

## Métodos de classificação de imagens orbitais para o mapeamento do uso do solo: estudo de caso na Sub-Bacia do Córrego das Três Barras

Julio Cesar Demarchi<sup>1</sup>  
Anderson Antonio da Conceição Sartori<sup>1</sup>  
Célia Regina Lopes Zimback<sup>1</sup>

<sup>1</sup> Universidade Estadual Paulista “Júlio de Mesquita Filho” – UNESP/FCA  
Caixa Postal 237 – 18610-307 – Botucatu – SP, Brasil  
{julio.demarchi, sartori80, czimback}@gmail.com

**Abstract:** The knowledge of the land use and occupation has an essential importance for the agricultural, regional and environmental planning. The use of Remote Sensing tools has increased a lot nowadays, allowing the land use maps creation through many techniques, as satellite images classification. Under this context, this work aims to compare different methods of image classification using CBERS-2 images, bands 2, 3 and 4, for mapping the land use of Três Barras stream sub-basin, situated in the city of Santa Cruz do Rio Pardo, São Paulo State. The image classification methods used were: Cluster broad (CB), Cluster Fine (CF), minimum distance, maximum likelihood with equal prior probability for each signature (MAXLIKE/IP), maximum likelihood with prior probabilities specified for each signature (MAXLIKE/EP), parallelepiped and image segmentation. The classifications accuracy was calculated through Kappa index and global accuracy. The maps produced and the accuracy indexes analysis show that the MAXLIKE/EP classification was the most efficient method used for the goal proposed, and the parallelepiped method presented the worst accuracy, while the others classifiers presented intermediated qualities, each one with its advantages and disadvantages. Some thematic classes showed confusion among them, specially "annual crops" and "sugarcane", because of the similarity in their spectral response, and small representativeness classes were overestimated in great number of the classification methods used.

Palavras-chave: satellite images classification, land use maps, CBERS-2 images, classificação de imagens de satellite, mapas de uso do solo, imagens CBERS-2.

### 1. Introdução

O conhecimento da dinâmica de uma paisagem numa determinada região é um fator importante no planejamento racional e sustentabilidade do meio ambiente. Desta maneira, o sensoriamento remoto orbital torna-se uma notável ferramenta na aquisição primária de informações para o mapeamento do uso do solo, fundamento primordial para o planejamento regional das terras (Barbosa, 2009).

Um dos principais objetivos do sensoriamento remoto é o de distinguir entre e identificar as composições de diferentes materiais superficiais, sejam eles tipos de vegetação, padrões de uso do solo, rochas e outros. Essa distinção e identificação tornam-se possíveis em razão dos materiais superficiais terem comportamentos específicos ao longo do espectro eletromagnético, comportamentos esses que podem, portanto, ser usados para identificá-los (Crosta, 1993).

O êxito de uma análise de imagens do sensoriamento remoto depende de fatores que vão além dos princípios básicos de interpretação, como a época de obtenção das imagens de satélite, o tipo de produto, as bandas espectrais, a escala das imagens e, por fim, a experiência do analista (Barbosa, 2009).

Tal experiência, bem como a capacidade interpretativa do analista, têm sido aproveitadas para avaliar os resultados das classificações digitais das imagens orbitais. A classificação via computador é baseada em determinados parâmetros estatísticos, ou seja, a identificação e a discriminação dos alvos são feitas sem a subjetividade da análise visual (Assad et al., 1998).

A classificação de uma imagem nada mais é que a identificação de elementos nelas presentes pela associação de cada um de seus pixels a uma determinada classe temática. A

comparação é realizada entre pelo menos duas bandas do espectro, a fim de se comparar o mesmo pixel por meio de possíveis diferentes respostas (Fitz, 2008).

Os métodos de classificação digital podem ser agrupados em função da presença ou não de uma fase de treinamento onde o analista interage com o computador, isto é, podem ser divididos em categorias, de acordo com o tipo de treinamento: supervisionados, não-supervisionados e híbridos, que podem ser rígidos ou relativos (Eastman, 2006).

