

Segmentação de imagens de alta resolução utilizando o programa SMAGIC

Thiago Alencar-Silva¹
Philippe Maillard¹

¹ Universidade Federal de Minas Gerais - UFMG,
Av. Antônio Carlos, 6627 – 31270-901 – Belo Horizonte - MG, Brasil
{thiago-alencar@ufmg.br, philippe@cart.igc.ufmg.br}

Abstract. Segmentation and classification of high resolution image is not an easy task. High intra-class variance acts as noise and directly affects classification results. A range of algorithms has been developed in the past decades to extract objects-like shapes from the image. Many of these are not able to work properly with noisy data like radar images or even high resolution images of the Earth. In this paper a new software is tested to process 1-meter Ikonos images: SMAGIC. Originally created as a tool to identify different types of ice from Radarsat images at Canada, SMAGIC can now process multivariate data. The algorithm is unique in its approach. The approach is a hybrid one that makes use of a watershed segmentation and a Markov Random Fields paradigm. In this study a set of three Ikonos images samples was segmented and by SMAGIC. Field work was done to recognize the area and validation data for used in the classification process and to label the classes obtained with SMAGIC. In addition, same images were classified by the ECHO algorithm used as a benchmark comparison. All results were interpreted visually. SMAGIC was able to produce good classification results that generally outperformed traditional classification methods without the necessity to use training data. SMAGIC's algorithm is described as well as the general testing design. Some insight is given about future developments of SMAGIC.

Keywords: SMAGIC, segmentation, high resolution image SMAGIC, segmentação, imagem de alta resolução.

1. Introdução

Nos últimos anos foi possível observar o avanço da tecnologia de sistemas sensores para a observação da Terra. Cada vez mais imagens de alta resolução são utilizadas para se extrair informações do espaço através de métodos de segmentação e classificação. A segmentação é um processo que consiste em dividir as imagens em segmentos homogêneos (GONZALEZ; WOODS, 2000). A classificação pode ser definida de forma genérica como um processo que consiste em agrupar pixels em classes pré-estabelecidas pelo usuário (JENSEN, 2005).

Métodos tradicionais de classificação de imagens agrupam os pixels em classes tendo como base a análise espectral pixel por pixel. A alta variância intra-classe em imagens de alta resolução ocasiona problemas na classificação. Esta alta variância comporta-se como ruídos no processo de classificação. Uma alternativa para se trabalhar com estas imagens é incorporar na classificação análises que vão além da mera resposta espectral de cada pixel, adicionando parâmetros de distribuição espacial dos objetos na imagem (N-BARBOSA; ACCO; KIRCHNER, 2003). Este método é conhecido como classificação orientada ao objeto. Este processo é dividido em duas partes: a primeira consistem em segmentar a imagem, de acordo com parâmetros pré-estabelecidos, e em seguida a rotulação das classes.

Existem um número grande de segmentadores, cada qual com seus parâmetros de agrupamento de feições. Este artigo possui o objetivo de apresentar e avaliar o desempenho do segmentador SMAGIC (do inglês *Segmentation of Map Guided Ice Classification*) em imagens de alta resolução. Para isto amostras de imagens IKONOS foram preparadas e segmentadas pelo SMAGIC. As mesmas imagens foram classificadas pelo algoritmo ECHO (*Extraction and Classification of Homogeneous Objects*) como forma de comparação dos resultados obtidos pelo SMAGIC. O ECHO foi escolhido por ser bastante conhecido e pelo fato de incorporar uma segmentação prévia no seu processo de classificação.

Dados obtidos em campo foram utilizados no processo de rotulação da segmentação realizada pelo SMAGIC e como áreas de treinamento e de teste no processo de classificação pelo ECHO.

