

## Análise Comparativa da Classificação Espectro-Textural de Imagens Fusionadas CCD e HRC/CBERS-2B Através de Redes Neurais Artificiais

Pedro Lacerda<sup>1</sup>  
Jose Marinaldo Gleriani<sup>1</sup>  
Vicente Paulo Soares<sup>1</sup>  
Gerardo Kuntschik<sup>2</sup>

<sup>1</sup>Universidade Federal de Viçosa- DEF/UFV  
36570-000 -Viçosa - MG, Brasil  
{pedro.lacerda, gleriani, vicente}@ufv.br

<sup>2</sup>Universidade de São Paulo - USP  
Av. Arlindo Bettio, 1000 – EACH  
03828-000 São Paulo SP  
gkuntschik@usp.br

**Abstract.** HRC and CCD / CBERS-2B data fusion provides improvements in the textural images, which have been little explored in automatic classification. In this work, the thematic accuracies of Land Use / Land Cover mapping obtained from neural networks like MLP (*Multilayer Perceptrons*) were performed through two methodologies: architectures with input windows ranging from 3x3 to 9x9 versus MLP networks with simple inputs. For the second architecture, the input vector consisted of three textural descriptors (Contrast, Entropy and Second Angular Momentum) derivatives of windows ranging from 3x3 to 9x9, plus data from the red and infrared bands. Through the Kappa statistics was found that the input windows should have no dimension larger than 5x5. However, the use of networks with textural descriptors improved the accuracies when the size of the windows were increased, presenting better performance compared to the MLP networks with inputs in NxN windows.

**Palavras-chave:** análise de textura, mapa de uso e cobertura da terra, redes neurais, sensores HRC e CCD, texture analysis, land use / land cover mapping, neural networks, HRC and CCD sensors.

### 1. Introdução

Extraír informação temática precisa de dados multiespectrais é um grande desafio para os usuários de Sensoriamento Remoto (SR). Segundo Civco (1993), a maioria das técnicas de classificações são baseadas em propriedades espectrais de uma única data e informações complementares (solos, altitude, etc) não são consideradas. Atributos espaciais como forma, tamanho, textura não são usualmente considerados e apesar dos avanços da classificação digital, fotointerpretes hábeis chegam a exatidões superiores em relação a classificação digital (Trotter, 1991), embora apresente a desvantagem da morosidade envolvida (Campbell e Wynne, 2011). A informação textural, caracterizada pela variação tonal dos pixels vizinhos, é de fácil percepção visual em fotografias de grande escala (Avery e Berlim, 1998), e está associada à resolução espacial do sensor (Mather, 1999) sendo dependente da geometria de iluminação e,consequentemente, do sombreamento.

Haralick et al. (1973) definiram vários descritores texturais derivados da Matriz de Co-ocorrência dos Níveis de Cinza (GLMC), cujo principal conceito são as relações de adjacências de tons de cinza (frequência  $-f_{ij}$  de duas células de tons de cinza  $i$  e  $j$ ) numa dada distância  $d$ . Segundo Tso e Mather (2001) os quatro descritores texturais mais comumente utilizados são:

Segundo Momento Angular (SMA), descrito na Equação 1:

$$SMA = \sum_i \sum_j [p(i, j)]^2 \quad (1)$$

Contraste (Con), descrito na Equação (2)

$$Con = \sum_{n=0}^{N_G-1} n^2 \left[ \sum_i \sum_j p(i, j) \right] \text{ para } |i-j| = n \quad (2)$$

Momento da Inversa da Diferença (MID), descrito na Equação 3:

$$MID = \sum_i \sum_j \frac{1}{1+(i-j)^2} p(i, j) \quad (3)$$

Entropia (E), descrito na Equação 4:

$$E = \sum_i \sum_j p(i, j) \log p(i, j) \quad (4)$$

Onde  $p(i, j)$  denota a  $(i, j)$ ésima entrada de uma matriz GLCM normalizada e  $N_G$  o número de níveis de cinza de uma imagem quantizada (Tso e Mather, 2001).

