

AValiação da EXatidão do Mapeamento da Cobertura da Terra em CAPIXABA, ACRE, UTILIZANDO CLASSIFICAÇÃO POR ÁRVORE DE DECISÃO

Symone Maria de Melo Figueiredo¹, Luis Marcelo Tavares de Carvalho²

(recebido: 16 de março de 2005; aceito: 16 de novembro de 2005)

RESUMO: Objetivou-se com este estudo avaliar a exatidão do mapeamento da cobertura da terra em Capixaba, Estado do Acre, por meio da classificação digital de imagens por meio do algoritmo árvore de decisão. Foram usados na construção e no uso da árvore de decisão onze atributos: dados provenientes das bandas 1, 2, 3, 4, 5 e 7 do sensor TM do satélite Landsat 5; imagens fração solo, sombra, vegetação e de erro, geradas pelo modelo linear de mistura espectral, e índice de vegetação por diferença normalizada (NDVI). O resultado do mapeamento foi considerado excelente segundo os conceitos estabelecidos por Landis & Koch (1977), com valores do coeficiente de concordância Kappa acima de 0,83, demonstrando ser uma técnica promissora no mapeamento de classes de cobertura da terra.

Palavras-chave: Classificação digital de imagens, mineração de dados, modelo linear de mistura espectral, NDVI.

EVALUATION OF DECISION TREE CLASSIFICATION ACCURACY TO MAP LAND COVER IN CAPIXABA, ACRE

ABSTRACT: This study evaluated the accuracy of mapping land cover in Capixaba, state of Acre, Brazil, using decision trees. Eleven attributes were used to build the decision trees: TM Landsat data from bands 1, 2, 3, 4, 5, and 7; fraction images derived from linear spectral unmixing; and the normalized difference vegetation index (NDVI). The Kappa values were greater than 0,83, producing excellent classification results and demonstrating that the technique is promising for mapping land cover in the study area.

Key words: digital image classification, data mining, linear spectral unmixing, NDVI.

1 INTRODUÇÃO

Durante as últimas décadas, com a intensificação do desmatamento na Amazônia, aumentou a preocupação das instituições brasileiras e internacionais, pesquisadores, organizações não-governamentais e da sociedade em geral, com o ritmo acelerado desse processo. Várias experiências e políticas públicas têm sido aplicadas para reverter este cenário, entre elas, as que objetivam o monitoramento ambiental da cobertura florestal e utilizam a aplicação de técnicas de classificação digital de imagens de sensoriamento remoto no mapeamento da cobertura da terra.

Os métodos tradicionais de reconhecimento de padrões para a classificação digital de imagens de sensoriamento remoto baseavam-se exclusivamente nas técnicas estatísticas convencionais, como os procedimentos de máxima verossimilhança e distância mínima, além de outros. Esses métodos, geralmente, possuem habilidade limitada de resolver confusões entre classes, principalmente aquelas que possuem alguma similaridade espectral e por vezes não são

evidentes as suas diferenças radiométricas.

Recentemente, avanços nas técnicas computacionais propõem estratégias alternativas na classificação de imagens digitais, conhecidas como *data mining*, ou mineração de dados, cuja principal característica é a extração de informações previamente desconhecidas e de máxima abrangência a partir de grandes bases de dados, usando-as para efetuar decisões. A mineração de dados por árvore de decisão, apesar de ser uma técnica relativamente nova, é relatada como promissora na análise de dados de sensoriamento remoto e o interesse pelo uso de métodos de construção e uso de árvores de decisão tem crescido nos últimos anos (CARVALHO et al., 2004; TSO & MATHER, 2001).

A árvore de decisão utiliza mecanismos de categorização usando divisão hierárquica dos dados, em que um padrão desconhecido é rotulado usando-se uma seqüência de decisões. Na aplicação em dados multiespectrais, o desenho da árvore de decisão é baseado no conhecimento das propriedades espectrais de cada classe e na relação entre as classes (TSO & MATHER, 2001).

