

Uso de classificadores para o mapeamento da vegetação nativa de cerrado

Étore Francisco Reynaldo¹
Fabrício Pinheiro Povh¹
Luciano Marcelo Fallé Saboya²
Marina de Fátima Vilela³

¹ Universidade de São Paulo - USP/ESALQ
Caixa Postal 96 - 13416-000 - Piracicaba - SP, Brasil
etfreynaldo@yahoo.com.br
fppovh@gmail.com

² Fundação Universidade Federal do Tocantins – UFT
Caixa Postal 66 – CEP: 77410-000 – Gurupi – TO, Brasil
saboya@uft.edu.br

³ Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA - Cerrados
Caixa Postal: 08223 - CEP: 73310-970 – BR 020 km 18 - Planaltina – DF, Brasil
marina@cpac.embrapa.br

Use of classifiers for mapping savannah native vegetation

Abstract. The environment is in constant change, and for a better comprehension of these changes it is necessary observations with an amplitude of temporal and spatial scales. The use of geoprocessing and remote sensing techniques to identify the modifications promoted by human race in the environment are becoming more frequent, highlighting the monitoring of deforestation and illegal burning. In this work the objective was to realize the mapping of savannah native vegetation using an image CCD/CBERS-2 and the classification methods visual, supervised and non supervised. The work was realized in the municipal district of Gurupi, TO, coordinates 11° 44' 47" S and 49° 04' 15" W. The delimitation of the area was defined by the map SC-22-Z-D-IV-4-NE from the Brazilian Institute of Geography and Statistics (IBGE), scale of 1:25.000, with a total area of 19,093.19 ha. After the image registration it was obtained a mean error of 0.48 pixel or 9.6 m. After the classification using the different methods it is possible to say that for local conditions, the visual and supervised classifications were the most indicated, mapping an area of 6,112.19 and 4,173.40 ha, respectively. The non supervised classification mapped an area of 6,646.00 ha. The exactitude indices were considered excellent for visual and supervised classification. The previous knowledge about the area was indispensable to the results of the visual and supervised classifications. A non supervised classification with a reduced number of classes could reduce the excess of similar classes and increase the exactitude indices for the classification, according to local conditions.

Palavras-chave: remote sensing, image processing, environmental preservation, sensoriamento remoto, processamento de imagens, preservação ambiental.

1 Introdução

Os recursos naturais e o meio ambiente da Terra estão em constantes mudanças, as quais se têm intensificado a partir de meados do século XX. Para compreender melhor estas mudanças são necessárias observações numa amplitude de escalas temporais e espaciais.

Nas últimas décadas, com o advento do sensoriamento remoto orbital, tornou-se possível o monitoramento da evolução espacial e temporal das mudanças na cobertura da superfície terrestre. Valendo-se de sensores multiespectrais, fenômenos como queimadas, desmatamentos, expansão urbana e mudanças na cobertura vegetal, passaram a ser estudados de forma objetiva.

Segundo Novo (1989) as principais vantagens que justificam os programas de sensoriamento remoto orbital são as seguintes: Estímulo às pesquisas multidisciplinares; informações de áreas de difíceis acessos; universalização dos dados e das técnicas de tratamento e análise de dados digitais; facilidade do recobrimento de grandes áreas (visão sinóptica); cobertura repetitiva com mesma hora local; grande quantidade de dados pontuais, sobre uma mesma área; transferência de dados Satélite/Terra em tempo real; e o aspecto multiespectral, isto é, a capacidade dos sistemas sensores gerarem produtos em diferentes faixas espectrais, tornando possível o estudo e análise de diferentes elementos, os quais são identificados em determinadas faixas do espectro.

Através de softwares dedicados exclusivamente ao tratamento de imagens (Spring 4.1, ENVI 4.0 e IDRISI), podem-se gerar imagens com diferentes composições de cores, ampliações de partes das imagens e classificações de objetos nelas identificados, obtendo-se assim, produtos como mapas temáticos utilizados em estudos de geologia, vegetação, uso do solo, relevo, agricultura, rede de drenagem, inundações, entre outros.

