

# GENERALIZAÇÃO DE REDES NEURAS ARTIFICIAS USANDO DADOS DE DIFERENTES SENSORES - LANDSAT E CBERS - UMA ABORDAGEM ORIENTADA A REGIÕES

Igor Amazonas de Andrade<sup>1</sup>

Mosar Faria Botelho<sup>2</sup>

Selma Regina Aranha Ribeiro<sup>3</sup>

Jorge Antonio Silva Centeno<sup>4</sup>

<sup>1</sup> UFPR – Engenharia Cartográfica – igoramazonas@hotmail.com

<sup>2</sup> UFPR – Curso de Pós graduação em Ciências Geodésicas – mfbotelho@yahoo.com.br

<sup>3</sup> UFPR – Universidade Estadual do Oeste do Paraná - UNIOESTE – selmar@ufpr.br

<sup>4</sup> UFPR – Departamento de Geomática –centeno@ufpr.br

## RESUMO

O presente estudo tem como objetivo a verificação da capacidade de generalização de Redes Neurais Artificiais (RNA) na classificação digital de imagens de dois sensores diferentes, o LandSat-5 (TM) e o CBERS-II, na cidade de Araucária – PR. Executou-se o treinamento da RNA, com amostras da imagem obtidas pelo sensor LandSat e utilizou-se os mesmos pesos da RNA, portanto treinamento e amostras, para a classificação do uso do solo da imagem adquirida pelo sensor CBERS. Para tanto foram utilizadas as duas imagens digitais de datas diferentes e dos dois sensores, tendo como elemento mínimo regiões e não *pixels* (abordagem orientada a regiões). Obtiveram-se duas imagens classificadas, quanto ao uso do solo, em datas diferentes podendo-se executar uma análise temporal. A habilidade de generalização da RNA foi verificada, pois o treinamento executado na imagem LandSat foi eficiente na classificação do uso do solo na imagem do sensor CBERS.

**Palavras-chave:** Sensoriamento Remoto, Redes Neurais Artificiais, Abordagem Orientada a Regiões.

## GENERALIZATION OF ARTIFICIAL NEURAL NETWORKS USING DIFFERENT SENSORS - LANDSAT AND CBERS – AND A REGION BASED APPROACH

### ABSTRACT

In this paper, we present an experiment about the ability of a neural net, trained using data derived from one sensor, to classify data from a different sensor within a region based approach. For this purpose, data of two sensors are used: LandSat-5 (TM) and the CBERS-II (CCD), in the city of Araucária – PR. Both sensors have similar spectral bands in the visible and near infrared spectrum, but different spatial resolutions. The neural net was trained using samples taken from the LandSat image and the trained net was then used to classify land-use in the CBERS image. Since the images were taken in two different dates, the result enabled a temporal analysis of the region based on samples of one unique image.

**Keywords:** Remote Sensing, Neural Networks, Region Based Approach

## 1. INTRODUÇÃO

O mapeamento da cobertura existente sobre determinada área pode ser executado por meio de métodos de classificação de imagens digitais. A classificação é um processo de generalização de dados coletados sobre certos fenômenos para que estes sejam reconhecidos. Na classificação digital supervisionada de imagens digitais, a coleta de amostras puras e representativas da área é uma tarefa importante, pois esta etapa pode definir a qualidade do produto gerado.

A RNA vem sendo utilizada em sensoriamento remoto para a classificação do uso do solo com êxito. A RNA supervisionada utiliza amostras que representam as classes de interesse, portanto ela possui a capacidade de aprender (treinar) por meio de exemplos e generalizar. Em sensoriamento remoto para a classificação digital, vem sendo utilizada a RNA *perceptron multicamadas* com o algoritmo de treinamento *backpropagation*.

A vantagem da RNA sobre os classificadores estatísticos é que nenhuma hipótese prévia sobre a distribuição dos dados a serem classificados é necessária. A tarefa mais demorada na utilização da técnica de RNA é a definição da arquitetura e o treinamento, ou seja, processo iterativo, das amostras representativas das classes.

Após o processamento de RNA é possível que o aprendizado, executado por meio das amostras das classes, possa ser armazenado. No presente caso, este aprendizado armazenado é e aplicado para a mesma área de estudo, em datas diferentes e com imageamento de diferente sensor (CBERS), como já executado por GALLO (2003) só que o elemento mínimo não é o *pixel*, mas sim uma abordagem orientada a regiões.