No início dos anos 90, a redes neurais deram grande impulso á análise de dados de SR (Paola e Schowengerdt, 1995; Kavzoglu e Mather, 2003). Como classificadores, as redes apresentam a vantagens de não serem paramétricas e poderem incorporar informação textural pela criação de entradas em janelas  $N \times N$  (3x3, 5x5, etc ) (Benediktsson et al., 1990; Hepner, 1990; Bischof et al, 1992; Paola e Schowengerdt, 1997; He e Collet, 1999, Lima et al., 2005).

Segundo He e Collet (1999), a textura “interpretada” por um rede  $N \times N$  não tem descrição matemática como encontramos em Haralick et al (1973), além disso, uma rede ao operar com entrada  $N \times N$  tem um ajuste dos pesos com menor número de ciclos (Bischof et al, 1992), o que ilustra uma melhor caracterização do padrão “espectro-textural”. Quanto ao tamanho das janelas, Lima et al. (2005) desaconselharam janelas maiores que 3x3 para dados CCD/CBERS (20m).

O objetivo do presente trabalho foi avaliar, através de estatística kappa, o desempenho comparativo de redes supervisionadas MLP (*Perceptrons de Múltiplas Camadas*), aonde utilizou-se como dados de entrada, as bandas 3 e 4 e os descritores – Entropia, Contraste e Segundo Momento Angular, com redes aonde a textura era “interpretada” em entradas  $N \times N$ . Comparou-se também o tamanho ideal da janela e a vantagem ou não de utilização de informação textural além da espectral.

## 2. Metodologia de Trabalho

A área de estudo fica localizada no município de Dionísio (MG) entre as coordenadas 19°47'50''S/42°36'45''O e 19°53'34''S/42°44'6,7''O, a qual engloba parte do Parque Estadual do Rio Doce. Na área encontra-se Mata Atlântica, Lagoas, pequena áreas urbanas, reflorestamento com eucalipto e pastagem.

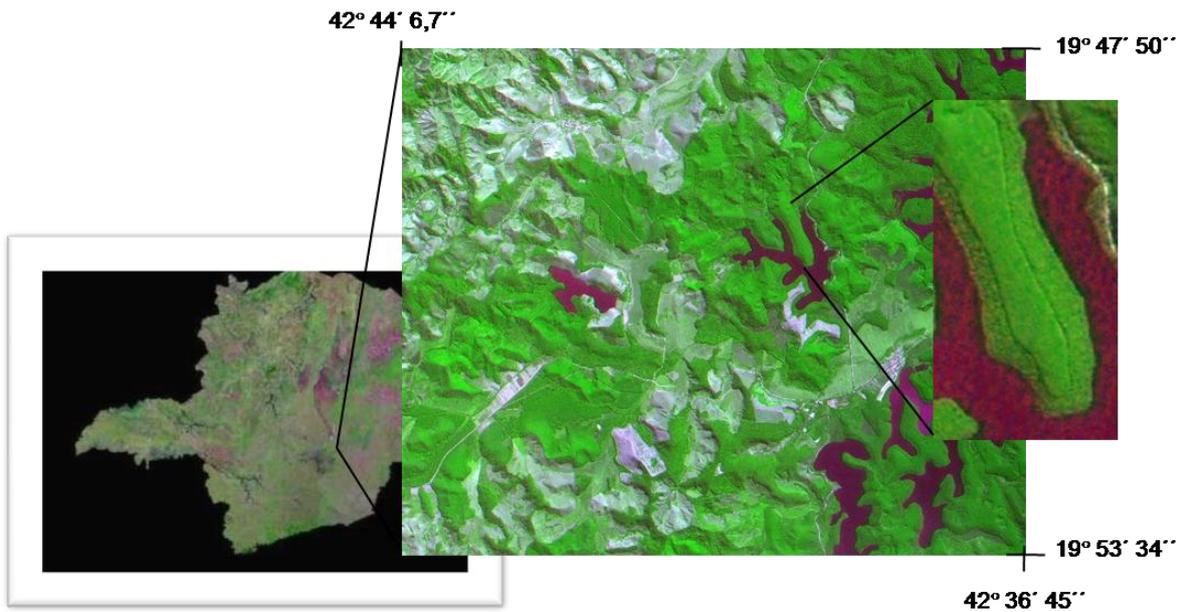


Figura 1. Localização da área de estudo em cena Fusionada HRC/CCD CBERS-2B 2B3R4G, com detalhe da variação textural da água, mata nativa no entorno e plantio de eucalipto no centro.

