1996).



**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 3)

$$y = f(w, x) \tag{3}$$

$$y = f(S_i) \tag{4}$$

$$S_i = \sum_{j=1}^n W_{ij} X_i \tag{5}$$

Onde:

$x_i$  é o impulso de entrada;

$w_{ij}$  o peso atribuído à 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 sigmoideal:  $f(x) = \frac{1}{1+e^{-x}}$  (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.

#### **4 MATERIAIS E MÉTODOS**

A área em questão, Bacia do Passocuê, faz parte da Bacia do Paraná Três, situada na região Oeste do estado do Paraná entre as latitudes Sul  $23^{\circ} 59' 00''$  e  $24^{\circ} 41' 45''$  e longitudes Oeste  $53^{\circ} 54' 30''$  e  $54^{\circ} 37' 21''$ . O uso do solo nesta região é caracterizado por culturas anuais e pastagens e matas ciliares

##### **4.1 SELEÇÃO DAS AMOSTRAS**

A partir da imagem orbital Landsat – TM, bandas 5, 4, e 3, foram selecionadas 20 amostras para cada classe nas três bandas.

Os níveis de cinza da imagem orbital foram coletados das classes: cultura, água, mata ciliar, pastagem, solo exposto nuvem e sombra de nuvem.

##### **4.2 ARQUITETURA DA REDES NEURAI**

A quantidade de camadas de entrada foi definida a partir dos dados de entrada, a camada de saída em função do número de classes e a definição de pelo menos uma camada escondida, para a divisão do espaço das amostras em hiperplano ou hipersuperfícies. A figura 2 esquematiza as arquiteturas utilizadas.



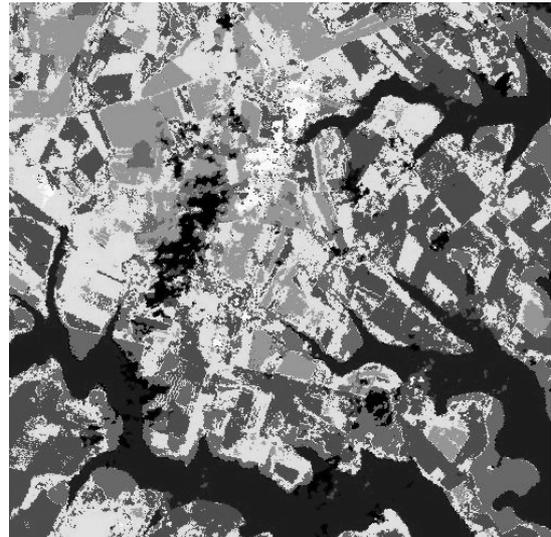
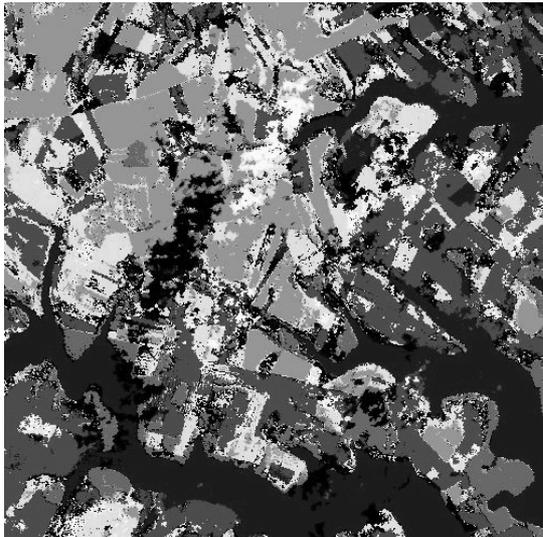
Na Tabela 1 podemos verificar que as melhores amostras classificadas foram as das classes água, mata, pasto, nuvem, sombra de nuvem e vindo em seguida as classes solo e cultura. Para esta classificação ocorreram 2,38% de “pixel”, da classe solo, que não foram classificados. Ainda notamos as confusões espectrais entre as classes cultura e solo, Figura 3 (A).

**TABELA 2-PERCENTUAL ESTATÍSTICO DA CLASSIFICAÇÃO MAXVER**

Classe	Água	Mata	Cultura	Solo	Pasto	Nuvem	Sombra
Não/clas	0	0	0	0	0	0,85	0
água	98,78	0	0	1,74	0	0	0
Mata	0	98,86	0	0	0	0	0
Cultura	0,41	0	97,30	0	0	0	0,66
Solo	0,81	0	2,70	98,26	0	1,72	0
Pasto	0	1,14	0	0	100,00	2,56	0,66
Nuvem	0	0	0	0	0	94,87	0
Sombra	0	0	0	0	0	0	98,68
Total	100	100	100	100	100	100	100

Para a classificação MAXVER ocorreram 0,83% de “pixel”, das classes nuvem e sombra de nuvem, que não foram classificados. Nesta classificação a classe melhor definida foi a de pasto, água e pasto vindo a seguir as classes mata, água, sombra de nuvem, cultura e nuvem, Figura 3 (B).

**FIGURA 3- -IMAGENS CLASSIFICADAS RN(A) E MAXVER(B)**



	Água		Solo		Pastagem		Sombra de nuvem
	Mata		Cultura		Nuvem		

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. 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.

## 6 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 multisuse 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.