## 2. REVISÃO DE LITERATURA

### 2.1. REDES NEURAIS ARTIFICIAIS

As RNA são usualmente organizadas em camadas compostas de unidades de processamento (neurônios), conectadas por canais de comunicação que fazem fluir dados numéricos. Os dados são apresentados à rede por meio de uma camada de entrada, a qual se comunica a uma ou mais camadas ocultas onde ocorre o processamento por meio de um sistema de conexões ponderadas. A camada de saída apresenta o resultado do processamento (GERMAN e GAHEGAN, 1996).

O funcionamento da rede é determinado pela conexão entre as unidades de processamento. É possível treinar uma rede para reproduzir uma função particular através do ajustamento das conexões entre as unidades. A idéia das RNA é ajustar a conexão entre os neurônios em função do problema a ser desenvolvido (RIBEIRO, 2003). O aprendizado é o processo no qual a taxa de aprendizado da rede ajusta os pesos através das mudanças do erro fornecido pela saída, isto é, requer que a troca dos pesos seja proporcional a derivada do erro em relação aos pesos. O gradiente descendente ideal necessita que passos infinitesimais sejam executados (HAYKIN, 1999).

O algoritmo para treinamento de RNA multicamadas chamado de *backpropagation*, ou retropropagação do erro, foi criado através da generalização da taxa de aprendizado, sendo essa a taxa com que os "ganhos" (pesos) são alterados em consequência dos erros, de redes de múltiplas camadas com funções de transferência não lineares. Os vetores de entrada e os correspondentes de saída são usados para treinar a rede até que ela possa aproximar a função, isto é, associar os vetores de entrada a um específico vetor de saída, partindo-se de um ponto arbitrário no espaço dos pesos e percorrendo a superfície do erro quadrático em direção a um ponto mínimo. É um método simples de gradiente descendente para minimizar o erro quadrático total de saída computado pela rede (GERMAN e GAHEGAN, 1996).

### 2.3. ABORDAGEM BASEADA EM REGIÕES

A abordagem baseada em regiões conhecida também como segmentação representa um passo no sentido de preparar as imagens digitais para uma futura classificação temática em nível de segmentos, onde os elementos analisados são regiões resultantes do agrupamento de *pixels*, espacialmente próximos e com características espectrais similares (VENTURIERI et al., 1998). A segmentação divide uma imagem em partes ou objetos que a constituem. O processo de segmentação ideal é finalizado quando os objetos de interesse, na aplicação, estiverem isolados.

Uma das técnicas de segmentação, por crescimento de regiões, é a multi-resolução, FNEA ("Fractal Net Evolution Approach"). Esta segmentação é executada utilizando as propriedades básicas de valores de níveis digitais, bem como as propriedades espaciais como a forma, a compacidade e a suavidade do contorno dos grupos formados a cada iteração, ou seja, são analisadas a heterogeneidade espacial e espectral dos *pixels* e sua vizinhança.

Após a análise da heterogeneidade espacial e espectral, o processo de fusão inicia-se com um *pixel* (como no crescimento de regiões) formando uma região, sendo que a cada etapa, um par de objetos funde-se para formar um objeto maior; o processo de fusão está baseado no critério de homogeneidade, observando-se a heterogeneidade entre objetos adjacentes (ANTUNES, 2003).

Após a fusão dos *pixels* formando regiões (segmentos) estas são descritas (discriminadas) por meio de variáveis espectrais e/ou espaciais. Pode-se citar os descritores espectrais: o brilho, o valor médio de brilho, a razão, etc.; e como descritores espaciais: o comprimento, a largura, a direção principal, dentre outros. Com os descritores definidos obtém-se uma nova imagem onde o elemento mínimo dela são regiões.

### 3. MATERIAL E MÉTODO

#### 3.1. MATERIAL

Foram usadas duas imagens digitais dos sensores Landsat e CBERS. A imagem Landsat TM foi obtida em 18/07/1994. A imagem CBERS foi obtida em 08/04/2004. Em ambos os casos, as bandas 2,3 e 4 foram usadas.

Um recorte das duas imagens foi feito segundo as coordenadas:

E = 677690,78 – 678600,78.

N = 7184297,72 – 7183387,02.

#### Programas

- ENVI 4.0 – correção geométrica das imagens dos dois sensores.
- ECognition 2.0 – segmentação das imagens.
- VIEW - classificação mediante a técnica de RNA. Programa desenvolvido no curso de Pós graduação em Ciências Geodésicas por Mosar Faria Botelho.