No presente trabalho, utilizaram-se as cenas dos sensores CCD (151/122) e HRC (151-C/122-3) do dia 19 de julho de 2008. Após o registro de ambas as cenas na projeção UTM – Datum SAD-69 procedeu-se o processo de fusão (RGB-IHS-RGB) com a substituição da componente I (Intensidade) pelos dados HRC (2,5m) antes do retorno às componentes RGB (Richards e Jia, 1998). Na página eletrônica “<http://wiki.dpi.inpe.br/doku.php?id=fusaohrccdcbers2b:exemplo>” existe um tutorial sobre o procedimento.

Foi empregada uma metodologia semelhante a utilizada por He e Collet (1999). Na banda 4 fusionada, para janelas de tamanho 3x3, 5x5, 7x7, 9x9, gerou-se o Contraste, a Entropia e o Segundo Momento Angular (Con, E, SMA), que, junto com os dados das bandas 3 e 4 formaram os vetores de entrada das redes *MLP* (*Perceptrons de Múltiplas Camadas*), contendo assim, três descritores texturais e dois espectrais (Figura 2). Utilizou-se as bandas 3 e 4 por estas conterem mais de 90% da informação espectral da vegetação (Baret et al. 1989).

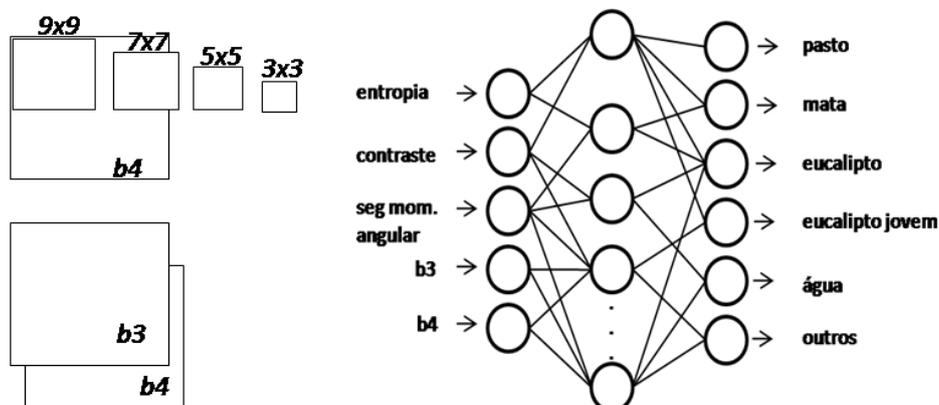


Figura 2. – Rede MLP com arquitetura 5-9-6, ilustrando os dados texturais obtidos em janelas além dos dados espectrais e as classes de saída.

Todos os dados originais e imagens texturais obtidos foram linearizados através da Equação (5), sendo exportados em formato ASCII para o SNNS (*Stuttgart Neural Network Simulator*) (Zell et al, 1998). A função de ativação utilizada foi a logística sigmóide.

$$x_{i,j,k} = \frac{DN_{i,j,k} - DN_{\min,k}}{DN_{\max,k} - DN_{\min,k}} \tag{5}$$

Aonde,  $x_{i,j,k}$  são os números reais obtidos para os pixels da linha  $i$ , coluna  $j$ , banda  $k$ . DN são os valores digitais,  $\min$  e  $\max$  são os valores digitais mínimos e máximos da banda  $k$ .

Numa segunda etapa utilizou-se redes como entrada com janelas variando de 3x3 até 9x9, para que a informação textural fosse captada além da informação espectral (Figura 3).