A exatidão de mapas temáticos tem sido determinada a partir das chamadas matrizes de erros ou de contingência, as quais são constituídas por igual número de linhas e de colunas, e representam o confronto entre o resultado da classificação (visual ou digital) de um produto de sensoriamento remoto (mapa temático) e a verdade terrestre ou outra informação considerada como referência (Ponzoni e Almeida, 1996).

Este trabalho teve por objetivo comparar a eficiência de métodos de classificação de imagens orbitais em mapeamentos de uso e ocupação do solo, na Bacia do Córrego das Três Barras, localizada no município de Santa Cruz do Rio Pardo–SP.

## **2. Material e Métodos**

### **2.1 Área de estudo**

A sub-bacia do Córrego das Três Barras está localizada na porção Sudoeste do município de Santa Cruz do Rio Pardo - SP, e possui superfície de 5.053,28 ha. Apresenta as seguintes coordenadas geográficas: 624502 – 635709 e 633806 - 7465604, no fuso 22 S, no sistema de coordenadas Universal Transversa de Mercator (UTM).

### **2.2 Imagens orbitais**

Para a realização dos mapeamentos de uso e cobertura do solo através dos métodos de classificação supracitados, foi utilizada imagem de satélite no formato digital CCD do Satélite Sino-Brasileiro de Recursos Terrestres (CBERS-2), com órbita 157 e ponto 126 e resolução espacial de 20 m, obtida na data de passagem de 07 de março de 2007. Para a elaboração do mapa de verdade terrestre através da análise visual, utilizou-se imagem orbital do satélite Advanced Land Observing Satellite (ALOS), sensor AVNIR-2 com resolução espacial de 10 m, obtida em 11 de março de 2007.

### **2.3 Classificação das Imagens**

Inicialmente, foi realizado o mosaico das cartas topográficas, folhas Ourinhos (SF-22-Z-A-VI-3) e Santa Cruz do Rio Pardo (SF-22-Z-A-VI-4), correspondentes à área de estudo, e delimitado o limite da sub-bacia. As imagens CBERS-2 foram obtidas no catálogo de imagens CBERS, na página do Instituto Nacional de Pesquisas Espaciais (INPE). Foram realizadas a correção do georreferenciamento das bandas 2, 3 e 4, de modo a se ajustar ao limite da sub-bacia, e a elaboração da composição colorida falsa-cor 243.

A imagem ALOS (AVNIR-2) foi utilizada para vetorização das classes de uso do solo em tela, e geração do mapa de verdade terrestre.

Para a realização das classificações da imagem, foram mapeadas sete classes de uso do solo, divididas em vinte e três amostras de treinamento conforme a variabilidade da assinatura espectral, a saber: 1. Solo exposto (classes 1 a 5 e 23); 2. Mata nativa (classes 6 e 7); 3. Cana-de-açúcar (classes 8 a 13); 4. Pastagem (classes 14 a 16); 5. Eucalipto (classe 17); 6. Culturas anuais (classes 18 a 21); e 7. Café (classe 22). As classes obtidas foram reclassificadas e agrupadas nas sete classes iniciais. As áreas ocupadas por Várzea e Mata Ciliar não foram incluídas nas classificações em razão do elevado grau de confusão entre suas assinaturas espectrais e as demais classes. Portanto, elaborou-se uma máscara das duas classes a partir da imagem verdade, que foi aplicada aos mapas temáticos após as classificações. A classe

“Rodovias” também não foi considerada no mapeamento devido à confusão com a classe “Solo exposto” e, portanto, foi digitalizada e rasterizada sobre os mapas gerados.

Os métodos de classificação utilizados, suas características, especificidades e procedimentos são descritos abaixo:

- *Cluster*: método de classificação não-supervisionada. Neste trabalho, foram executados dois tipos de classificação cluster: *Broad* (CB), que agrupa em um cluster o pico e seus vizinhos de ambos os lados, e é dividido no ponto médio entre os picos; e *Fine* (CF), que permite que um pico possua vizinhos não diagonais com maior frequência, e separa em diferentes clusters todas as quebras de histograma. Para o primeiro, foi definido o número máximo de vinte e três clusters, mas o classificador gerou apenas dezesseis. O segundo método gerou os vinte e três clusters previamente definidos. Em seguida, os clusters foram comparados à imagem verdade de modo a realizar a reclassificação e agrupamento nas sete classes consideradas, conforme a classe mapeada por cada cluster.