2. Materiais e Métodos

2.1. SMAGIC

SMAGIC é uma sigla que significa “Segmentation of Map Guided Ice Classification” porque foi inicialmente desenvolvido como ferramenta capaz de aprimorar a interpretação de imagens Radarsat-1 para a classificação dos tipos de gelo de mar e produzir uma classificação a nível do pixel. Por outro lado o padrão de mapas de gelo para navegação da WMO (“World Meteorological Organization”) somente fornecem uma informação genérica das proporções e tipos de gelo em grandes áreas sem especificar a localização precisa desses tipos de gelo. Com o lançamento de Radarsat-2 fornecendo dados multi-polarizados, o SMAGIC precisou ser adaptado a uma fonte de dados multivariada e essa modificação abriu um universo de novas perspectivas para a segmentação e a classificação de imagens multiespectrais em geral e especificamente de alta resolução espacial (estamos considerando portanto trocar o “Ice” por “Image”). Por enquanto SMAGIC não incorporou a classificação e se restringe à segmentação de imagens, motivo pelo qual o “S” foi inserido no início da sigla. O futuro MAGIC irá incorporar várias possibilidades de classificadores inclusive alguns inéditos.

O segmentador de SMAGIC é único na sua implementação e pelos princípios que incorpora. É um segmentador híbrido porque utiliza duas abordagens algorítmicas distintas: o “watershed” e os Campos Aleatórios de Markov (CAM). A segmentação é iniciada aplicando o algoritmo do “watershed” que produz uma segmentação preliminar e gera segmentos (áreas) de 10 a 30 pixels dependendo do nível de ruído na imagem. Os pequenos segmentos são então organizados topologicamente de maneira que todos os segmentos contíguos possam ser determinados. Para isso um gráfico de adjacência é construído ou RAG (“Region Adjacency Graph”). A segunda etapa é baseada nos CAMs que irá unir ou não segmentos contíguos se essa união gera uma diminuição da energia total da vizinhança definida na equação 1.

$$E = E_f + \alpha E_r \quad (1)$$

Onde E_f representa a energia global espectral e E_r representa a energia local espacial; α é um peso normalmente constante mas flutuante na abordagem atual (DENG; CLAUSI, 2005). A vantagem do modelo CAM reside na sua capacidade inerente em descrever simultaneamente o contexto espacial local (a interação espacial local entre os segmentos vizinhos) e a distribuição global de cada segmento (a partir de parâmetros de distribuição dos valores espectrais por exemplo). Tal característica é apropriada desde que os segmentos vizinhos não sejam estatisticamente independentes mais espacialmente correlacionados (TSO; MATHER, 2001). Essa nova abordagem foi intitulada de “Iterative Region Growing using Semantics” ou IRGS e é descrita em Yu e Clausi (2008).

Desde 2008, SMAGIC é dotado de uma interface gráfica (Figura: 1) desenvolvida para plataforma Windows (©2008 Microsoft). A interface incorpora várias ferramentas como a visualização de imagens (incluindo “zoom” e deslocamento de tipo “hand”) que também permite a superposição dos resultados da segmentação em semi-transparência. A interface oferece ainda a possibilidade de incorporar polígonos de dados auxiliares (daí a denominação “Map-Guided”) ou ainda para o usuário de desenhar seus próprios polígonos que são utilizados para restringir a segmentação a um setor específico.

2.2. ECHO

O ECHO é um classificador que incorpora em sua rotina além da avaliação espectral uma avaliação espacial (KETTIG; LANDGREB, 1976). O processamento ocorre em duas etapas: primeiro a cena é segmentada em regiões estatisticamente homogêneas e posteriormente




Figura 1: Interface gráfica do SMAGIC.

estas regiões são classificadas através do processo de máxima verossimilhança. Na etapa de segmentação grupos de pixels são submetidos a um primeiro teste para a verificação estatística de homogeneidade. Os parâmetros de número de pixels e de limiar estatístico são definidos pelo usuário. Os grupos de pixels que passam por este teste são considerados agrupamentos homogêneos. A precisão da classificação ECHO é geralmente maior quando comparada com classificadores pixel por pixel, pelo fato de que os limiares de teste são definidos pelo usuário em todas as etapas do processo. Outra vantagem deste classificador é o tempo de processamento, uma vez que se trabalha com agrupamentos de pixels.