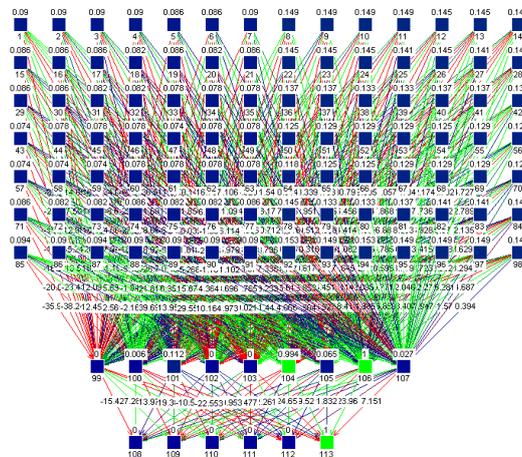


Figura 3.– Interface do SNNS com rede 7x14-9-6

Gerou-se um Plano de Informação (PI) com 593 pontos com amostragem aleatória, excetuando-se as áreas de onde foram coletadas amostras de treinamento, e fez-se a fotointerpretação com a rotulagem dos pontos nas classes pré-definias. Gerou-se a estatística kappa e a sua variância para a execução do teste comparativo – Z (Gongalton e Green, 2009).

$$Z = \frac{|\hat{k}_1 - \hat{k}_2|}{\sqrt{\hat{v}\text{ar}(\hat{k}_1) + \hat{v}\text{ar}(\hat{k}_2)}} \tag{6}$$

Aonde  $\hat{k}_1$  e  $\hat{k}_2$  são os estimadores de kappa para dois classificadores cujo desempenho é comparado e  $\hat{v}\text{ar}(\hat{k}_1)$  e  $\hat{v}\text{ar}(\hat{k}_2)$ , estimadores das respectivas variâncias.

### 3. Resultados e Discussão

Os resultados comparativos dos valores dos índices Kappa entre as duas maneiras de interpretar textura são exibidos na Tabela 1. O primeiro ponto a ser analisado é que o aumento do tamanho da janela aumenta a exatidão temática para a classificação - Con, E, SMA, b3 e b4 - ao contrário do que ocorre com a rede  $N \times N$  aonde o valor começa a ter decréscimo a partir da rede 5x5. Uma explicação para o decréscimo do kappa para as redes com janelas maiores é que tanto no processo de treinamento, como na classificação, o tamanho da entrada, faz que durante a leitura de um padrão de amostra nos arquivos de treinamento tenha, nos limites desse, impureza nas entradas, para o mesmo padrão de saída.

Tabela 1.- Valores do índices Kappa para redes alimentadas com descritores estatísticos (Con, E, SMA, b3 e b4) comparados a redes com entradas em janelas  $N \times N$ .

Con, E, SMA + b3 e b4	<i>Kappa</i>	Redes $N \times N$	<i>Kappa</i>
		$1^*$	0,3864
$3 \times 3$	0,4079	$3 \times 3$	0,3867
$5 \times 5$	0,4443	$5 \times 5$	0,4312
$7 \times 7$	0,4650	$7 \times 7$	0,4208
$9 \times 9$	0,4668	$9 \times 9$	0,3936

\*As vezes descrito como  $1 \times 1$ , é a rede com entrada simples, sem janela, como na Figura 2.

Durante o processo de classificação, a mesma entrada, cuja saída é desejada, está lendo pixels de classes diferentes (Figura 4). Provavelmente, a janela  $N \times N$  faz o mesmo papel de amostras coletadas nas bordas das classes o que, segundo Foody (1999), aumenta a exatidão de classificação por evitar o sobreajuste no treinamento da rede. No entanto, no presente trabalho, o aumento da janela além de  $5 \times 5$  não trouxe esse benefício.