¹ Engenheira Agrônoma, Msc., Secretaria de Estado de Meio Ambiente e Recursos Naturais, Acre – Rua Barbosa, 450 – Rio Branco, AC – symone@mdnet.com.br

² Professor do Departamento de Ciências Florestais da Universidade Federal de Lavras/UFLA – Cx. P. 3037 – 37200-000 – Lavras, MG – passarinho@ufla.br

A árvore de decisão é composta de um conjunto de nós, conforme ilustra a Figura 1. O nó inicial, denominado raiz, e os nós interiores são representados por estágios de decisão, enquanto o nó terminal, chamado folha, representa a classificação final. O processo de classificação é implementado por um conjunto de regras que determina o caminho a ser seguido, iniciando no nó raiz e finalizando em um nó folha que representa a classe temática da classificação. Em cada nó não-terminal, a decisão deve ser feita sobre o caminho para o próximo nó.

A utilização de árvores de decisão binárias para classificação pode ser considerada uma abordagem não-paramétrica para reconhecimento de padrões (QUILAN, 1986). A seleção da estrutura da árvore, de apropriados subconjuntos de feições em cada nó terminal e das regras de decisão, reflete no desempenho (acurácia da classificação) e na eficiência (tempo computacional usado na classificação) do classificador (SWAIN & HAUSKA, 1977; TSO & MATHER, 2001). As principais vantagens dos algoritmos baseados em árvores de decisão são sua eficiência computacional e sua simplicidade (AURÉLIO et al., 1999).

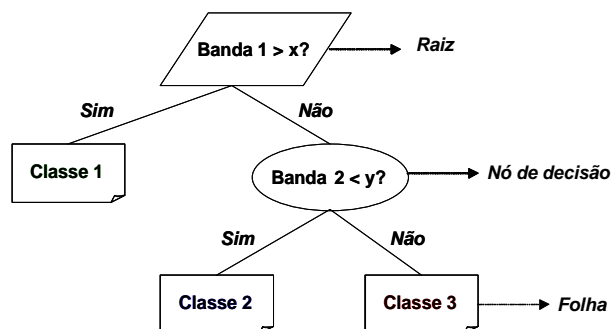


Figura 1 – Representação de uma árvore de decisão binária.
Figure 1 – Binary decision tree.

Objetivou-se com este estudo avaliar a exatidão do mapeamento da cobertura da terra em Capixaba, Estado do Acre, por meio da classificação digital de imagens de sensoriamento remoto, utilizando o algoritmo árvore de decisão.

2 MATERIAL E MÉTODOS

2.1 Área de estudo

A área de estudo está localizada no sudeste do estado do Acre, situada em torno de 10°11'52" de latitude sul e 68°04'30" de longitude oeste (Figura 2) e corresponde ao município de Capixaba, com superfície territorial de 1.713 km², equivalendo a 1,1% da área total do estado (IBGE, 2004).




Figura 2 – Localização do município de Capixaba, estado do Acre.

Figure 2 – Municipality of Capixaba, Acre, localization.

O clima é do tipo equatorial quente e úmido, caracterizado por altas temperaturas, elevados índices de precipitação pluviométrica e alta umidade relativa do ar. Os solos predominantes são argissolos com horizonte B textural e baixa atividade da argila, muito deles com alta saturação de alumínio, bem drenados e com relevo plano a suave ondulado. A vegetação predominante é floresta ombrófila aberta de palmeiras com fasciações de floresta ombrófila densa (ACRE, 2000).

2.2 Fonte de dados

Para a realização desse estudo, as fontes de dados foram as imagens multiespectrais do sensor Thematic Mapper (TM) do satélite Landsat 5, disponibilizadas nas bandas 1 (0,45–0,52 μm), 2 (0,53–0,61 μm), 3 (0,63–0,69 μm), 4 (0,76–0,90 μm), 5 (1,55–1,75 μm) e 7 (2,08–2,35 μm), referente ao ano de 2003, e as imagens derivadas de técnicas de extração de informações, como imagens-fração geradas pela aplicação do modelo linear de mistura espectral e índice de vegetação por diferença normalizada (NDVI). Foram utilizados aplicativos de mineração de dados e de processamento de imagens para a construção da árvore de decisão e geração do mapa temático.