#### 3.1.1. Área de estudo

O município de Araucária situa-se a 25°35'36", latitude S e 49°24'27" longitude W. Está localizado no leste do Estado do Paraná, com uma superfície de 460,85 Km<sup>2</sup>; essa área corresponde a 0,2% da área total do Estado. Está a 897 metros acima do nível do mar e a 20 Km da capital Curitiba. Ao norte, limita-se com o município de Campo Largo, ao oeste com Contenda e Balsa Nova, ao leste com Curitiba e ao sul com Contenda, ao sudeste Fazenda Rio Grande e Mandirituba. Sua área é de 460,85 km<sup>2</sup>, cobre aproximadamente 5,45% da área da Região Metropolitana de Curitiba. A Zona Rural ocupa 81,77% do Município. Por outro lado, apenas 40% da Zona Urbana é ocupada por áreas urbanas e industriais, o que representa apenas 7,3% do Município.

#### 3.2. MÉTODO

##### ETAPAS:

1 - A imagem LandSat já se encontrava corrigida geometricamente e serviu de base para a correção geométrica da imagem CBERS na qual foram utilizados 10 pontos de controle e o erro médio quadrático ficou em 10 metros.

2 - As duas imagens, LandSat e CBERS, foram segmentadas no programa ECognition, portanto foram geradas duas outras imagens com a abordagem baseada em regiões.

3 - Na nova imagem LandSat, com a abordagem baseada em regiões, foram coletadas amostras puras e representativas das classes.

4 - Mediante o treinamento destas amostras com a técnica de RNA, foi executada a classificação do uso do solo, isto é a generalização do treinamento. Os pesos gerados durante o aprendizado foram armazenados.

5 - A próxima etapa foi a generalização da imagem CBERS utilizando o treinamento efetuado com as amostras da imagem LandSat, ou seja, somente a generalização foi efetuada na imagem CBERS.

6 - Como duas classificações foram geradas, uma da imagem LandSat da data de 18/07/1994 e outra da CBERS referente a data 08/04/2004 estas foram processadas mediante a subtração de bandas e pode-se gerar uma terceira imagem representando o crescimento urbano referente as datas supra citadas.

### 3.2.1. Segmentação

Alguns programas que vem utilizando o algoritmo de segmentação FNEA. Cita-se como exemplo, o programa "eCognition", onde o usuário pode representar o conhecimento utilizando relações derivadas experimentalmente e modificar tais relações de maneira a satisfazer os fins da análise da imagem. Neste programa, os objetos resultantes da segmentação representam a informação da imagem de uma forma abstrata. Além das informações espectrais outras informações ou atributos adicionais, como forma, textura relacionamento entre objetos e sua vizinhança, podem ser usados para a classificação (ECOGNITION, 2001).

A abordagem baseada em regiões foi executada em dois níveis e duas escalas para cada nível, a saber:

1 - Nível 1 - escala 5 e 0,8 para a cor e 0,2 para a forma, incluindo o valor 0,9 e 0,1 para a suavidade e para a compacidade, respectivamente.

2 - Nível 2 - escala 10 e 0,2 para a cor e 0,8 para a forma, incluindo o valor 0,9 e 0,1 para a suavidade e para a compacidade, respectivamente.

### 3.2.2. Redes Neurais

A RNA utilizada é a *perceptron multicamadas* com o algoritmo de treinamento *backpropagation*. A arquitetura da RNA foi definida experimentalmente. O número de neurônios da camada de entrada é três e esta quantidade foi definida pelo número de variáveis de entrada, uma imagem digital do sensor LandSat com três bandas espectrais.

O número de camadas escondidas e a quantidade de neurônios, nesta camada, foram testada e ficou estabelecido que, o melhor experimento foi com duas camadas escondidas contendo 8 e 3 neurônios na primeira e na segunda camadas escondidas, respectivamente.

A camada de saída é definida pelo número de classes desejadas no processamento, neste estudo quatro classes foram estabelecidas.

## 4. RESULTADOS

As figuras 1, 2 e 3 mostram os resultados obtidos no experimento. Na figura 1 é mostrada a imagem temática derivada da imagem Landsat TM. Na figura 2 é mostrada a imagem temática obtida usando a rede treinada para classificar a imagem Landsat aplicada à imagem CBERS. Na figura 3 é mostrada a diferença entre as imagens temáticas. As cores mostram as áreas onde a classe "área urbana" sofreu modificações.