A utilização de técnicas de geoprocessamento e sensoriamento remoto, para identificar as modificações promovidas pelo homem no meio ambiente, são cada vez mais freqüentes, destacando-se os estudos e o monitoramento dos desmatamentos e das queimadas ilegais, os ditos vilões da devastação ambiental.

Santos *et al.*, (1993) comenta que o uso de imagens de satélite como base cartográfica é muito promissor, devido ao relativo baixo custo, fácil aquisição, periodicidade de aquisição e fornecimento de importantes informações sobre mudanças no uso da terra.

As grandes extensões de terras e florestas, a falta de recursos humanos e financeiros tem dificultado e promovido a subeficiência da atuação dos órgãos de fiscalização ambiental.

Uma possível solução para estes problemas seria o emprego de técnicas de sensoriamento remoto e geoprocessamento. Os dados obtidos a partir de satélites propiciam coberturas repetitivas da superfície terrestre em intervalos relativamente curtos, possibilitando uma visão sinóptica e temporal da superfície terrestre e viabilizando ações de monitoramento, identificação e quantificação de áreas com maior rapidez e custo operacional relativamente baixo.

Diante das inúmeras vantagens dos sensores remotos e das técnicas de geoprocessamento na discriminação de feições, aliando qualidade técnica e recursos financeiros, objetivou-se mapear áreas de vegetação nativa do cerrado utilizando imagem CCD/CBERS-2, e os métodos de classificação visual, classificação supervisionada, e classificação não supervisionada.

2 Materiais e métodos

A área de estudo esta localizada no município de Gurupi, localizado a 250 km da capital Palmas na região Sul do Estado do Tocantins, nas coordenadas Lat. 11° 44' 47,11" Sul e Log. 49° 04' 15,16" Oeste.

A área de estudo foi definida pelo recorte da folha SC-22-Z-D-IV-4-NE do Instituto Brasileiro de Geografia e Estatística (IBGE), escala de 1: 25.000. Contendo uma área total de 19.093,19 ha., e um perímetro de 55.272,74 m.

Os dados utilizados no estudo foram obtidos de imagem CCD/CBERS-2, órbita 159, ponto número 113, adquirida em dia 30 de Março de 2004.

Com a ajuda de um receptor GPS foram adquiridas as coordenadas de 55 pontos de controle, posteriormente as imagens foram corrigidas geometricamente, através do procedimento de registro (georreferenciamento) disponível no software Spring 4.1. Foram utilizados 23 Pcts de um total de 55 Pcts coletados.

Utilizou-se uma divisão simples de duas classes, denominadas Vegetação Nativa e Outros:

Vegetação Nativa - compreendem as principais fitofisionomias do bioma Cerrado - Campo Limpo (CL) e Campo Sujo (CS) (estrato herbáceo-arbustivo); Campo Cerrado (CC) e Cerrado sensu stricto (CSS) (estrato arborescente); e Mata de Galeria (MG) (estrato arbóreo).

Outros - Compreendem as Pastagens; Solos Descobertos; Lagos/Represas; Estradas; Rodovias; Construções e demais alvos que não se enquadravam no objetivo da pesquisa.

2.1 Classificação visual

Primeiramente definiu-se a escala de 1:30.000 para o mapeamento dos fragmentos de vegetação nativa. A escala definida exprime bem os detalhes da imagem a ser classificada.

O segundo passo foi identificação e a digitalização dos fragmentos de vegetação nativa, baseando-se das propriedades de formas; rugosidade, padrão, tonalidade, cor e tamanho, textura e sombra dos alvos terrestres. Os alvos de estudo se apresentaram com formas irregulares, tamanhos variáveis e coloração vermelho escuro a vinho com textura rugosa, os quais se destacavam do restante da imagem graças à composição denominada de falsa cor da composição das bandas 4, 3 e 2.

É importante dizer que neste processo guia-se principalmente pela tonalidade para de distinguir uma classe de outra, o que pode levar há um erro de omissão ou comissão de determinados alvos. Isto é devido ao baixo poder de diferenciação de cores (tonalidades) que os seres humanos possuem.