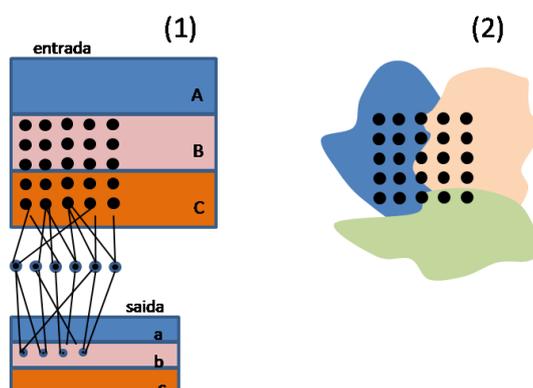


Figura 4.– Rede com entrada  $N \times N$  com janela de entrada “lendo” dados em duas classes para uma mesma saída (1) e problema de generalização oriundo das janelas  $N \times N$  durante transição entre classes (2).

Resultados semelhantes podem ser encontrados em Lima et al. (2005) com dados CCD/CBERS-2 (20m), onde uma janela  $3 \times 3$  resultou em valores de kappa (0,7683), significativamente superior a uma rede com entrada simples (0,6169), porém, as redes  $5 \times 5$  e  $7 \times 7$  resultaram em valores de kappa muito semelhantes – 0,767 e 0,775 - respectivamente, sem nenhum acréscimo significativo.

Fazendo-se a análise comparativa sobre o tamanho da janela  $N \times N$  (Tabela 2), observa-se que existe uma melhora na exatidão de classificação com o aumento da mesma, porém, nunca significativo a 5 ou 1%. Essa melhora ocorre até a janela com dimensões  $5 \times 5$  com posterior decréscimo.

Tabela 2.- Valores da estatística Z e de p-calculado, resultantes da análise do kappa e a respectiva variância, com o progressivo dimensões da janela.

Estatística Z e p-calculado	Dimensão da janela NxN	Dimensão da janela NxN				
		1x1	3x3	5x5	7x7	9x9
Z	1x1	x				
p		x				
Z	3x3	0,0028	x			
p		0,4988	x			
Z	5x5	1,2548	1,2724	x		
p		0,1047	0,1016	x		
Z	7x7	0,9657	0,9799	0,2947	x	
p		0,167	0,1635	0,3841	x	
Z	9x9	0,1998	0,2049	1,0531	0,7635	x
p		0,4208	0,4188	0,1461	0,2225	x

\* p&lt;0,05 ; \*\*p&lt;0,01

Analisando-se comparativamente a extração de informação textural via descritores (Con, E, SMA, b3 e b4) *versus* janelas NxN (Tabela 3) observa-se vantagens para a primeira metodologia, comparando-se janelas de mesma dimensão como a 9x9 e até janelas inferiores como a 7x7 *vs* 9x9, p.e. He e Collet (1999) afirmam, para dados XS1/SPOT (20m), que o tamanho da janela pode ser inapropriado levando a queda na exatidão temática e, que os descritores devem ser obtidos em janelas de 5x5 até 7x7.

Tabela 3.- Valores da estatística Z e de p-calculado confrontando-se diferentes dimensões de janela *versus* redes cujas entradas foram descritores Con, E, SMA e as bandas 3 e 4.

Estatística Z e p-calculado	Con, E, SMA b3 e b4	Janelas NxN			
		3x3	5x5	7x7	9x9
Z	3x3	0,6153	0,6622	0,3674	0,4025
p		0,2691	0,2539	0,3566	0,3436
Z	5x5	1,652*	0,3722	0,6693	1,4271
p		0,0492	0,3548	0,2516	0,0767
Z	7x7	2,2416*	0,9605	1,2589	2,097*
p		0,01224	0,1683	0,104	0,022
Z	9x9	2,2124*	0,9285	1,2275	1,9803*
p		0,0134	0,1765	0,1098	0,0238

\* p&lt;0,05, \*\*p&lt;0,01

Não se trata de afirmar que as janelas aqui utilizadas equivalem matematicamente aos descritores (Con, E, SAM) utilizados, apenas fez-se a opção de utilizar três dos quatro descritores utilizados em He e Collet (1999) e Tso e Mather (2001). Como afirmado, a textura extraída na janela NxN é “caixa-preta” e, objetivou-se utilizar dados HRC para o enriquecimento textural da cena. Lima et al (2005) observaram que uma janela 3x3 foi suficiente para dados CCD (20m). Por outro lado, no presente trabalho, janelas superiores a 5x5 produziram resultados com exatidão decrescente.