- *KNN*: método de classificação supervisionada. Foram testados os *k* vizinhos mais próximos com valores 2, 4 e 6, mas adotado apenas o de  $k = 2$ , pois apresentou melhor exatidão.

- *Máxima verossimilhança*: método de classificação supervisionada. No presente trabalho, foram utilizados dois métodos de classificação Maxver: igual probabilidade de ocorrência para cada assinatura (MAXVER/IP), e probabilidades especificadas a priori (MAXVER/EP). Nestes dois métodos, a proporção de exclusão dos pixels foi de 0%, classificando-se assim todos os pixels da imagem. A probabilidade de ocorrência de cada classe de uso do solo foi calculada a partir da área de cada categoria de uso e cobertura do solo na imagem verdade para o método MAXVER/EP. Para as classes de uso do solo sub-divididas, a probabilidade de ocorrência de cada classe foi dividida entre estas sub-classes.

- *Distância mínima (ou mínima distância para médias)*: o método de classificação supervisionada foi do tipo bruto (raw), que classifica cada pixel na classe cuja média possui menor distância em relação ao referido pixel. Este método foi adotado em razão da sub-divisão das classes para a coleta de amostras de treinamento, que não apresentarem alta variabilidade de DN.

- *Paralelepípedo*: este método de classificação supervisionada define áreas quadradas ou em paralelepípedo limitadas pelo maior e pelo menor valor de pixels contidos em agrupamentos pré-escolhidos, determinados pelas amostras de treinamento, que representarão uma determinada classe presente na imagem para a classificação.

- *Segmentação*: este método de classificação baseia-se no crescimento de regiões de acordo com a similaridade espectral, definida por um limiar de similaridade especificado pelo usuário, sendo que os segmentos serão mais homogêneos quanto menor o limiar (EASTMAN, 2009). A metodologia utilizada segue o princípio de segmentação de imagens executado por Coutinho (1997). Neste trabalho, foram testados os limiares de similaridade 30, 40 e 50, mas utilizou-se a imagem de segmentos com limiar 30, por criar regiões visualmente mais homogêneas que os demais.

## 2.4 Avaliação da acurácia das classificações

A acurácia das classificações foi determinada através de dois métodos: o índice Kappa e a exatidão global, ambos calculados com base em uma matriz de erros e utilizados como medida de concordância entre o mapa e a referência adotada para a estimativa da exatidão, neste caso, a imagem verdade.

O índice Kappa (*k*) é calculado a partir da seguinte fórmula, conforme descrito por Ponzoni e Rezende (2002):

$$k = \frac{N \sum x_{ii} - \sum x_{i+} \cdot x_{+i}}{N^2 - \sum x_{i+} \cdot x_{+i}} \quad (1)$$

Em que:  $N$  = número total de observações;  $x_{ii}$  = elementos da diagonal principal da matriz; e  $x_{i+}$  e  $x_{+i}$  = somatório dos elementos da linha e coluna, respectivamente.

O valor de  $k$  expressa a concordância entre a classificação dos dados contidos nos produtos de sensoriamento remoto considerados e a realidade de campo (verdade terrestre), mostrando a qualidade da classificação, conforme Tabela 1.

Tabela 1. Qualidade da classificação associada aos valores da estatística Kappa

Valor de Kappa	Qualidade do mapa temático
< zero	Péssima
zero - 0,20	Ruim
0,20 - 0,40	Razoável
0,40 - 0,60	Boa
0,60 - 0,80	Muito Boa
0,80 - 1,0	Excelente

Fonte: Adaptada de Landis e Koch (1977) citado por Moreira (2001).