2.3 Classes temáticas de mapeamento da cobertura da terra

Para o mapeamento da cobertura da terra foram definidas sete classes temáticas, cujas principais características são:

- Floresta: compreende o domínio da floresta ombrófila aberta, com palmeiras, cipós ou bambus, dependendo das feições fitoecológicas de floresta densa ou de floresta aberta, em função das características das formas de relevo (ACRE, 2000).
- Capoeira: caracterizada pela ocorrência de vegetação em vários estágios de sucessão secundária, plantios florestais com seringueira (*Hevea brasiliensis* Muel. Arg.) ou mistos com várias espécies florestais e sistemas agroflorestais com consórcio de culturas perenes e espécies florestais e frutíferas. O agrupamento das subclasses (estágios de sucessão secundária, plantios florestais e agroflorestais) ocorreu devido à heterogeneidade da estrutura da vegetação e à limitação da resolução espacial dos sensores remotos.

- Pasto alto: nesta classe foram agrupadas as áreas de pasto limpo com gramíneas exóticas de porte alto e textura mais homogênea, os pastos degradados ou pastos sujos, e os plantios agrícolas.

- Pasto baixo: encontrado nas grandes fazendas de pecuária bovina, formado principalmente pelas gramíneas *Brachiaria brizantha*, *Brachiaria decumbens* e *Panicum maximum*. A pressão de pastejo maior que a capacidade de produção forrageira, principalmente na época da seca, confere o porte mais baixo ao pasto neste período.

- Solo: representa a pequena área do perímetro urbano de Capixaba, composta de áreas construídas de uso residencial, comercial, industrial e público, e ainda as edificações nas propriedades rurais, a usina de produção de álcool no projeto de assentamento Alcoobrás, as estradas e ramais com ou sem pavimentação asfáltica.

- Água: representa os corpos d'água da área de estudo, composta pelo leito dos rios, vários igarapés permanentes e temporários e açudes das propriedades rurais.

2.4 Técnicas de processamento de imagens digitais

A imagem Landsat de 2003 foi processada de acordo com as seguintes etapas:

- Correção geométrica: para o georreferenciamento da imagem foram usados 17 pontos de controle no terreno coletados com GPS e alocados na imagem por suas coordenadas na projeção cartográfica Universal Transverse Mercator ou UTM, datum SAD 69/Brasil. O método de transformação usado foi polinomial de 1º grau e o de reamostragem dos *pixels* a técnica de alocação do vizinho mais próximo (*nearest neighbour*).

- Conversão radiométrica: Consiste na transformação dos valores digitais brutos (número digital – DN) das imagens Landsat para reflectância aparente, com o objetivo exclusivo de viabilizar a aplicação do modelo linear de mistura espectral. A reflectância aparente foi calculada utilizando-se as relações propostas por Markham & Barker (1987), em que inicialmente, convertem-se os números digitais em valores de radiância e depois para valores de reflectância aparente, usando as seguintes equações:

$$L(\lambda) = L_{\min\lambda} + \frac{(L_{\max\lambda} - L_{\min\lambda})}{\text{QCAL}_{\max\lambda}} \text{QCAL} \quad \text{e}$$

$$\rho_p = \frac{\pi L_\lambda d^2}{E_{\text{sol}\lambda} \cos\theta_s}$$

em que:

$L(\lambda)$ = radiância espectral, em $\text{mW cm}^{-2} \text{sr}^{-1} \mu\text{m}^{-1}$;

$L_{\min\lambda}$ = radiância espectral equivalente ao número digital mínimo;

$L_{\max\lambda}$ = radiância espectral equivalente ao número digital máximo;

$\text{QCAL}_{\max\lambda}$ = amplitude de variação dos números digitais, equivalente a 255 para todos os dados TM e ETM+ ;
 QCAL = número digital.

ρ_p = reflectância aparente, adimensional;

L_λ = radiância espectral ($\text{mW cm}^{-2} \text{sr}^{-1} \mu\text{m}^{-1}$);

d = distância Terra-Sol em unidades astronômicas;

$E_{\text{sol}\lambda}$ = irradiância solar exoatmosférica média ($\text{mW cm}^{-2} \mu\text{m}^{-1}$); e

θ_s = ângulo zenital solar, em graus.

