

## Classificação digital do uso do solo comparando os métodos “pixel a pixel” e orientada ao objeto em imagem QuickBird

Henriqueta Veloso Ferreira Bernardi <sup>1</sup>

Maíra Dzedzej <sup>1</sup>

Luis Marcelo Tavares de Carvalho <sup>1</sup>

Fausto Weimar Acerbi Júnior <sup>1</sup>

<sup>1</sup> Universidade Federal de Lavras - UFLA

Caixa Postal 37 - 37200-000 - Lavras - MG, Brasil

henriquetabernardi@gmail.com, mairafloresta@yahoo.com.br,

{passarinho, fausto}@ufla.br

**Abstract.** In remote sensing applications the increasing availability of new sensors, imaging in variety of ground scales, undoubtedly provides strong motivations for the experimentation of new classification technologies. This is the case for high spatial resolution images where the traditional pixel based classification methods is not able to capture the all variation in the image. This study compared the traditional pixel based classification, using the maximum likelihood algorithm, with an object-oriented classification, using the nearest neighbor algorithm. The results showed that the object-oriented classification yielded maps more accurate than the traditional pixel based classification.

**Palavras-chave:** remote sensing, image processing, land-cover, high resolution image, sensoriamento remoto, processamento de imagens, cobertura do solo, imagem de alta resolução.

### 1. Introdução

As modificações dos ecossistemas caracterizadas pelo processo de ocupação do Brasil sem planejamento e conseqüente destruição dos recursos naturais, particularmente das florestas, associado ao crescimento demográfico, desencadearam processos de destruições que envolvem o solo, a cobertura florestal nativa, o relevo e o uso dos recursos hídricos.

A noção de recursos naturais inesgotáveis estimulou e ainda estimula a expansão da fronteira agrícola. Assim, o processo de fragmentação florestal é intenso nas regiões economicamente mais desenvolvidas, ficando a vegetação arbórea nativa representada, principalmente, por florestas secundárias, em variado estado de degradação.

Neste contexto, surge a necessidade de avaliar o modelo de ocupação e uso do solo a fim de identificar suas relações com diferentes níveis de degradação dos recursos locais e assim estruturar métodos de recuperação destas áreas. O levantamento do uso do solo, em uma dada região, tornou-se um aspecto de interesse fundamental para a compreensão dos padrões de organização do espaço.

Para isto, torna-se necessário à utilização de técnicas que permitam uma avaliação espaço-temporal rápida e eficiente dessas áreas. Dentre as várias ferramentas existentes no universo de geoprocessamento, a classificação digital das imagens de satélite surge como uma ótima opção. Seu processo se baseia na distinção e identificação de diferentes classes que possuem comportamentos espectrais diferenciados, os quais permitem a sua classificação automatizada, em tempo hábil e em grandes áreas. Para isso, algoritmos de classificação ou classificadores são adotados para extrair as feições de interesse a partir de um espaço multidimensional, geralmente representado pelas bandas da imagem, criando um único nível de informação temática, as classes, Maillard (2001), citado por Dutra, (2005).

Essa classificação pode ser realizada através da análise “pixel a pixel” ou orientada ao objeto. Classificadores “pixel a pixel” utilizam apenas a informação espectral, isoladamente, de cada pixel para achar a classe mais provável para o pixel.

Já a classificação orientada ao objeto, a análise é realizada sobre objetos ou segmentos na imagem e não apenas sobre *pixels*. Na imagem um objeto representa uma entidade que pode ser individualizada, tem atributos próprios e as mesmas propriedades da classe que lhe deu origem (Definiens, 2006). Entre os motivos para se adotar a classificação de imagem orientada ao objeto podem ser citados, Gonçalves *et al.*, (2001):

- O processamento de imagens aproxima-se mais dos processos cognitivos humanos que as análises baseadas em *pixel*;

- É mais fácil incorporar informação de contexto com significado numa abordagem orientada ao objeto do que numa abordagem apenas por *pixel*.