O índice de exatidão global, conforme descrito por Ponzoni e Rezende (2002), é descrito pela fórmula:

$$G = \frac{\sum n_{ii}}{n} \quad (2)$$

Em que:  $G$  é a exatidão global;  $n_{ii}$  o número de elementos da diagonal da matriz de confusão; e  $n$  o número total de observações.

### 3. Resultados e discussão

As Figuras 1 a 8 apresentam os mapas de uso do solo da Sub-bacia do Córrego das Três Barras, obtidos pelos diferentes métodos de classificação de imagens orbitais.

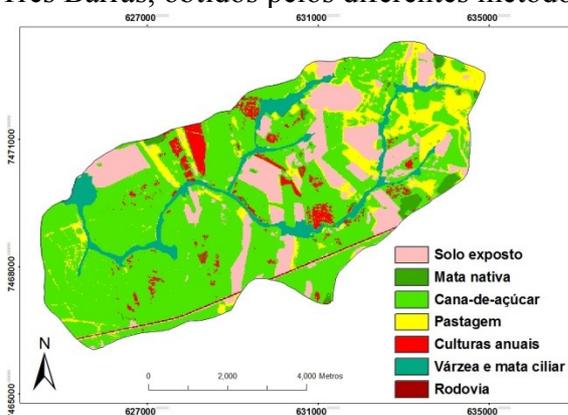


Figura 1. Classificação não-supervisionada CB

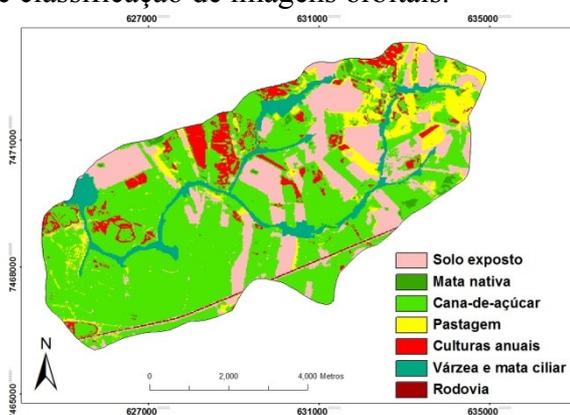


Figura 2. Classificação não-supervisionada CF

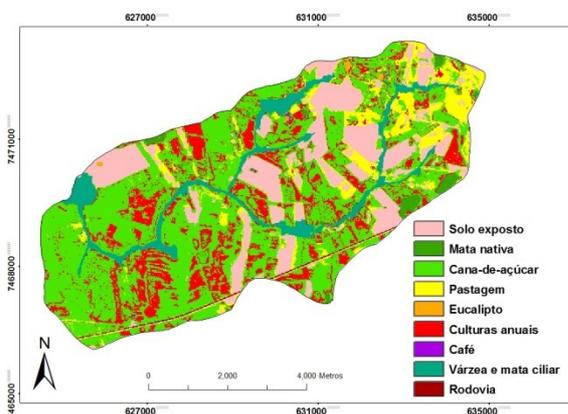


Figura 3. Classificação supervisionada KNN (k=2)