2.3. Área de estudo, dados e pré-processamento

A área de estudo em questão localiza-se no Parque Estadual Veredas do Peruaçu, situado no norte do estado de Minas Gerais (Figura: 2). A região é caracterizada por uma topografia plana, clima semi-árido, com duas estações bem definidas: excedente hídrico (outubro - março) e déficit hídrico (abril-setembro). A vegetação é composta por cerrado em diversos estágios de regeneração, além de regiões de veredas (GOMES; MAILLARD, 2003).

A vereda é considerada uma fitofisionomia do cerrado associada às zonas onde há maior concentração de umidade no solo, geralmente ocorre ao longo de cursos d'água. Este ambiente, é caracterizado pela presença da palmeira arbórea buriti (*Mauritia flexuosa L.f.*), em meio a agrupamentos mais ou menos densos de espécies arbustivas e herbáceas (RIBEIRO; WALTER, 1998). As veredas são encontradas na região ao longo do curso do Rio Peruaçu e seus afluentes. Este rio forma a divisa entre o parque e áreas adjacentes de agropecuária. Por este motivo é possível verificar que as veredas da margem direita do rio Peruaçu (área pertencente ao parque) são melhores preservadas do que as da margem esquerda.

Neste estudo três amostras de um mosaico de imagens Ikonos foram utilizadas. O mosaico de imagem Ikonos, que recobre toda a área do parque estadual, foi obtido através de um convênio com o Instituto Estadual de Florestas de Minas Gerais. As imagens que compõe este mosaico foram adquiridas com as bandas multispectrais e pan-cromáticas já fusionadas e corrigidas geometricamente. A resolução espacial da imagem é de 1m. A correção atmosférica

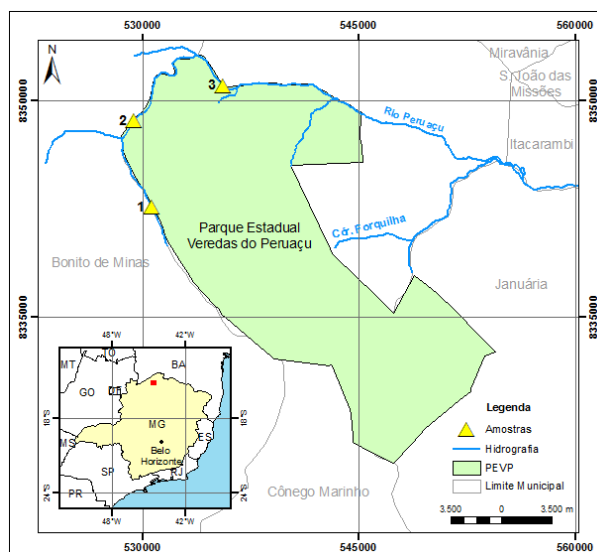


Figura 2: Localização da Área de Estudo. Fonte: Adaptado de IBGE.

não foi realizada por se tratar de uma única cena e como forma de avaliar o desempenho dos segmentadores nesta condição. Três amostras de imagens foram preparadas a partir do mosaico com o objetivo de otimizar o processamento (amostra 1, 2 e 3). Cada amostra é composta por um arranjo de 1000 x 1000 pixels totalizando uma área de 1km^2 . As amostras possuem 4 bandas espectrais: azul, verde, vermelho e infravermelho próximo.

A amostra 1 recobre a área próxima à nascente do rio Peruaçu. A vereda está localizada em uma faixa estreita e central da imagem no sentido sudeste-noroeste. A margem direita da vereda é composta de forma sucessiva por uma faixa de vegetação herbácea e arbustiva, uma estrada estreita e uma área de cerrado. Este último dividido entre cerrado, cerrado ralo e cerrado denso. Na margem esquerda da vereda é também possível observar em seqüência uma área herbácea/arbustiva, uma estrada larga e regiões de cerrado, com as mesmas divisões da margem direita.