A segmentação é um processo realizado antes da classificação, com o objetivo de dividir a imagem em regiões homogêneas, para solucionar problemas de subjetividade em classificações supervisionadas. O processo consiste em separar os atributos espectrais da imagem em regiões homogêneas, isto é, os *pixels* com características similares (forma, textura, área, parâmetros espectrais) são associados (Moreira, 2003).

Existem essencialmente dois métodos de classificação de imagens: 1) a classificação supervisionada, na qual o usuário identifica alguns dos “pixels” (elementos de resolução) pertencentes às classes desejadas e deixa ao computador a tarefa de localizar todos os demais pixels pertencentes àquelas classes, baseado em alguma regra estatística preestabelecida, e, 2) a classificação não-supervisionada em que o próprio computador decide, também com base em regras estatísticas, quais são as classes a serem separadas e quais os “pixels” pertencentes a cada uma Crosta, (1993), Rosa y Brito, (1996), citado por Pinheiro (2003).

Os algoritmos aplicados à classificação de imagens, como o Kmédias, Isodata, (não-supervisionados); Máxima Verossimilhança (MAXVER), Distância Mínima, Paralelepípedo, Distância Mahalanobis, (supervisionados), segundo Tanaka e Sugimura (2001), utilizam a classificação “por ponto” ou “por *pixel*”. Entretanto, algoritmos como Iseseg, (não-supervisionado) e Bhattacharyya (supervisionado), são métodos de classificação por regiões, isto é, utilizam uma imagem segmentada em regiões por polígonos como dado de entrada.

Nos últimos anos, houve uma grande inovação nas imagens orbitais para uso comercial, como o lançamento dos novos sistemas orbitais com alta resolução espacial, a partir da segunda metade da década 90, buscando superar algumas limitações das imagens adquiridas pelos satélites da série LANDSAT, SPOT (*Satellite Pour l’Observation de la Terre*), entre outros (Tanaka e Sugimura, 2001).

Os novos sistemas sensores orbitais, como o IKONOS-II e o QuickBird, exigiram novos métodos para a extração de informações das respectivas imagens. Hoffmann e Vejt (2001) sugerem a classificação orientada ao objeto para classificar imagens com alta resolução.

Atualmente, o aplicativo *eCognition Object-Oriented Image Analysis* desenvolvido pela empresa alemã Definiens tornou-se uma ferramenta importante para a classificação de imagens de SR. Este aplicativo é empregado, p.ex., para processar imagens de satélites com alta resolução espacial como o IKONOS-II e QUICKBIRD, bem como dados dos satélites LANDSAT e SPOT (Hoffmann e Vejt, 2001; Bauer e Steinnocher, 2001; Hofmann, 2001; Blaschke e Strobl, 2001; Schwarz, *et al.*, 2002).

Estes novos sensores orbitais com alta resolução espacial possibilitam a produção de mapeamentos em escalas maiores que permitem uma compreensão detalhada tanto do padrão de cobertura do espaço como, com o passar do tempo, do nível da alteração deste padrão. Em função das resoluções espacial, espectral e radiométrica dessas imagens será possível identificar classes mais finas que as produzidas pelos sistemas orbitais anteriores, o que

permitirá conseqüentemente, uma melhor compreensão dos processos ambientais nas áreas sob risco e uma definição mais direcionada e mais fundamentada das ações que visam a sua preservação.

De acordo com o exposto, o presente estudo teve como objetivo a experimentação e comparação das classificações “pixel a pixel” (MAXVER) e a orientada a objetos (Nearest Neighbor) sobre uma imagem de alta resolução QuickBird, quanto à adequação para a distinção de diferentes alvos que ocupam a cena.

## 2. Material e métodos

O trabalho foi realizado em uma imagem QuickBird, datada de 27/05/2003, do município de Lavras, na região sul do estado de Minas Gerais, a qual compreende uma parte da bacia do Ribeirão Santa Cruz. A bacia têm como curso d’água principal o Ribeirão Santa Cruz, que é tributário do Rio Capivari que, por sua vez, é tributário do Rio Grande e este, integrante da bacia do Rio Paraná.