Com a identificação dos alvos de interesse, os mesmos foram adicionados á classe temática a qual pertenciam.

2.2 Classificação supervisionada

As amostras de treinamento foram obtidas em campo segundo as classes Vegetação Nativa e Outros.

As amostras de treinamentos foram analisadas para detectar e eliminar amostras impuras. Manteve-se o teor de pureza ao redor de 99%, para que o mesmo não prejudicasse a classificação.

As amostras analisadas treinaram o algoritmo de classificação Maxver com um limiar de aceitação de 99%, ou seja, o limiar de aceitação indica a % de "pixels" de uma dada classe que será classificada como pertencente a esta classe.

2.3 Classificação não supervisionada da imagem digital

Os procedimentos de classificação não supervisionada do SPRING requerem uma imagem rotulada. A imagem rotulada é gerada pelo processo de segmentação da imagem. O método de segmentação adotado foi o de crescimento de regiões. Inicialmente, este processo de segmentação rotula cada "pixel" como uma região distinta. Calcula-se um critério de similaridade para cada par de regiões adjacente espacialmente. O critério de similaridade

baseia-se em um teste de hipótese estatístico que testa a média entre as regiões. A seguir, divide-se a imagem em um conjunto de sub-imagens e então se realiza a união entre elas, segundo um limiar de agregação definido (SPRING, Vr. 4.1).

A imagem segmentada mais se adequou aos objetivos apresentou um limite de similaridade da ordem de 5 %. Deve-se informar que o processo de segmentação pode se tornar um processo lento dependendo do limite de similaridade e do tamanho de área adotados. Isto pode ser um fator limitante dependendo do equipamento utilizado.

Após a geração da imagem segmentada, inicia-se o processo de classificação não supervisionado, utilizando-se o classificador Iseog.

O classificador Iseog é um algoritmo que agrupa dados conforme os atributos estatísticos de média e matriz de covariância e área.

2.4 Índices de exatidão das classificações geradas

Através da metodologia proposta por JENSEN (1996), determinou-se um número de 76 amostras referência, considerando-se um percentual de exatidão de 95% e um erro permissível de 5%.

As amostras, ou pontos de referência, constituindo o arquivo de referência ou verdade de campo, foram plotadas na área segundo a estratégia de amostragem aleatória como demonstrado na Figura 1. Estabelecidas às classificações finais e o arquivo de referência, foram geradas matrizes de erros que possibilitaram o cálculo dos índices de Exatidão Global e Kappa.