A amostra 2 encontra-se a jusante da amostra 1. A vereda nesta imagem também é estreita e localizada na região central, contudo no sentido sudoeste-nordeste. A leste da vereda de forma sucessiva temos uma faixa herbácea/arbustiva, uma estrada e cerrado: dividido em cerrado e cerrado denso. A oeste da vereda é verificado uma faixa de vegetação herbácea e arbustiva, uma estrada e uma região de cerrado aberto, onde é possível verificar áreas de solo exposto dispersas entre a vegetação.

A amostra 3 possui um nível maior de complexidade. Nesta região as veredas são mais largas e intercaladas por faixas herbácea/arbustiva. Na parte central existe uma “ilha” de cerrado rodeada por veredas. Porções de solo exposto estão concentradas na parte sul e leste da imagem com a presença de uma área que um dia foi um lago.

2.4. Trabalhos de Campo

Dois trabalhos de campo foram realizados entre julho e novembro de 2006 como forma de auxiliar o processamento das imagens. O primeiro campo teve o objetivo de se obter dados de validação e áreas de treinamento para posterior processamento das imagens. Quatro transectos fito-fisionômicos foram feitos entre a região de cerrado e vereda com o auxílio de um receptor GPS de navegação. Pontos de controle foram obtidos para cada mudança fisionômica da vegetação a medida que se atravessava de forma transversal a vereda. O ponto inicial de

cada transecto foi o cerrado em uma das margens das veredas e ponto final foi o cerrado da outra margem. As anotações sobre as mudanças fito-fisionômicas foram feitas em caderneta de campo. Em seguida os pontos de controle foram transformados em vetores para facilitar a aplicação no processamento das imagens.

O objetivo do segundo campo foi o reconhecimento geral da região. O acesso por terra não é uma tarefa fácil uma vez que o cerrado encontra-se bem preservado no parque. Um sobrevôo de helicóptero foi realizado para se obter pontos de controle e fotografias aéreas auxiliares da região. Este procedimento facilitou o processamento das imagens na escolha de áreas de treinamento e de teste de cerrado que não foram visitadas por terra.

2.5. Processamento das imagens

A fim de dar uma base de comparação para os resultados obtidos com SMAGIC, as amostras foram classificadas utilizando um classificador de máxima verossimilhança. Como era previsível que a variância intra-classe iria produzir resultados com pouca consistência (contigüidade) espacial, ele foi usado em conjunto com o segmentador rudimentar do algoritmo ECHO desenvolvido por Landgrebe (1980) e disponível no programa MultiSpec (©2007 Purdue Research Foundation / NASA, USA).

Uma chave de classificação apropriada para a área de estudo foi usada na etapa de classificação das amostras. Esta chave de classificação está fundamentada nos estudos de veredas realizados por (ALENCAR-SILVA, 2007) na região. Seis classes foram determinadas para as amostras 1 e 2 e cinco para a amostra 3. As classes para as amostras 1 e 2 foram: Vereda, Herbáceo/Arbustivo, Solo Exposto, Cerrado, Cerrado Ralo e Cerrado Denso. As classes para a amostra 3 foram: Vereda, Herbáceo/Arbustivo, Solo Exposto, Cerrado e Cerrado Denso.

3. Resultados e Discussão

Os resultados da segmentação feita pelo SMAGIC e a classificação realizada pelo ECHO são apresentados nas Figuras: (3, 4 e 5). Os resultados obtidos pelo SMAGIC e ECHO foram comparados com a interpretação visual da composição colorida das amostras. Fomos obrigados a adotar este procedimento em vista da falta de dados sobre os diversos tipos de cerrado, pois as veredas e as áreas de herbáceas não representavam um problema para os classificadores tradicionais enquanto as áreas de cerrado eram facilmente confundidas.