Os valores de $L_{\min\lambda}$, $L_{\max\lambda}$ e $E_{\text{sol}\lambda}$ utilizados na conversão radiométrica do Landsat 5 estão relacionados na Tabela 1. Os valores de θ_s e d foram obtidos a partir dos dados dos arquivos, em formato

texto, que acompanham as imagens.

• Extração de informações: as imagens TM do Landsat 5 foram utilizadas na geração de imagens fração ou sintéticas oriundas da análise de mistura espectral e do índice de vegetação por diferença normalizada (NDVI). As imagens geradas foram posteriormente utilizadas na fase de classificação digital como informação adicional à fonte de dados, tendo em vista que não há limitação no número de atributos no uso da árvore de decisão.

A mistura espectral consiste na integração da energia espectral refletida ou emitida por todos os objetos, denominados componentes da mistura, contidos no pixel, devido à variação e à proximidade dos alvos na superfície da terra (AGUIAR, 1991; LILLESAND & KIEFER, 2000). A hipótese básica é que a variação espectral numa imagem é causada por misturas de um número limitado de materiais na superfície e a sua análise envolve técnicas em que as respostas espectrais misturadas são comparadas com um conjunto de referência espectral “pura”. O resultado é uma estimativa de proporções aproximadas das áreas em cada pixel que são ocupadas pelas classes de referência.

Tabela 1 – Valores de $L_{\min\lambda}$ e $L_{\max\lambda}$ em $\text{W}/(\text{m}^2.\text{sr}.\mu\text{m})$ utilizados na calibração radiométrica da imagem TM do Landsat 5.

Table 1 – Values of $L_{\min\lambda}$ and $L_{\max\lambda}$ in $\text{W}/(\text{m}^2.\text{sr}.\mu\text{m})$ used for radiometric calibration of Landsat TM.

Sensor	TM / Landsat 5	
Data do processamento	Depois de 05/03/2003	
Banda	Lmin	Lmax
1	-1,52	193,00
2	-2,84	365,00
3	-1,17	264,00
4	-1,51	221,00
5	-0,37	30,20
7	-0,15	16,50

Fonte: Chander & Markham (2003).

Os componentes puros selecionados foram solo, sombra e vegetação, amplamente utilizados no mapeamento da cobertura da terra na Amazônia (DUARTE et al., 2003; ESCADA, 2003; LU et al., 2003; SHIMABUKURO et al., 1999). Para a seleção das amostras dos componentes puros ou *endmembers* foi utilizada a teoria do simplex (AGUIAR, 1991; BAJJOUK et al., 1998), em que os componentes puros localizam-se nos vértices do triângulo formado no espaço de feições bidimensional, representando a distribuição dos *pixels* nas bandas 3 e 4, correspondente ao comprimento de onda do vermelho e infravermelho próximo.

Depois de selecionados os componentes puros, foi realizada a decomposição espectral linear, cuja formulação matemática pode ser expressa por

$$R_i = \sum_{k=1}^n f_k R_{ik} + \varepsilon_i \quad (\text{LU et al., 2003})$$

em que:

$i = 1, \dots, m$ (número de bandas espectrais);

$k = 1, \dots, n$ (número de componentes puros ou *endmembers*);

R_i = reflectância espectral na banda i de um *pixel*, contendo um ou mais *endmembers*;

f_k = proporção do *endmember* k dentro de um *pixel*;

R_{ik} = reflectância espectral do *endmember* k dentro do *pixel* na banda i ; ε_i ,

ε_i = erro da banda i .

Por ser tratar de proporções de área de um *pixel*, o modelo linear de mistura espectral é submetido

às seguintes restrições: $\sum_{k=1}^n f_k = 1$ e $0 \leq f_k \leq 1$.