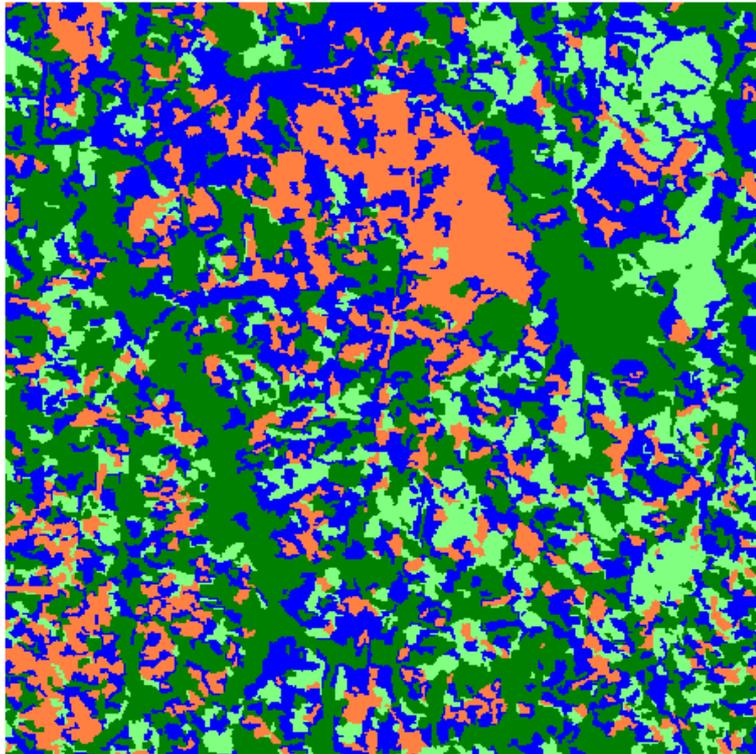


Figura 1 – imagem classificada Landsat

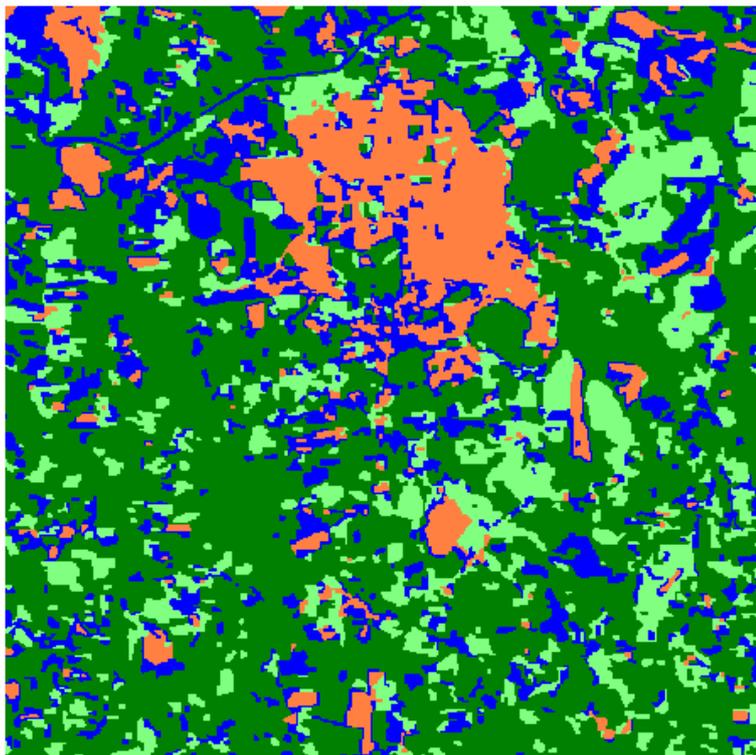


Figura 2 – Imagem classificada CBERS

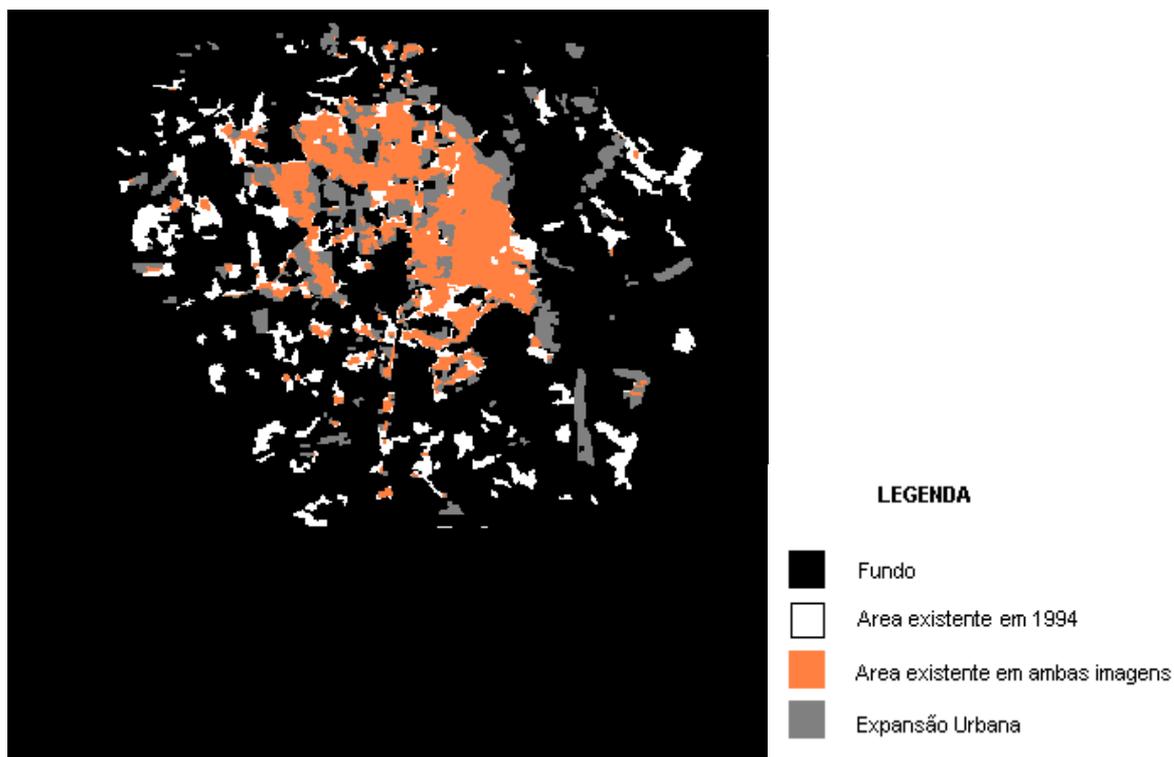


Figura 3 – Imagem do crescimento urbano do ano de 1994 para 2004

## 5. CONSIDERAÇÕES FINAIS

A técnica de RNA mostrou-se eficiente na classificação do uso do solo nas imagens LandSat e na posterior classificação da imagem adquirida pelo sensor CBERS. Cabe salientar que, as datas das imagens são diferentes podendo-se assim por meio das duas imagens classificadas fazer uma avaliação temporal. A capacidade da RNA generalizar a imagem CBERS, a partir de amostras e treinamento da mesma área com uma imagem de diferente data e resolução – LandSat - é importante pois pode-se estender este estudo temporal, simplesmente generalizando outras imagens da mesma área de datas diferentes e destacando que a diferença de resolução não interferiu no processamento utilizando - se esta técnica.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