Para a amostra 1 o SMAGIC obteve um resultado geral que demonstra uma boa consistência espacial com uma imagem onde as classes apresentaram-se mais homogêneas quando comparado com o ECHO. O SMAGIC segmentou bem as classes de vereda, herbáceo/arbustivo e solo exposto. Contudo, algumas áreas de veredas e solo exposto podem ser encontradas em região que são de cerrado e cerrado ralo. Áreas da classe herbáceo/arbustivo foram encontradas em região de cerrado ralo. O resultado do ECHO para a amostra 1 mostra uma boa distinção entre as classes. Contudo, quando analisamos cada classe de forma separada podemos observar grande quantidade de “ruído”, que está relacionado com a presença de pequenos grupos de pixels de outras classes.

O SMAGIC conseguiu separar bem a classe de vereda na amostra 2, além de segmentar melhor as classes de cerrado e cerrado denso. A classe herbáceo/arbustiva não obteve o mesmo sucesso anterior, sendo que foi confundida com áreas de cerrado e cerrado ralo. A classe de cerrado ralo apresenta confusão com a classe herbáceo/arbustiva. O solo exposto apresenta boa segmentação contudo também aparece em regiões de cerrado ralo. Para a amostra 2 o SMAGIC apresentou maior homogeneidade intra-classe assim como ocorreu para a amostra 1. O ECHO, mais uma vez, apresentou uma boa separação geral mas com grande confusão intra-classes.

Os resultados do SMAGIC para a amostra 3 correspondem visualmente com a interpretação

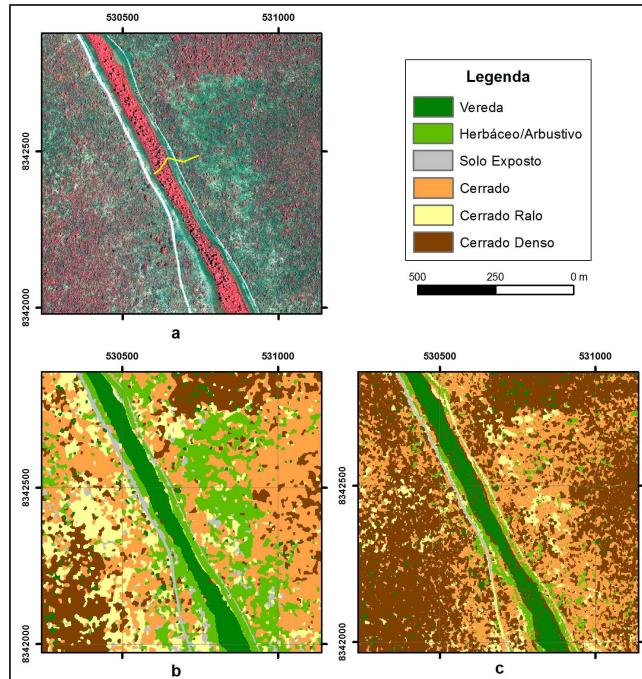


Figura 3: Resultados do processamento da amostra 1. a) Imagem Ikonos RGB = 4,3,2 e transecto. b) Segmentação feita pelo SMAGIC. c) Classificação feita pelo ECHO.