#### 4. Conclusões

Redes MLP com entradas  $N \times N$  captam a textura e produzem melhores resultados, comparada às redes com entradas simples. Porém, para os dados de 2,5m de resolução geométrica, janelas com dimensões superiores a  $5 \times 5$  são desaconselháveis. A classificação com a utilização de descritores texturais como Contraste, Entropia e Segundo Momento Angular é superior, e a exatidão temática obtida é progressiva ao tamanho da janela.

#### Agradecimentos

Os autores agradecem o apoio FAPEMIG

#### Referências Bibliográficas

Avery, T. E.; Berlím, G.L. **Fundamentals of remote sensing and airphoto interpretation**. 5 ed, New Jersey, Editora Prentice Hall, 472p.

Baret, F.; Guyot, G.; Major, D.J. Crop biomass evaluation using radiometric measurements. **Photogrammetria (PRS)**, v.43, n.5, p. 241-256, 1989.

Benediktsson, J.A.; Swain, P. H.; Ersoy, O.K. Neural network approaches versus statistical methods in classification of multisource remote sensing data. **IEEE on Transactions on Geoscience and Remote Sensing** v.28, n.4, p.540-552, 1990.

Bischof, H.; Schneider, W.; Pinz, A.J. Multispectral Classification of Landsat-images using neural networks, **IEEE on Transactions on Geoscience and Remote Sensing**.v.30, n.3, p.482-490, 1992.

Foody, G.M. The significance of border training patterns in classification by a feedforward neural network using back propagation learning. **International Journal of Remote Sensing**. v.20, n.18, p.3549-3563, 1999.

Gongalto, R.G.; Green, K. **Assessing the accuracy of remotely sensed data: principles and practices**, Boca Raton: CRC Editora, 612p.

Haralick, R. M., Shanmugan, K., and Dinstein, I., Textural Features for Image Classification. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 3, n. 6, p. 610-621, 1973.

He, H.; Collet, C. Combining spectral and textural features for multispectral image classification with artificial neural networks. In: International Archives of Photogrammetry and Remote Sensing. Proceedings. Valladolid. Espanha, Jun 1999. Vol XXXII, PP. 175-181.

Hepner, G. F. Artificial neural network classification using a minimal training set: comparison to conventional supervised classification. **Photogrammetric Engineering and Remote Sensing**, vol.56, n.4, p.469-473, 1991.

Kavzoglu, T.; Mather, P.M. The use o backpropagation artificial neural networks in land cover classification. **International Journal of Remote Sensing**. v.24, n.23, p.4907-4938, 2003.

Lima, R.P.; Gleriani, J.M.; Antunes, M.A.M.; Zanutto, P.A. Discriminação espectral e textural entre florestas de eucalipto e mata atlântica com dados CCD/CBERS através de redes neurais artificiais In: Simpósio Brasileiro de cartografia (SBC), 22, 2005, Macaé (RJ). CD-ROM, **Anais...Congresso Brasileiro de Cartografia**. Rio de Janeiro – RJ. Sociedade Brasileira de Cartografia, 2005.

Paola, J.; Schowengerdt, R.A. The effect of neural-network structure on a multispectral land-use/land-cover classification. **Photogrammetric Engineering and Remote Sensing**.vol.63, n.5, p.535-544, 1997.

Paola, J.D.; Schowengerdt, R. A. A review and analysis of backpropagation neural networks for classification of remotely-sensed multi-spectral imagery. **International Journal of Remote Sensing**. v.16, n.16, p.3033-3058, 1995.

Tso, B.; Mather, P.M. **Classification methods for remotely sensed data**. London, Taylor e Francis, 332p, 2001.