O NDVI foi usado para transformar os dados multiespectrais do sensor TM em uma imagem com única banda representando a distribuição da vegetação. Os valores do NDVI indicam a quantidade de vegetação verde presente no *pixel*, ou seja, quanto maior o valor do NDVI, mais vegetação verde possui o *pixel*. O NDVI foi gerado por meio do seguinte algoritmo padrão

$$\text{NDVI} = (\text{NIR} - \text{R}) / (\text{NIR} + \text{R})$$

em que:

NIR = valor do *pixel* na faixa do espectro eletromagnético correspondente à região do infravermelho próximo (0,7 a 0,9 μm);

R = valor do *pixel* na faixa do espectro eletromagnético correspondente a região do vermelho (0,6 a 0,7 μm).

• Classificação digital: na classificação pelo algoritmo de árvore de decisão foi utilizado um aplicativo de mineração de dados, para geração do conjunto de regras da árvore de decisão e, posteriormente, um aplicativo de processamento de imagens para a classificação digital.

Os atributos usados nesta técnica de classificação foram: bandas 1, 2, 3, 4, 5 e 7 do Landsat 5 com valores em número digital; imagens fração solo, sombra, vegetação e de erro geradas pelo modelo linear de mistura espectral e índice de vegetação NDVI. Essas onze variáveis foram organizadas em um único arquivo de imagem.

Foram utilizadas amostras de treinamento e amostras de teste na construção da árvore de decisão. Cada *pixel* das amostras e seus respectivos valores nas onze imagens do arquivo de dados constituem um caso a ser analisado pelo algoritmo de aprendizado de máquina. Na preparação dos dados necessários para a implementação da mineração de dados, foram organizados três arquivos, denominados arquivo de nomes, arquivo de dados e arquivo de teste.

O arquivo de nomes contém o nome das classes temáticas, dos atributos e valores dos atributos. O arquivo de dados descreve os casos ou amostras de treinamento, em que cada *pixel* da amostra foi especificado pelos seus respectivos valores para todos os atributos (imagens usadas) e a classe temática do caso. O arquivo de teste, no mesmo formato do arquivo de dados, foi utilizado para avaliar o erro da árvore de decisão produzida pela mineração de dados.

Por último, foi aplicado a técnica convencional de classificação digital por meio do algoritmo de máxima verossimilhança e do algoritmo isodata, a fim de verificar seu desempenho em relação ao algoritmo árvore de decisão.

2.5 Exatidão do mapeamento

Um método comum para avaliação da acurácia do resultado da classificação digital de imagens de sensoriamento remoto é o uso da matriz de erro e das estatísticas derivadas, o que permite o cálculo da exatidão global, exatidão por classe de mapeamento

e do coeficiente de concordância Kappa (LU et al., 2003; SKIDMORE, 1999).

Para a estimativa do coeficiente Kappa empregam-se as seguintes equações:

$$K = \frac{P_o - P_c}{1 - P_c},$$

$$P_o = \frac{\sum_{i=1}^M n_{ij}}{N}, \text{ e}$$

$$P_c = \frac{\sum_{i=1}^M n_{i+} n_{+i}}{N^2},$$

sendo:

P_o = exatidão global;

P_c = proporção de unidades que concordam por casualidade;

M = número de classes presentes na matriz de erro;

n_{ij} = número de observações na linha i e coluna j ;

n_{i+} e n_{+i} = totais marginais da linha i e da coluna j , respectivamente; e

N = número total de unidades amostrais contempladas pela matriz.

O valor do coeficiente de Kappa (K) varia entre 0 e 1, em que o valor 1 representa uma completa concordância entre a imagem classificada com o dado de referência. O valor K pode ser comparado como os valores e conceitos contidos na Tabela 2, desenvolvidos por Landis & Koch (1977) e, dessa forma, avaliar o mapa temático obtido da classificação da imagem.

Tabela 2 – Conceitos do coeficiente de concordância Kappa.

Table 2 – *Qualitative classification of Kappa agreement coefficient.*

Valor de K	Qualidade da classificação
<0,0	Péssima
0,0 - 0,2	Ruim
0,2 - 0,4	Razoável
0,4 - 0,6	Boa
0,6 - 0,8	Muito boa
0,8 - 1,0	Excelente

Fonte: Adaptada de Landis & Koch (1977).