- ANTUNES, A. F. B. 2003, **Classificação de Ambiente Ciliar Baseada em Orientação a Objeto em Imagens de Alta Resolução Espacial**. Tese de doutoramento Universidade Federal do Paraná. 147 p.
- CRUZ, N.C E GALLO, M. L. B , 2003 **Aplicação de redes neurais artificiais na classificação de imagens multitemporais e multisensor**. III Anais do Colóquio Brasileiro de Ciências Geodésicas – Curitiba-PR
- ECOGNITION, 2001. **User Guide**. Definiens Imaging. München, Germany
- GERMAN, G. W. H.; GAHEGAN, M. N. 1996. **Neural network architectures for the classification of temporal image sequences**. Computers Geosciences, v. 22, n.9, p. 969 – 979.
- HAYKIN, S.1999. **Neural networks. A comprehensive foundation**. 2 Ed. Prentice Hall. New Jersey. p. 842.
- RIBEIRO, S.R. A . 2003. **Integração de imagens Lansat TM e dados auxiliares para a classificação automática de unidades fisionômicas/geológicas usando redes neurais**. Tese de doutoramento Universidade Federal do Paraná. 169 p.
- VENTURIERI A.; SANTOS, J. R. 1998. **Técnicas de classificação de imagens para análise de cobertura vegetal**. Sistema de Informações Geográficas-Aplicações na Agricultura. EMBRAPA. 2ª ed. Brasília. 351-371p.