O clima do município de Lavras é do tipo Cwa, conforme a classificação de Köppen. A temperatura média anual está em torno de 19,3°C e a precipitação anual normal é de 1.530mm (Brasil, 1992). A formação florestal da bacia é classificada como floresta estacional semidecidual montana (Veloso et al., 1991).

O desenvolvimento deste trabalho foi efetuado nas seguintes etapas: preparação da imagem, seleção de amostras de treinamento, classificação orientada ao objeto (Nearest Neighbor), classificação “pixel a pixel” (MAXVER) e avaliação dos resultados.

A imagem do sensor QuickBird, Imagem Padrão (*Standard Imagery*) possui resolução espacial de 0,60m (PAN) e 2,4m (MS). Para corrigir as distorções foi preciso ortorretificá-la. No processo de ortorretificação da imagem, foi utilizado o DEM da área além dos coeficientes “RPC” disponibilizados no arquivo metadados da imagem.

Os materiais utilizados para o processamento da imagem foram:

- *Software* ENVI 4.1, para a preparação da imagem e classificação “pixel a pixel” (MAXVER);
- *Software* e-Cognition 4, para a análise orientada a objetos (Nearest Neighbor).

As amostras usadas foram as mesmas para os dois métodos. Primeiro elas foram coletadas no software e-Cognition e depois exportadas para o software ENVI. Para as amostras de treinamento foram coletados pixels puros e representativos das classes de interesse.

Foram estabelecidas 7 classes de acordo com o que foi observado visualmente, em campo e através dos subsídios fornecidos pelas técnicas de interpretação digital testadas anteriormente.

As classes de uso definidas foram individualizadas conforme a listagem a seguir: mata nativa (que correspondem aos fragmentos florestais e às matas ciliares primárias ou secundárias em avançado estágio de sucessão), campos (representada pelas áreas cobertas por campos nativos), área agrícola (representada por áreas cultivadas com plantações perenes e anuais), área urbana (representadas por áreas cobertas por edificações, aeroporto e também por vias asfaltadas que ligam estas áreas), pastagem, água e solo exposto.

A classificação da imagem realizada no *eCognition* considera, além do nível de cinza, a forma, a textura e funções de SIG (tamanhos de bordas de objetos, as suas relações topológicas) Hofmann (2001).

O processamento de imagens no *eCognition* desenvolveu-se a partir de uma segmentação, construção de uma hierarquia de classes e a classificação.

A **Figura 1** ilustra um modelo conceitual dos procedimentos operacionais no aplicativo.

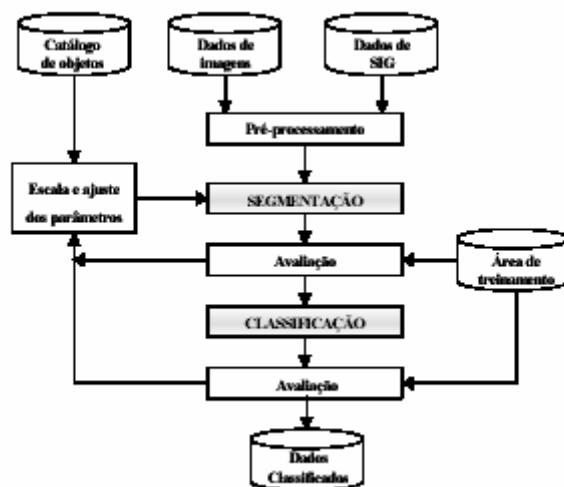


FIGURA 1 - Fluxograma conceitual de uma análise de dados de SR baseada em regiões.  
 FONTE: adaptada de Schiewe e Tufte (2002).

Segundo Schwarz *et al.*, (2002), citado por Pinheiro (2003) o modelo de classificação da imagem orientado ao objeto no *eCognition* pode ser resumido como segue:

- As imagens são segmentadas em diferentes níveis com distintos detalhes;
- A hierarquia de classe e a descrição da classificação são definidas;
- A imagem é classificada com base na hierarquia da classificação;
- Sobre a imagem segmentada é realizada a classificação;
- A exatidão temática da classificação é analisada.