Dessa forma, para quantificar os erros gerados de um mapa temático, atribuindo-se aos *pixels* selecionados a classe temática correspondente, com base em dados obtidos em campo com auxílio de GPS. Para a construção da matriz de erro, foram selecionadas as amostras de validação numa imagem de referência estratificada por classes temáticas. A estratificação e conseqüente produção do mapa temático de referência foram feitas utilizando um algoritmo de análise de agrupamento e migração, conforme procedimento utilizado por Oliveira (2004).

3 RESULTADOS E DISCUSSÃO

O mapeamento da cobertura da terra em Capixaba por meio da classificação pelo algoritmo árvore de decisão gerou as estimativas do percentual de área de cada uma das classes temáticas, conforme demonstra a Figura 3.

A cobertura florestal representa 57,94% da área total do município, além do percentual ocupado pela classe capoeira, ou seja, por vegetação secundária e plantios florestais que totalizam outros 10,56%. As pastagens nas propriedades rurais e projetos de assentamento somam 29,05% da área de Capixaba, aproximadamente 50 mil hectares.

Nas Figuras 4 e 5, ilustram-se a imagem do município de Capixaba e o mapa temático do ano de 2003, respectivamente.

As classes de floresta e água apresentaram os melhores desempenhos na classificação, com erros de inclusão ou omissão inferiores a 10%, demonstrando a eficiência do algoritmo árvore de decisão no mapeamento dessas classes temáticas.

Em áreas de capoeira os erros de classificação foram devido a confusão causada com as classes de pasto alto e floresta. Constatou-se que a classe de pasto alto, que incluiu a subclasse de pasto sujo, causou confusão com capoeira em estágios iniciais de sucessão secundária. Isso ocorreu devido à presença de espécies herbáceas e arbustivas nos pastos sujos, iniciando a regeneração da vegetação. Por outro lado, capoeira em estágios avançados de sucessão secundária, apresentam resposta espectral muito semelhante ao das florestas maduras, tornando uma tarefa difícil a separação entre elas.




Figura 3 – Percentual da área do município de Capixaba, Acre, coberta pelas classes mapeadas pelo algoritmo árvore de decisão em 2003.

Figure 3 – Percentage of the municipality of Capixaba, Acre, covered by the land classes mapped using decision trees, in 2003.



Figura 4 – Imagem Landsat de Capixaba, 2003, indicando a área do mapa temático ilustrados na Figura 5.

Figure 4 – Landsat imagery of Capixaba, 2003, indicating the mapped area of Figure 5.

Apesar disso os maiores erros de classificação obtidos pelo algoritmo árvore de decisão foram verificados nas classes de pasto alto (18,18%), pasto baixo (17,65%) e capoeira (16,87%).

Os erros causados entre as classes pasto alto e pasto baixo se deu em função da subclasse pasto limpo com a classe de pasto baixo. Na classe de pasto baixo, a pressão de pastejo e manejo do rebanho pode conferir uma rala cobertura de solo pelas gramíneas,

principalmente na época mais seca. Essa situação proporcionou confusão da classe de pasto baixo com a de solo. No entanto, a exatidão da classe de solo foi satisfatória, com acurácia do produtor de omissão de 84,62%.

A exatidão global obtida pelo classificador árvore de decisão e os erros de inclusão e omissão por classe de mapeamento em 2003, estão citados na Tabela 3.