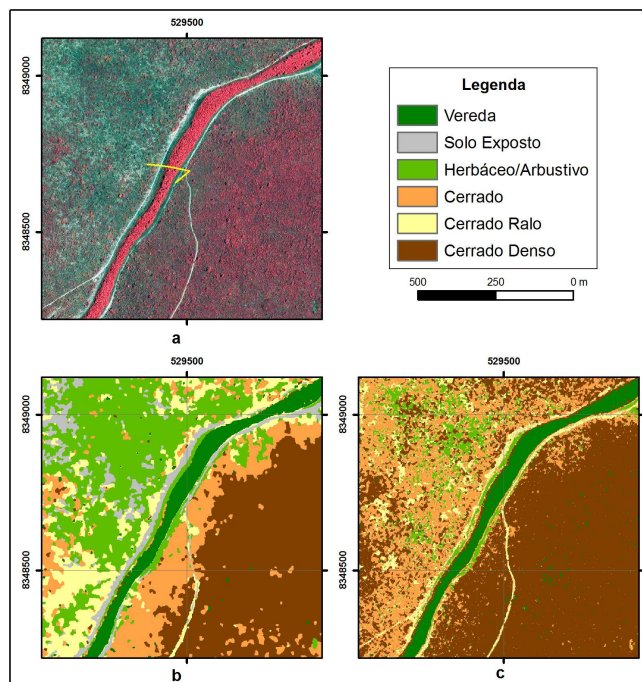


Figura 4: Resultados do processamento da amostra 2. a) Imagem Ikonos RGB = 4,3,2 e transecto. b) Segmentação feita pelo SMAGIC. c) Classificação feita pelo ECHO.

da imagem original. As classes, herbáceo/arbustiva, solo exposto e cerrado foram bem segmentadas. O SMAGIC, inclusive, conseguiu identificar a área oval de herbáceas correspondendo a um antigo lago no canto inferior esquerdo da imagem, fato que não pode ser

verificado no resultado ECHO. Assim como os resultados anteriores as classes apresentaram-se mais homogêneas quando comparado com o resultado ECHO. Nesta amostra o resultado negativo do SMAGIC foi a confusão dos resultados da classe vereda e cerrado denso.

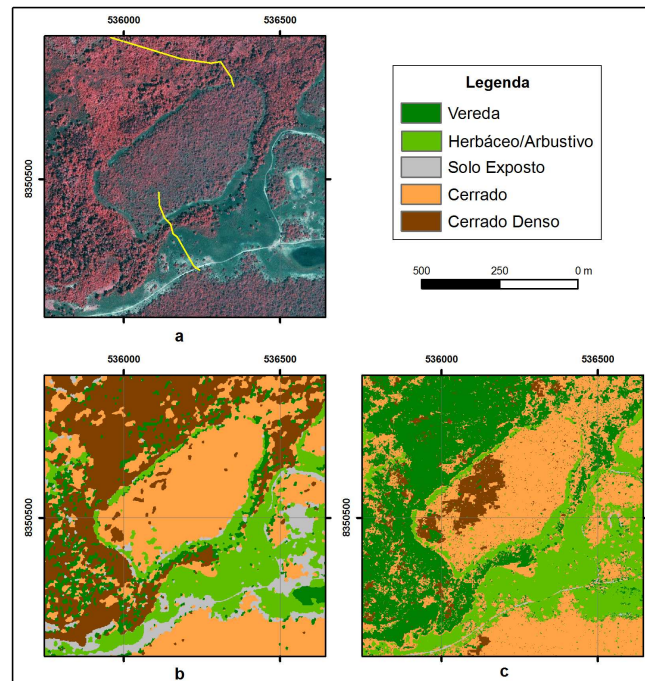


Figura 5: Resultados do processamento da amostra 3. a) Imagem Ikonos RGB = 4,3,2 e transecto. b) Segmentação feita pelo SMAGIC. c) Classificação feita pelo ECHO.

4. Conclusão

O processo de segmentação de imagens possui o objetivo de se realizar de forma automática ou semi-automática a tarefa de fotointerpretação. A identificação com acurácia das feições de uma imagem não é uma tarefa fácil, principalmente em imagens de alta resolução espacial, onde a variância intra-classes é elevada. Segmentadores que utilizam a análise orientada ao objeto possui resultados melhores que segmentadores baseados apenas na análise pixel por pixel, isto porque agrupamentos de pixels que na maioria dos casos correspondem à um objeto na cena, são analisados de forma conjunta. Mesmo com a presença de ruído intra-classe a maioria das classes são identificadas nesta abordagem, assim como pode ser observado nos resultados apresentados nesta pesquisa.