O *eCognition* utiliza a Segmentação Multi-resolução, que realiza a fusão de regiões (*region-merging*) que funciona da base para cima (*bottom-up*), onde os setores da imagem são agrupados par a par. Inicialmente, um pixel individual é sinônimo de um objeto da imagem ou de uma região. Nos passos seguintes, pequenos objetos da imagem são agregados gerando outros maiores. Em cada passo o par adjacente do objeto da imagem é fundido segundo um patamar de crescimento definido para a heterogeneidade. O processo ocorre segundo um critério de homogeneidade, descrevendo a semelhança dos objetos vizinhos (Hofmann, 2001).

A decisão de agrupar um pixel, ou não, será tomada por meio do Grau de Homogeneidade (GH). Os *pixels* (ou objetos) são associados se o GH calculado for inferior ao Parâmetro Escalar (Fonseca, 2002). O Parâmetro Escalar utilizado para este trabalho foi de 10, e este determina a máxima heterogeneidade dos objetos e influência o tamanho desses (*Definiens*, 2006).

Para classificar a imagem o *eCognition* possui dois classificadores, o Vizinho mais Próximo (*Nearest Neighbor*) e as Funções Fuzzy de Pertinência (*Fuzzy Membership Functions*), além da classificação manual. O Vizinho mais Próximo classifica os objetos da imagem num dado espaço de características e com áreas de treinamento das classes. Depois de gerada a classificação a imagem foi exportada do software e-Cognition para o software ENVI para posteriores análises.

Realizou-se então, no ENVI, dentro do método “pixel a pixel” uma classificação supervisionada utilizando o método da máxima verossimilhança (MAXVER), por ser este um método comumente utilizado e também porque ele avalia quantitativamente tanto a variância quanto a covariância dos padrões espectrais de cada pixel durante a classificação. Deste modo, os padrões de resposta podem ser descritos com mais parâmetros de análise.

Os mapas resultantes foram comparados entre si, que consistiu em identificar e delimitar as diferentes áreas da superfície terrestre na imagem de satélite, considerando-se os diferentes

padrões tonais, o tamanho, a forma e a textura. O resultado final é um mapa contendo a distribuição espacial das diferentes classes de uso e coberturas do solo.

A comparação dos mapas foi realizada por meio da análise da matriz do erro, também chamada de tabela de confusão, que estima a precisão da área mapeada partindo de dados de sensoriamento remoto. Cada elemento da matriz representa o número de observações analisadas, considerando a classe na qual ela foi mapeada e a classe determinada no campo. A matriz de erro foi utilizada como ponto de partida para medidas estatísticas descritivas e analíticas (Fonseca, 2002).

### 3. Resultados e discussão

Os resultados da classificação “pixel a pixel” (MAXVER) e da orientada ao objeto são apresentados nas **Figuras 2 e 3**. Por intermédio das matrizes, percebe-se que a classificação MAXVER detectou melhor as áreas de matas nativas e as áreas com solo exposto, entretanto, confundiu bastante dois pares de classes que apresentam comportamento espectral semelhantes: área agrícola X mata nativa e área urbana X solo exposto.

Na classificação orientada ao objeto, esta confusão foi feita com mata nativa X área agrícola e solo exposto X pastagem. A classificação orientada a objetos também demonstrou uma melhor identificação das classes campo, água, área agrícola, pastagem e área urbana.