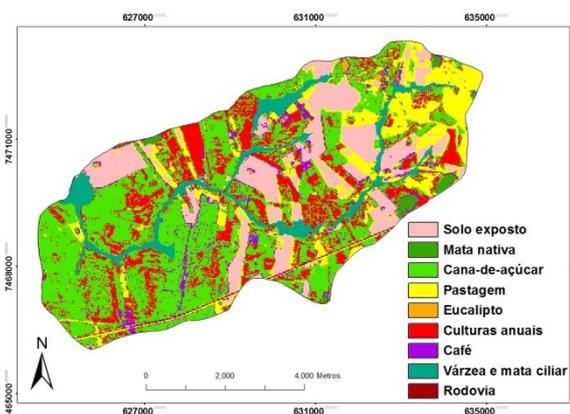


Figura 4. Classificação supervisionada MAXVER/IP

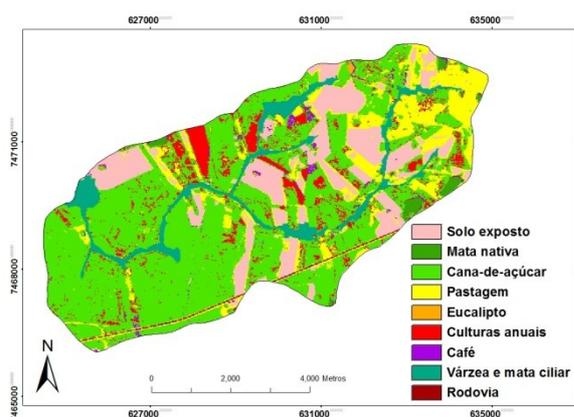


Figura 5. Classificação supervisionada MAXVER/EP

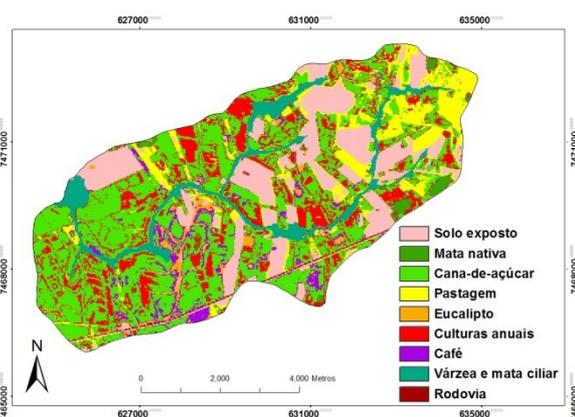


Figura 6. Classificação supervisionada por distância mínima

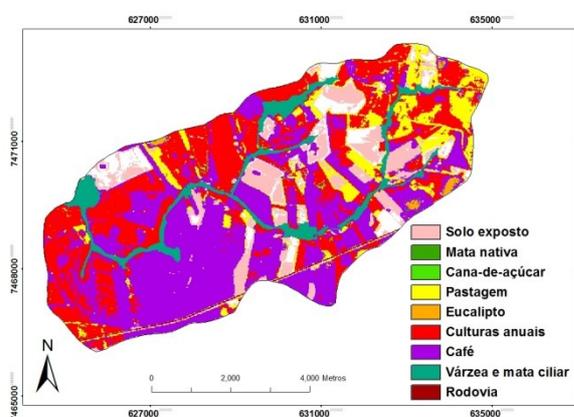


Figura 7. Classificação supervisionada por paralelepípedo

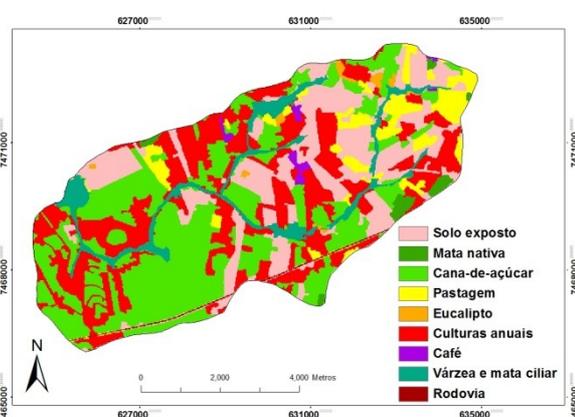


Figura 8. Segmentação de imagem com limiar de similaridade = 30

A Tabela 2 mostra a distribuição das áreas dos mapas de uso do solo nas classes temáticas consideradas, em hectares, e a Tabela 3 apresenta os valores de Índice Kappa, qualidade dos mapeamentos e exatidão global das classificações.