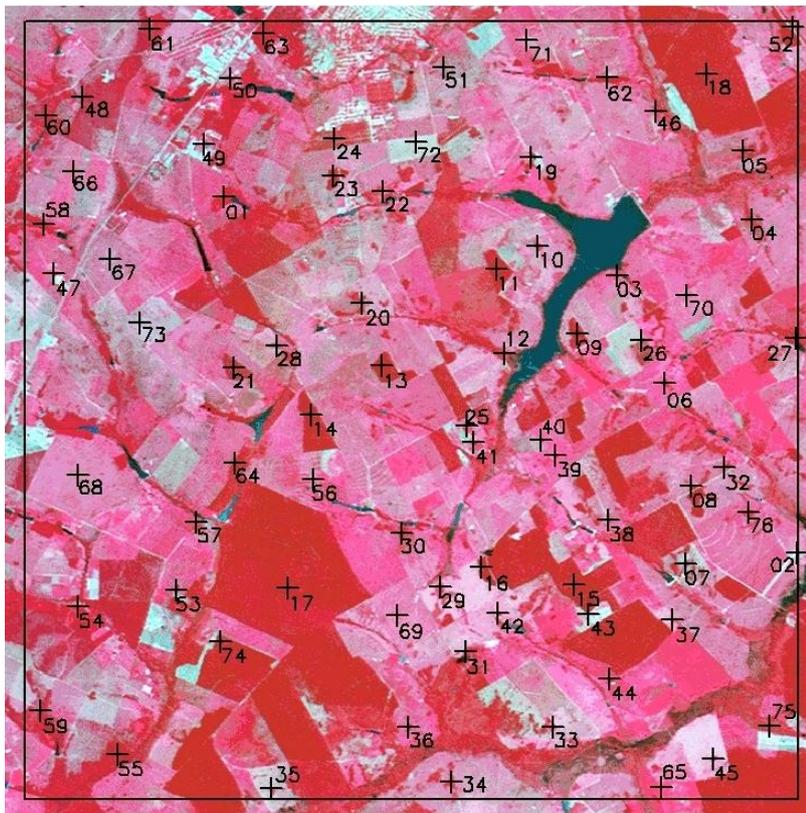


Figura 1: Localização dos pontos de referência distribuídas na área de estudo

3 Resultados e discussão

A imagem corrigida apresentou um erro médio de 0,48 Pixel ou 9,6 metros, cujo valor está dentro daqueles admitidos por Eastman (1994).

As áreas referentes às classes Vegetação Nativa e Outros, mapeados segundo os sistemas classificadores estão representadas na Tabela 1.

Tabela 1: Áreas de Vegetação Nativa e Outros, definidas pelos diversos métodos de classificação digital de imagens digitais, em ha e porcentagem.

Classes Temáticas			C. Visual	C. Superv.	C. Não-superv.
Vegetação Nativa	Área	(ha)	6.646,00	4.173,40	6.112,19
		(%)	34,81	21,86	32,01
Outros	Área	(ha)	12.447,19	14.919,79	12.981,00
		(%)	65,19	78,14	67,99
Total	Área	(ha)	19.093,19	19.093,19	19.093,19
		(%)	100	100	100

Nas Figuras 2, 3 e 4 temos a vegetação nativa mapeada pelos métodos de classificação visual, supervisionada e não supervisionada respectivamente. Sobreposta à imagem sintética do local do trabalho obtida pela composição das bandas 4(R) 3(G) 2(B) da imagem orbital.