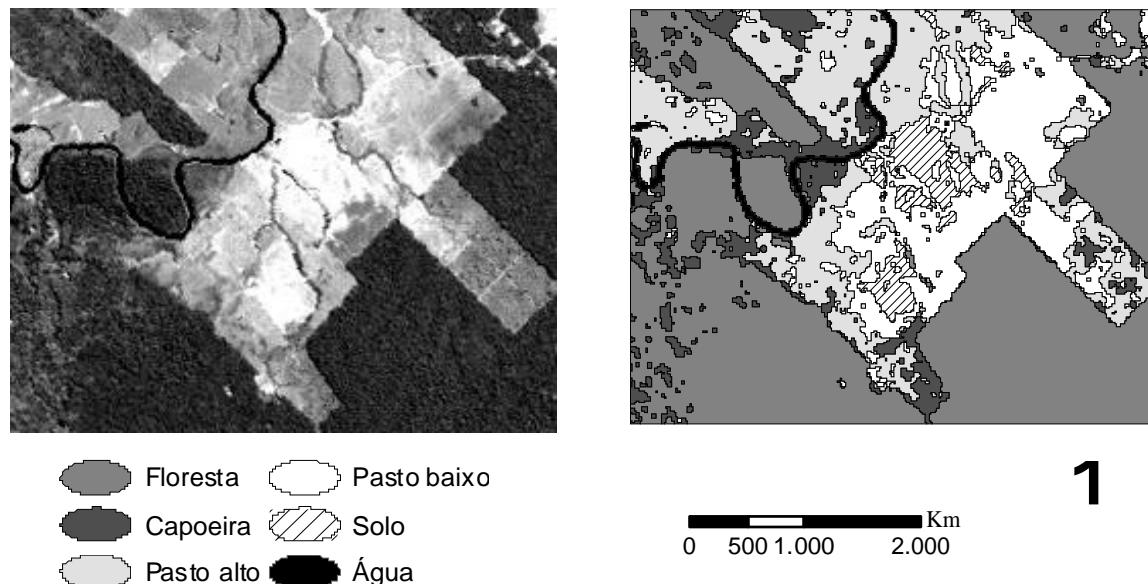


Figura 5 – Imagem Landsat de 2003 (a) e mapa de cobertura da terra de 2003 (b).

Figure 5 – Landsat imagery from 2003 (a) and the thematic maps of 2003 (b).

Tabela 3 – Matriz de erro do mapa produzido com o classificador de árvore de decisão aplicado à imagem de 2003.

Table 3 – Error matrix of the map produced with the decision tree classifier applied to the images from 2003.

Classificação	Amostras de validação (pixels)						Total	Inclusão	
	CA	FL	SO	AG	PA	PB			
Capoeira (CA)	69	1	0	0	5	0	75	8,0%	
Floresta (FL)	11	194	0	0	0	0	205	5,4%	
Solo (SO)	0	0	44	0	0	1	45	2,2%	
Água (AG)	0	0	0	77	0	0	77	0,0%	
Pasto alto (PA)	3	0	0	0	90	17	110	18,2%	
Pasto baixo (PB)	0	0	8	0	0	84	92	8,7%	
Total	83	195	52	77	95	102	604		
Omissão	16,9%	0,5%	15,4%	0,0%	5,3%	17,6%			
Exatidão global = 92,38%		Kappa = 0,9044							

O mapeamento da cobertura da terra em Capixaba foi considerado excelente, com valor de Kappa acima de 0,90, conforme conceitos estabelecidos por Landis & Koch (1977). Esse desempenho foi similar ao obtido pelo algoritmo de

máxima verossimilhança (Kappa = 0,89) e superior ao obtido pelo método de classificação digital não supervisionada isodata que alcançou valor de Kappa de 0,79, em ambos os casos utilizando-se as imagens multiespectrais do Landsat 5 (em número digital).

4 CONCLUSÕES

A classificação digital de imagens de sensoriamento remoto por meio do algoritmo árvore de decisão demonstrou ser eficiente para o mapeamento da cobertura da terra, principalmente para as classes de floresta e água com exatidão superior a 94%.

As classes que possuem subclasses com vegetação em estágios iniciais de sucessão secundária demonstraram ser mais difícil a separação entre elas pelo classificador, ocasionada pela sua semelhança espectral. Contudo, apesar dos erros de classificação verificados nessas classes, a avaliação do mapeamento da cobertura da terra pelo classificador árvore de decisão foi excelente, de acordo com os conceitos estabelecidos por Landis & Koch (1977), demonstrando que a técnica é adequada para essa finalidade.