Tabela 2. Sub-bacia do Córrego das Três Barras: Área (ha) das classes de uso do solo por método de classificação e verdade terrestre

Área (ha)	Verdade terr	Cluster (broad)	Cluster (fine)	KNN 2	Maxver (IP)	Maxver (EP)	Mindist raw	Piped (min/max)	Segment
Solo exposto	877,76	826,56	1.050,6	838,72	761,12	756,92	868,52	482,84	1.080,32
Mata nativa	98,16	80,4	45,24	75,2	49,68	48,56	62,4	3,52	64,6
Cana-de-açúcar	2.555,28	3.060,44	2.841,48	2.502,96	2.057,32	2.791,08	2.086,52	16,84	1.749,68
Pastagem	564,28	548,04	436,72	456,84	707,32	673,4	550,04	496,84	349,92
Eucalipto	16,04	0	0	15,64	18,68	11,04	132,88	24,24	39,68
Culturas anuais	560	190,16	331,56	806,88	897,68	374,36	782	1525,16	1.381,68
Café	31,28	0	0	9,36	213,8	50,24	223,24	1865,12	39,72
Não classificado	2,8	0	0	0	0	0	0	291,04	0
<b>Total</b>	<b>4.705,6*</b>	<b>4.705,6</b>	<b>4.705,6</b>	<b>4.705,6</b>	<b>4.705,6</b>	<b>4.705,6</b>	<b>4.705,6</b>	<b>4.705,6</b>	<b>4.705,6</b>

\* A área total classificada é inferior à área total da sub-bacia por não considerar as classes “Várzea e mata ciliar” e “Rodovias”.

Tabela 3. Índice Kappa, qualidade do mapeamento e Exatidão Global das classificações

Classificadores	Índice Kappa	Qualidade	Exatidão global
Cluster broad (CB)	0,5342	Boa	0,7229
Cluster fine (CF)	0,5121	Boa	0,7021
K-nearest neighbor (k = 2)	0,4652	Boa	0,6548
MAXVER/IP	0,5059	Boa	0,6585
MAXVER/EP	0,60	Boa	0,7516
Distância mínima	0,4219	Boa	0,601
Paralelepípedo (min/max)	0,16	Ruim	0,223
Segmentação (limiar de similaridade 30)	0,4930	Boa	0,6396

De maneira geral, algumas classes de uso do solo apresentaram confusão entre si, em razão da semelhança na assinatura espectral da composição falsa-cor da imagem CBERS-2 utilizada na coleta das amostras de treinamento. Vários métodos de classificação de imagem apresentaram confusão entre as classes “cana-de-açúcar” e “culturas anuais”, sobretudo a região situada na porção sudeste da sub-bacia, ocupada por uma extensa área de cana-de-açúcar, que apresentou várias manchas de culturas anuais. Curiosamente, na mesma área, foram identificadas poucas manchas de solo exposto, representado pelos carregadores situados entre os talhões de cana-de-açúcar, uma vez que os polígonos das amostras de treinamento coletadas reuniam parte dos talhões e dos carregadores.

A classe temática “café” não foi bem identificada e delimitada em nenhuma das classificações realizadas. Tal cultura é cultivada em apenas 31,28 ha na área de estudo, ou 0,66 % e em pequenas manchas. A classificação Maxver/EP apresentou a maior exatidão no mapeamento da cultura do café, enquanto a classificação pelo método do paralelepípedo a superestimou em 39,63 % da área de estudo, ocupando áreas cultivadas com cana-de-açúcar e culturas anuais, principalmente. Tal fato se deve ao grande intervalo entre os valores máximo e mínimo de reflectância, o que gerou um paralelepípedo de níveis de cinza de intervalo muito grande para a classe “café”. Já a classe “solo exposto”, em razão da assinatura espectral bem definida e da subdivisão em seis classes de reflectância características de solo exposto, apresentou maior exatidão nos mapeamentos.

Os métodos de classificação não-supervisionada por Cluster utilizados (CB e CF) apresentaram valores próximos de índice Kappa e exatidão global. A qualidade do mapeamento foi prejudicada pelo agrupamento, no mesmo cluster, de classes de uso do solo diferentes, identificadas na imagem verdade, fato que levou os operadores a optar, durante a reclassificação nas sete classes consideradas no trabalho, por atribuir a ele a classe de maior representatividade dentro do cluster. De modo geral, houve confusão entre as classes “cana-de-açúcar” e “culturas anuais” e entre “pastagem” e “solo exposto”. As classes “cana-de-açúcar” e “mata nativa” também apresentaram confusão na classificação CF, em razão do maior número de clusters. Neste método, as classes “eucalipto” e “café” tiveram presença nula.