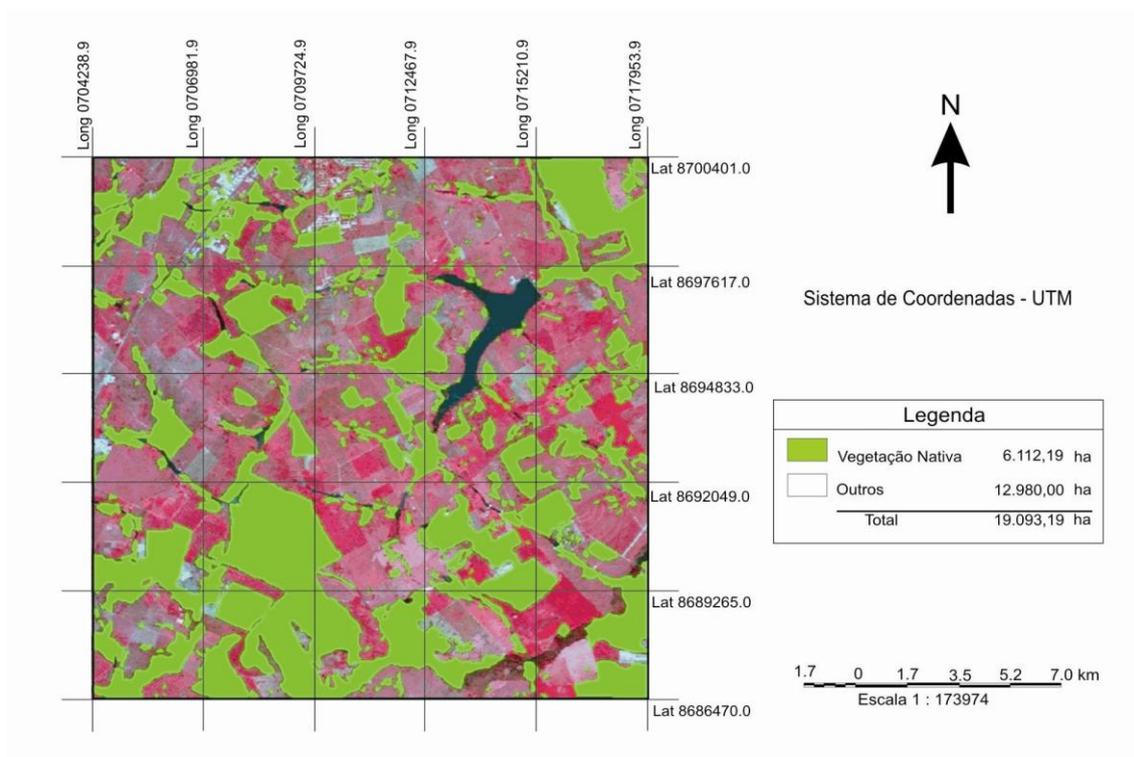


Figura 2: Vegetação nativa mapeada pelo método da classificação visual sobreposta à imagem sintética do local do trabalho obtida pela composição das bandas 4(R) 3(G) 2(B) do sensor CCD a bordo do satélite CBERS 2

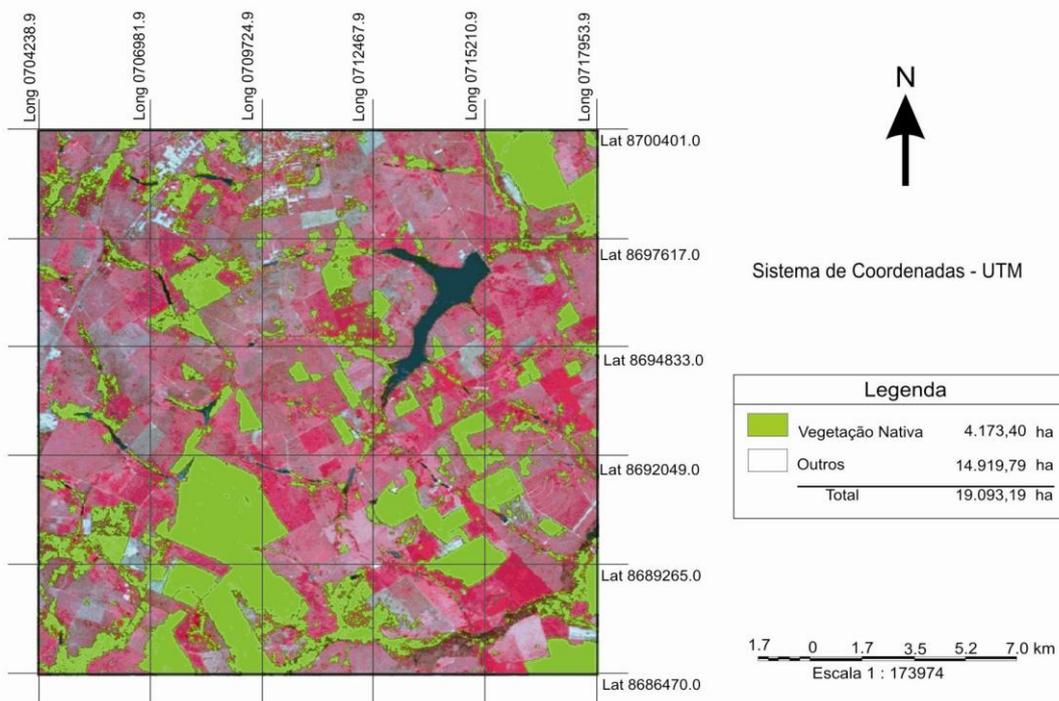


Figura 3: Vegetação nativa mapeada pelo método da classificação supervisionada sobreposta à imagem sintética do local do trabalho obtida pela composição das bandas 4(R) 3(G) 2(B) do sensor CCD abordo do satélite CBERS 2.