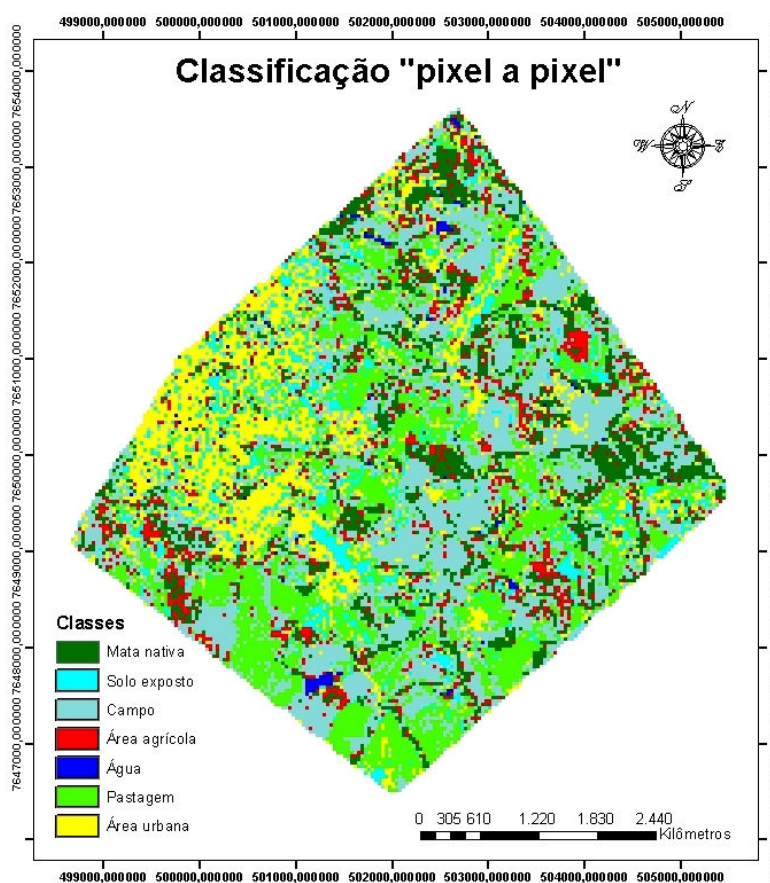


FIGURA 2 – Mapa da classificação pelo método “pixel a pixel”.

TABELA 1 - Matriz de erros da classificação “pixel a pixel”.

	Mata nativa	Solo exposto	Campo	Área agrícola	Água	Pastagem	Área urbana	Total
<i>Mata nativa</i>	88,09	0,00	9,39	28,31	0,00	0,01	2,16	21,08
<i>Solo exposto</i>	0,00	84,27	0,97	0,11	0,00	0,97	18,39	10,39
<i>Campo</i>	1,14	0,15	78,95	11,51	0,48	27,28	8,75	23,15
<i>Área agrícola</i>	10,37	0,00	3,49	58,91	0,00	3,12	3,07	16,67
<i>Água</i>	0,00	0,00	0,20	0,00	96,29	0,01	0,26	1,39
<i>Pastagem</i>	0,00	1,39	2,88	0,35	0,00	55,30	4,01	12,91
<i>Área urbana</i>	0,41	14,19	4,11	0,81	3,23	13,31	63,35	14,41
Total	100	100	100	100	100	100	100	100

Coefficiente Kappa = 0.6297

A matriz de erro para a classificação “pixel a pixel” apontou uma exatidão global de 69,087% , demonstrando que, dos 61099 pontos amostrados, 42212 apresentaram concordância entre a situação observada no mapa e a verificada pelas amostras de acurácia. Pelos dados da Tabela 1 verifica-se que todas as classes possuem erros de omissão. A classe que apresentou menor erro de omissão foi a classe água, e a classe que apresentou o maior erro de omissão foi a classe pastagem onde vários pixels foram incluídos nas classes campo, área cultivada e área urbana.