5 REFERÊNCIAS BIBLIOGRÁFICAS

- ACRE. Governo do Estado do Acre. Programa Estadual de Zoneamento Ecológico-Econômico do Estado do Acre. **Zoneamento ecológico-econômico: recursos naturais e meio ambiente: documento final.** Rio Branco: SECTMA, 2000. v. 1, 116 p.
- AGUIAR, A. P. D. **Utilização de atributos derivados de proporções de classes dentro de um elemento de resolução de imagem (“pixel”) na classificação multiespectral de imagens de sensoriamento remoto.** 1991. 227 f. Dissertação (Mestrado em Sensoriamento Remoto e Aplicações) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1991.
- AURÉLIO, M.; VELLASCO, M.; LOPES, C. H. **Descoberta de conhecimento e mineração de dados.** Rio de Janeiro: PUC-Rio, 1999. 102 p. Apostila.
- BAJJOUK, T.; POPULUS, J.; GUILLAUMONT, B. Quantification of subpixel cover fractions using principal component analysis and a linear programming method: application to the Coastal Zone of Roscoff (France). **Remote Sensing of Environmental**, New York, v. 64, p. 153-165, 1998.
- CARVALHO, L. M. T. de et al. Selection of imagery data and classifiers for mapping brazilian semideciduos atlantic forests. **International Journal of Applied Earth Observation and Geoinformation**, Enschede, n. 5, p. 173-186, 2004.
- CHANDER, G.; MARKHAM, B. **Revised Landsat 5 TM radiometric calibration procedures and post-calibration dynamic ranges.** [S.l.]: USGS, [2003?]. Disponível em: <<http://landsat.usgs.gov/documents/L5TMCAL2003.pdf>>. Acesso em: 11 out. 2004.
- DUARTE, V.; SHIMABUKURO, Y. E.; AUCILINO, L. C. M. Metodologia para atualizar e padronizar o banco de dados do projeto “PRODES digital”. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003, Belo Horizonte. **Anais...** Belo Horizonte: SBSR/INPE, 2003. p. 2705-2712.
- ESCADA, M. I. S. **Evolução de padrões da terra na região centro-norte de Rondônia.** 2003. 264 f. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2003.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Cidades@.** Rio de Janeiro, 2004. Disponível em: <<http://www.ibge.gov.br/cidadesats>>. Acesso em: 5 set. 2004.
- LANDIS, J.; KOCH, G. G. The measurements of agreement for categorical data. **Biometrics**, Washington, v. 33, n. 3, p. 159-179, Mar. 1977.
- LILLESAND, T. M.; KIEFER, R. W. **Remote sensing and image interpretation.** 4. ed. New York: J. Wiley & Sons, 2000. 724 p.
- LU, D.; MORAN, E.; BATISTELLA, M. Linear mixture model applied to Amazonian vegetation classification. **Remote Sensing of Environment**, New York, v. 87, p. 456-469, 2003.
- MARKHAM, B. L.; BARKER, J. L. Radiometric properties of U.S. processes Landsat MSS data. **Remote Sensing of Environment**, New York, v. 17, p. 39-71, 1987.
- OLIVEIRA, L. T. **Fusão de imagens de sensoriamento remoto e mineração de dados geográficos para mapear as fitofisionomias no bioma cerrado.** 2004. 131 p. Dissertação (Mestrado em Engenharia Florestal) - Universidade Federal de Lavras, Lavras, 2004.

QUILAN, J. R. Induction of decision trees. **Machine Learning**, Dordrecht, v. 1, p. 81-106, 1986.

SKIDMORE, A. K. Accuracy assessment of spatial information. In: STEIN, A.; MEER, F. van der; GORTE, B. (Eds.). **Spatial statistics for remote sensing**. Dordrecht: Kluwer, 1999. p. 197-209.

SWAIN, P. H.; HAUSKA, H. The decision tree classifier: design and potential. **IEEE Transactions on**

geoscience electronics, New York, v. 15, n. 3, p. 142-147, July 1977.

SHIMABUKURO, Y. E. et al. Levantamento de áreas desflorestadas na Amazônia através de processamento digital de imagens orbitais. **Floresta e Ambiente**, Seropedica, v. 6, n. 1, p. 38-44, jan./dez. 1999.

TSO, B.; MATHER, P. M. **Classification methods for remotely sensed data**. London: Taylor & Francis, 2001. 332 p.