A classificação supervisionada pelo método K-nearest neighbor com valor K igual a 2 apresentou índice Kappa 0,4652 e exatidão global 0,6548, tal como ocorreu nas demais classificações, o que retrata menor exatidão entre as classes temáticas que a exatidão total do mapeamento. De modo geral, áreas representativas ocupadas com cana-de-açúcar foram classificadas como “culturas anuais”, e vice-versa. Houve também confusão entre as classes “cana-de-açúcar” e “pastagem”, e as manchas de café foram classificadas nas mais diferentes classes temáticas.

As classificações supervisionadas por máxima verossimilhança apresentaram comportamentos e qualidades diferentes, porém não muito distintos, conforme o método utilizado. O método MAXVER/EP, com probabilidades de ocorrência das classes retiradas da porcentagem de ocorrência das classes na imagem verdade, gerou os melhores índice Kappa e exatidão global entre as classificações realizadas, sobretudo porque limitou a ocorrência das classes “eucalipto” e “culturas temporárias”, classificadas com maior área e menor exatidão no mapa obtido pelo método MAXVER/IP. A confusão entre cana-de-açúcar e culturas anuais também foi menor no método MAXVER/EP em relação ao método MAXVER/IP: no primeiro método, houve superestimação da classe “culturas anuais” e, no segundo, da classe “cana-de-açúcar”, conforme constatado na Tabela 2.

A classificação supervisionada por distância mínima apresentou os segundos valores mais baixos de índice Kappa e exatidão global. Destacam-se as seguintes características: confusão entre as classes “cana-de-açúcar” e “culturas anuais”, dada em razão da semelhança na assinatura espectral de algumas sub-classes destas duas culturas; e superestimação das classes “eucalipto” e “café”, sobretudo em áreas cultivadas com “cana-de-açúcar” e “culturas anuais”, o que sugere uma maior variabilidade na resposta espectral destas últimas classes temáticas e suas sub-classes. Para minimizar este erro, poderia ser adotada a classificação pelo método da distância mínima normalizada, com um valor de Z-score que ampliaria o raio de enquadramento nas classes “cana-de-açúcar” e “culturas anuais”.

A classificação supervisionada por paralelepípedo, método dos valores mínimos e máximos, apresentou valores de exatidão global e índice Kappa muito baixos, caracterizando uma classificação “ruim”. As classes “café” e “culturas anuais” foram superestimadas, de 0,6 % e 11,9 % da área total (imagem verdade), para 39,6 % e 32,4 %, respectivamente, enquanto as classes “cana-de-açúcar” e “mata nativa”, que ocupam 54,3 % e 2,1 % da área de estudo, tiveram suas áreas mapeadas reduzidas a 0,3 % e 0,07 %, respectivamente. Além disso, cerca de 6,1 % da área da sub-bacia, caracterizadas por solo exposto, não foram mapeadas, o que torna inviável a adoção deste método no mapeamento de uso do solo em questão.

Finalmente, a segmentação de imagem com limiar de similaridade 30 apresentou áreas mais homogêneas com polígonos maiores, em razão da divisão da imagem em regiões (segmentos). O índice Kappa sugere uma classificação de boa qualidade. Porém, várias classes de uso do solo foram confundidas entre si, tais como: “pastagem” e “solo exposto”, “pastagem” e “culturas anuais”, “cana-de-açúcar” e “culturas anuais”, “eucalipto” e “mata nativa”, “café” e “cana-de-açúcar”, e outras classes, em menor grau.