Os resultados do programa SMAGIC apresentados neste artigo o coloca em uma categoria de algoritmo avançado para a realização de segmentação. Esta conclusão está fundamentada nos resultados aplicados desta pesquisa em amostras de imagens Ikonos. O SMAGIC foi capaz de separar as classes propostas pela chave de classificação em imagens com certa complexidade de distribuição de elementos. Algumas das classes propostas possuem respostas espectral semelhante (herbáceo/arbustivo e cerrado), o que de certa forma explica alguns resultados negativos do SMAGIC. Quando comparado com o classificador ECHO pode-se notar a superioridade o SMAGIC, uma vez que ele gera classes com maior homegeneidade. Cabe ressaltar atualmente o SMAGIC não incorpora áreas de treinamento em seu processamento.

Em um próximo momento novas amostras de imagens de alta resolução, e até mesmo de radar poderão ser testadas. MAGIC ainda está em fase de desenvolvimento e melhores

resultados poderão ser obtidos com a incorporação de áreas de treinamento e de teste, ou até mesmo parâmetros de textura de imagem.

Referências

ALENCAR-SILVA, T. *Proposta Metodológica para Delimitação e Classificação do Ambiente de Vereda Utilizando Imagens Orbitais*. 87 p. Dissertação (Mestrado) — Instituto de Geociências - Universidade Federal de Minas Gerais, 2007.

DENG, H.; CLAUSI, D. A. Unsupervised segmentation of synthetic aperture radar sea ice imagery using a novel Markov random field models. *IEEE Trans. on Geoscience and Remote Sensing*, v. 43, n. 3, p. 528–538, 2005.

GOMES, M. F.; MAILLARD, P. Mapeamento fitogeográfico das unidades de conservação do Peruaçu utilizando dados do sensor ETM de LANDSAT: uma abordagem multiespectral e textural. In: *Proceedings of the XI Brazilian Symposium on Remote Sensing, Belo Horizonte, MG, Brazil*. [S.l.: s.n.], 2003. p. 2753 – 2761.

GONZALEZ, R. C.; WOODS, R. E. *Processamento de Imagens Digitais*. (Traduzido do Inglês, Título original: Digital Image Processing): Editora Edgard Blücher. 509 p., 2000.

JENSEN, J. R. *Introductory Digital Image Processing*. 3rd. ed. [S.l.]: Pearson Prentice Hall, New Jersey. 526 p., 2005.

KETTIG, R. L.; LANDGREB, D. A. Computer classification of remotely sensed multispectral image data by extraction and classification of homogeneous objects. *IEEE Transactions on Geoscience Electronics*, v. 14, n. 1, p. 19–26, 1976.

LANDGREBE, D. A. The development of a spectral-spatial classifier for earth observational data. *Pattern Recognition*, v. 12, n. 3, p. 165–175, 1980.

N-BARBOSA, K. M.; ACCO, M.; KIRCHNER, F. F. Classificação de imagens ikonos e comparação por meio de segmentação e fotointerpretação da área amostral. *Anais do XI Simpósio Brasileiro de Sensoriamento Remoto*, v. 1, n. 1, p. 281–283, 2003.

RIBEIRO, J. F.; WALTER, B. M. T. Cerrado: ambiente e flora. In: _____. 1st. ed. Planaltina (DF): [s.n.], 1998. cap. Fitofisionomias do Bioma Cerrado, p. 89–153.

TSO, B.; MATHER, P. *Classification Methods for Remotely Sensed Data*. London, England: Taylor and Francis, 2001. 1-332 p.

YU, Q.; CLAUSI, D. A. Irgs: image segmentation using edge penalties and region growing. *IEEE Trans. Pattern Analysis and Machine Intelligence*, p. paper accepted for publication, 2008.