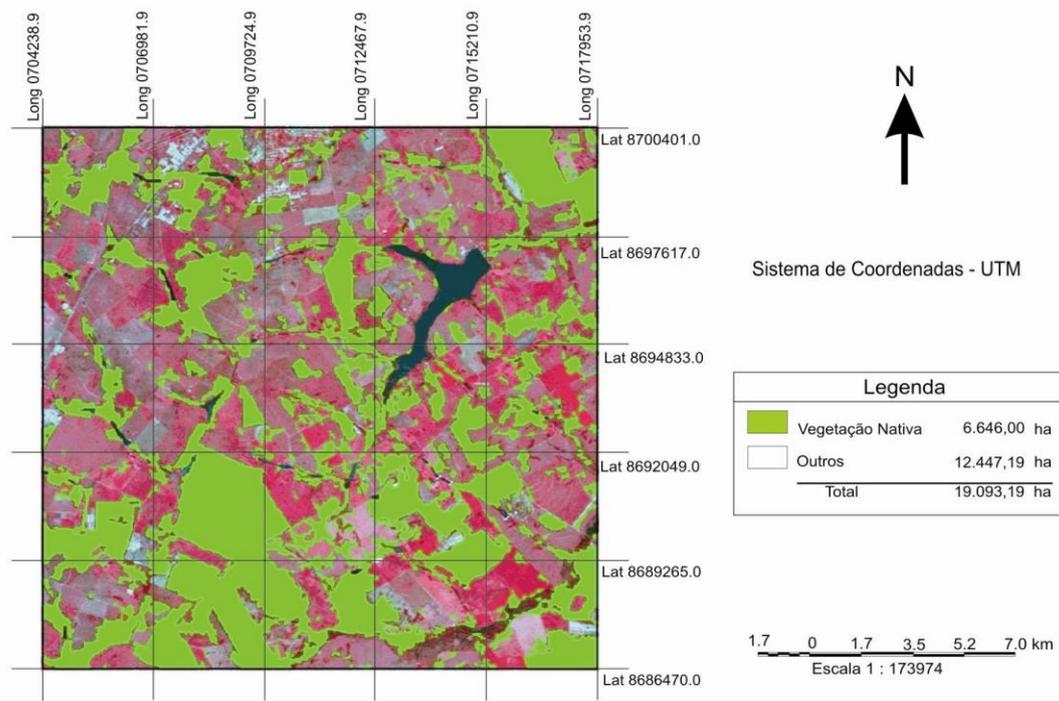


Figura 4: Vegetação nativa mapeada pelo método da classificação não supervisionada sobreposta à imagem sintética do local do trabalho obtida pela composição das bandas 4(R) 3(G) 2(B) do sensor CCD abordo do satélite CBERS 2.

Os índices Exatidão Global e Kappa das imagens classificadas, calculados a partir das matrizes de erros estão representados na Tabela 2.

Tabela 2: Índice Exatidão Global e Kappa para classificações geradas

M. de class. da imagem	Exatidão global	Kappa
Visual	97,36	91,21
Supervisionado	96,05	87,86
Não supervisionado	78,94	42,61

A diferença observada entre os índices Kappa e Exatidão Global são decorrentes da eliminação da concordância, em razão da casualidade, para os cálculos do índice Kappa (VILELA et al., 2005).

Segundo as classes de qualidade da classificação associada aos valores do índice Kappa estabelecidas por Ganan et al. (2005), as classificações visual e supervisionada apresentam qualidade excelente.

Os excelentes índices de exatidão, resultantes da classificação visual deve-se ao conhecimento prévio da área mapeada por parte do intérprete. O desconhecimento da área, do uso e da cobertura do solo por parte do técnico e interprete resultaria, invariavelmente, em índices de exatidão muito abaixo daqueles encontrados. Desta forma, a principal limitação da classificação visual é a necessidade de conhecimento prévio da área.

Outra limitação da classificação visual que deve ser mencionada refere-se e ao treinamento e experiência do técnico/intérprete e a subjetividade inerente ao processo de tomada de decisão.

O bom conhecimento da área mapeada teve importância fundamental nos excelentes índices de exatidão resultantes da classificação supervisionada, devido à coleta de amostra para treinamento do algoritmo de classificação.