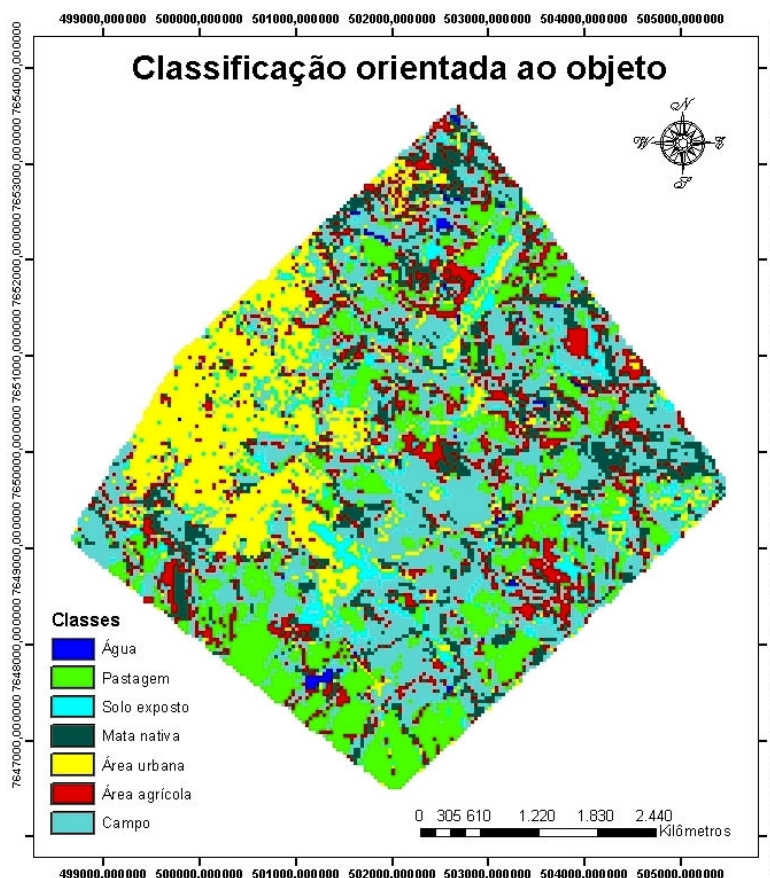


FIGURA 3 – Mapa da classificação pelo método orientada ao objeto.

TABELA 2 - Matriz de erros da classificação orientada ao objeto.

	Mata nativa	Solo exposto	Campo	Área agrícola	Água	Pastagem	Área urbana	Total
<i>Mata nativa</i>	74,67	0,00	3,92	16,54	0,00	0,00	0,00	15,21
<i>Solo exposto</i>	0,00	67,07	0,28	0,00	0,00	0,00	6,37	6,77
<i>Campo</i>	1,44	7,73	91,60	6,9	0,72	12,62	2,98	20,98
<i>Área agrícola</i>	23,89	0,00	3,34	71,23	0,00	0,11	2,64	20,72
<i>Água</i>	0,00	0,00	0,00	0,00	99,28	0,04	0,00	1,36
<i>Pastagem</i>	0,00	25,15	0,00	0,00	0,00	87,23	0,00	21,73
<i>Área urbana</i>	0,00	0,00	0,86	0,00	0,00	0,00	87,01	13,07
Total	100	100	100	100	100	100	100	100

Coeficiente Kappa = 0.7681

Já a matriz de erro para a classificação orientada ao objeto apontou uma exatidão global de 80,89%, demonstrando que, dos 61099 pontos amostrados, 49423 apresentaram concordância entre a situação observada no mapa e a verificada pelas amostras de acurácia. Verifica-se que todas as classes possuem erros de omissão. A classe que apresentou menor erro de omissão foi a classe água, e a classe que apresentou o maior erro de omissão foi a classe solo exposto onde vários pixels foram incluídos nas classes campo e pastagem. Apenas 1,14% dos pixels foram classificados erroneamente como área urbana.

Uma matriz de classificação ideal deve apresentar os valores na diagonal principal próximos a 100%, indicando que não houve confusão entre as classes. Contudo, esta é uma situação difícil em imagens com alvos de características espectrais semelhantes, melhorando quando a forma e a textura são analisadas.

De maneira geral, a comparação entre os métodos revela uma maior preservação das formas dos alvos de interesse na classificação orientada a objetos, enquanto o resultado da classificação MAXVER apresentou uma aparência granulada. Isso pode ser explicado devido a heterogeneidade entre os “pixels” e a alta resolução da imagem, com o aparecimento de muitos detalhes.