#### 4. Conclusões

Os procedimentos metodológicos utilizados neste trabalho possibilitaram as seguintes constatações:

O método de classificação supervisionada por máxima verossimilhança (MAXVER/EP) apresentou maior exatidão entre os métodos utilizados. Os métodos de classificação não-supervisionada por cluster tiveram qualidade comprometida em razão do agrupamento de diferentes classes temáticas no mesmo cluster. Os métodos de classificação supervisionada por distância mínima, MAXVER/IP e K-nearest neighbor apresentaram exatidão intermediária entre os métodos utilizados, este último com perda de exatidão à medida que se aumentou o valor de K. A segmentação de imagens possui a especificidade de gerar segmentos mais homogêneos, e o limiar de similaridade utilizado exerceu grande influência na geração dos segmentos e na qualidade da classificação. Neste trabalho, apresentou exatidão intermediária em relação aos demais métodos. Por fim, a classificação supervisionada pelo método do paralelepípedo apresentou baixo índice de exatidão, não sendo recomendado para este tipo de mapeamento.

A divisão das classes temáticas em sub-classes, utilizada na coleta de amostras de treinamento, foi eficiente para discriminar algumas classes de uso do solo na maioria dos mapeamentos, tais como “solo exposto”, “mata nativa” e “pastagem”. Porém, não solucionou o problema da confusão entre as classes “cana-de-açúcar” e “culturas anuais”, em razão da semelhança entre suas respostas espectrais.

Alguns métodos de classificação apresentaram melhor acurácia, porém, nenhum deles foi suficiente para um mapeamento plenamente confiável de uso do solo, já que a maior exatidão global foi 0,7516, o que mostra uma confusão de 24,84 %, e o maior índice Kappa de 0,6, apontando um erro de 40 %. Para estudos posteriores, sugere-se a adoção de imagens de outro satélite e outras bandas e composições coloridas, para que se possa testar o comportamento espectral dos alvos e distingui-los melhor na coleta das amostras de treinamento e no processamento das classificações.

### Referências bibliográficas

Assad, E. D.; Sano, E. E.; Meirelles, M. L.; Moreira, L. Estruturação de dados geoambientais no contexto de microbacia hidrográfica. In: Assad, E. D.; Sano, E. E. (org). **Sistemas de Informações Geográficas: Aplicações na agricultura**. 2.ed. Brasília: Embrapa-SPI/ Embrapa-CPAC, 1998. cap. 7. p. 119-137.

Barbosa, A. P. **Comparação de métodos de classificação de imagens, visando o gerenciamento de áreas citrícolas**. Botucatu, 2009. 65 f. Dissertação (Mestrado em Agronomia/Energia na Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista.

Coutinho, A. C. **Segmentação e classificação de imagens Landsat-TM para o mapeamento dos usos da terra na região de Campinas, SP**. São Paulo, 1997. 147 f. Dissertação (Mestrado em Ciências) – Instituto de Biociências, Universidade de São Paulo.

Crosta, A. P. **Processamento digital de imagens de sensoriamento remoto**. Campinas: IG/UNICAMP, 1993. 170p. (ed. rev.)

Eastman, J. R. **Idrisi Andes: Guide to GIS and Image Processing**. Worcester, MA: Clark University, 2006. 327 p.

Eastman, J. R. **Idrisi Taiga: Guide to GIS and Image Processing**. Worcester, MA: Clark University, 2009. 325 p.

Fitz, P. R. **Geoprocessamento sem complicação**. São Paulo: Oficina de Textos, 2008. 160p.

Moreira, M. A. **Fundamentos de Sensoriamento Remoto e Metodologias de Aplicação**. 1.ed. São José dos Campos: INPE, 2001. 250 p.

Ponzoni, F. J.; Almeida, E. S. A estimativa do parâmetro kappa (k) da análise multivariada discreta no contexto de um SIG. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8, 1996, Salvador. **Anais...** São José dos Campos: INPE, 1996. Artigos, p. 729-733. CD-ROM, On-line. ISBN 85-17-00014-5. Disponível em: <<http://marte.dpi.inpe.br/col/sid.inpe.br/deise/1999/02.05.09.39/doc/T130.pdf>>. Acesso em 07.out.2010.

Ponzoni, F. J.; Rezende, A. C. P. Influência da resolução espacial de imagens orbitais na identificação de elementos da paisagem em Altamira-PA. **Revista Árvore**, Viçosa, v. 26, n. 4, p.403-410, 2002.