Embora Ganan et al. (2005) informe como boa a qualidade da classificação associada ao índice Kappa de 42,61% para a classificação não supervisionada, outro autor como Queiroz (2002) associa a este índice uma qualidade razoável ou discreta tendendo a fraca para a classificação gerada.

A classificação não supervisionada não requer conhecimento prévio da área, por tal motivo à mesma é utilizada como uma classificação inicial, ou uma pré-classificação, para o conhecimento da área em relação aos padrões de reflectância espectral.

O SPRING, entretanto, após a classificação não supervisionada da imagem, possibilita o mapeamento ou rotulação das classes. No entanto, um número elevado de classes dificulta, sobremaneira, o mapeamento ou rotulação das classes.

A dificuldade de mapeamento ou rotulação das classes promove, invariavelmente, confusão entre as mesmas, resultando em erros de comissão e omissão elevados e, conseqüentemente um índice de exatidão baixo como observado para a classificação não supervisionada.

Uma vez que o objetivo do trabalho foi mapear as áreas de vegetação nativa, resultando apenas duas classes de interesse denominadas Vegetação Nativa e Outros, provavelmente uma classificação com um número reduzido de classes diminuiria a confusão entre as classes, elevando conseqüentemente os índices de exatidão.

4 Considerações finais

Como para a maioria das aplicações em sensoriamento remoto e sistema de informações geográficas é necessário que a classificação apresente um nível de exatidão satisfatório, pode-se afirmar, a partir dos resultados obtidos, que:

a) para as condições locais, a classificação visual e supervisionada foram as mais indicadas;

b) o conhecimento prévio da área foi imprescindível à qualidade do resultado da classificação visual e supervisionada;

c) uma classificação não supervisionada com um número reduzido de classes poderia diminuir a confusão entre as classes e elevar os índices de exatidão para a classificação, segundo as condições locais.

5 Referências bibliográficas

Livro:

EASTMAN, J. R.; **Idrisi exercícios tutorais**. Porto Alegre UFRGS. 1994 109p.

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 2. ed. New Jersey: Prentice Hall, 1996. 316p

NOVO, E. M., 1989. **Sensoriamento remoto: princípios e aplicações**. São Paulo. Edgard Blucher. 307p.

SPRING, Vr. 4.1. **Integrating remote sensing and GIS by object-oriented data modeling**. Camara G, Souza RCM, Freitas UM, Garrido J Computers & Graphics, 20: (3) 395-403, May- Jun 1996

Tese:

QUEIROZ, R. C. **Validade e confiabilidade das declarações de óbito por câncer de boca no município do Rio de Janeiro**. Dissertação (Mestrado) Fundação Oswaldo Cruz, Escola Nacional de Saúde Pública; 2002. 65 p

VILELA, M. F.; SOARES, V. P.; ADUAN, R.E.; FERNANDES FILHO, E. I.; PEREIRA, R. A.; RIBEIRO, C. A. A. S. **Uso de imagens orbitais como base de dados para projetos de reforma agrária**. *Revista Árvore*, Viçosa-MG, v.29, n.4, p.627-638, 2005.

Eventos:

GANAN, J.R.; ROCHA, J.V. MERCANTE, E.; ANTUNES, J.F.G. **Mapeamento da cultura da soja com imagens Landsat 5/TM utilizando algoritmos de classificação supervisionada**. In: XII Simpósio Brasileiro de Sensoriamento Remoto. Anais. Goiânia, 16-21 abril 2005, INPE, p. 549-555.

SANTOS, M.L.M.; MATTOS, M.M.; PIRES, I.O.; BROWN, I.F.; ASSIS, W.S. **Utilização de imagens de satélite no mapeamento preliminar do uso da terra e na capacitação de agricultores do médio Rio Capim - Paragominas - PA**, Brasil. In: Simpósio Brasileiro de Sensoriamento Remoto, 7., 1993, São José dos Campos. *Anais...* São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 1993. 15 p.