Antunes (2003) desenvolveu uma pesquisa com o intuito de analisar a metodologia de classificação de tipologias vegetais em ambientes ciliares através de imagens IKONOS-II. Foram testados classificadores por pixel e o classificador orientado ao objeto. No resultado geral percebeu-se que a classificação por pixel não foi adequada para imagens. O método de classificação orientada ao objeto foi superior aos métodos paramétricos (pixel) o que foi confirmado também no presente trabalho.

#### 4. Considerações finais

Nos testes realizados com a abordagem orientada ao objeto, apesar de algumas classes terem ficado confusas, o resultado do mapa temático, dos valores do índice Kappa e da acurácia foram melhores que a da abordagem “pixel a pixel”.

A análise estatística de um pixel individual, de uma imagem com alta resolução, não é o método mais adequado para representar a paisagem. Outros parâmetros devem ser considerados na extração de informações, como: textura, distância, localização e conceitos de vizinhança.

As imagens com alta resolução espacial do QuickBird necessitam de novas metodologias de tratamento. Os classificadores convencionais por pixel são menos adequados, sendo proposto o método de classificação orientada ao objeto.

## Referências Bibliográficas

- Antunes, A.F.B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. Curitiba, 147 p. Tese (Ciências Geodésicas) – Universidade Federal do Paraná. 2003.
- Barnett, J. P.; Baker, J.B. Regeneration methods. In: DURYEA, M. L.; OUGHERTY, P. M. **Forest regeneration manual**. Dordrecht: Kluwer Academic Publisher, 1991. p. 35-50.
- Definiens Imaging. **eCognition: user guide**. 2000, 468 p. Disponível em: <<http://www.definiens-imaging.com/down/ecognition>>. Acesso em: ago. 2006.
- Dutra, G. C. **Estratificação ambiental visando à recuperação da vegetação ciliar no entorno do lago da Usina Hidrelétrica do Funil, em Minas Gerais**. 2005. 111p. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, MG.
- Fonseca, A. M. Classificação da ocupação do solo urbano, utilizando funções de pertinência, sobre uma imagem Ikonos da cidade de Lisboa. In: Conferência Nacional de Cartografia e Geodésia. Lisboa, 2002. **Anais**. Lisboa: 11 p. Série Comunicação
- Gonçalves, L. Fonseca, A.M.; Caetano, M. Exploração de imagens de alta resolução do satélite Ikonos. In: Encontro de Utilizadores de Informação Geográfica (ESIG 2001), 6., Lisboa, 2001. **Anais**. Lisboa, 22p. Série Comunicação.
- Green, K. The Potential and limitations of remote sensing and GIS in providing ecological information. In: Sample, V. A. (ed). **Remote sensing and GIS in ecosystem management**. Washington: Island Press, 1994. Part 4. cap. 19. p. 327– 336.
- Hoffmann, A; Vejt, J.W.V. New sensor systems and new classification methods: laser-and digital camera-data meet object-oriented strategies. **Journal for Spatial Information and Decision Making**, n. 6/01. p. 18-23, June 2001.
- Moreira, M.A. **Fundamentos do sensoriamento remoto e metodologia de aplicação**. 2ed. Viçosa: UFV, 2003. 307p.
- Pinheiro, E. S. **Avaliação de imagens QUICKBIRD na análise geográfica de um setor da mata atlântica do rio Grande do sul**. São José dos Campos: INPE, 2003. 183p. – (10094-TDI-891).
- Schiewe, J.; Tufte, L. Integrative Auswertung von GIS – und Fernerkundung. In: BLASCHKE, Th. (ed.). **Fernerkundung und GIS – Neue Sensoren – innovative Methoden**, Herbert Wichmann Verlag: Heidelberg, 2002, p 42 – 52.
- Tanaka, S; Sugimura, T. A new frontier of remote sensing from IKONOS images. **International Journal of Remote Sensing**. v. 22, n.1, p. 1 – 5. 2001
- Veloso, S. M.; Rangel Filho, A. L. R.; Lima, J. C. A. **Classificação da vegetação brasileira, adaptado a um sistema universal**. [s.l.]: IBEGE, 1991. 123p.