

Classificação orientada a objetos de imagens Spot-5 com a finalidade de mapeamento do uso da terra

Alzir Felipe Buffara Antunes ¹

Naïssa Batista da Luz ²,

1- Eng. Florestal, MSc. Ciências Florestais, Doutoranda do Curso de Pós-Graduação em Ciências Geodésicas da Universidade Federal do Paraná, (naissa@ufpr.br; naissa@gmail.com).

2- Eng. Cartógrafo Prof. Dr. Departamento de Geomática da Universidade Federal do Paraná (felipe@ufpr.br)

Abstract: The object oriented classification approach represents a new paradigm to the high spatial resolution imagery processing. The use of spectral and form properties originated from the segmentation procedure allows better discrimination between objects. Fuzzy membership functions are generated from the segmented objects descriptors. The State of Parana has been currently updating its 1:50.000 land use maps by means of Spot 5 orthorectified imagery. The objective of this paper is to develop a methodology to the elaboration of land use maps by means of multiresolution segmentation techniques and image contextual classification with the aid of fuzzy logic. In order to identify which descriptors could provide better class separability, multivariate statistic, principal components and discriminant analysis techniques were used, as a result potential descriptors were selected. Finally the classification process was achieved using those descriptors to create the fuzzy sets and the membership functions. The Land Use Map generated reached a Kappa index near to 80%, indicating the potential application of this technique nevertheless subsequent methodological adaptation might be implemented.

Palavras Chave: high spatial resolution imagery; object oriented classification; fuzzy logic.

1. INTRODUÇÃO

Os tradicionais classificadores digitais foram desenvolvidos baseados em características do pixel como unidade primitiva de informações a respeito dos alvos, sendo denominados por esta abordagem de classificadores pixel a pixel, sobretudo voltados a imagens de baixa resolução espacial. A melhoria da resolução espacial e espectral trazida com o avanço tecnológico evidenciou a dificuldade de aplicação destes classificadores (BLÄSCHKE & STROBL, 2001). Enquanto em imagens de baixa resolução espacial um único pixel pode armazenar a resposta espectral de mais de um objeto, ou uma área heterogênea de um mesmo objeto, em imagens de alta resolução um pixel possui características espectrais semelhantes às de seus vizinhos, sendo mais puro em termos de mistura espectral (MACHADO & CAETANO, 2002).

Dada a dificuldade de extração de informações a partir de imagens de alta resolução, diversos autores têm adotado com sucesso uma nova abordagem de processamento, na qual a unidade primitiva de processamento não é mais o pixel, e sim objetos compostos por vários pixels, por esta razão denominada, classificação orientada a objetos (BAATZ & SHÄPE 2000; WHITESIDE & AHMAD, 2005; CHUBEY *et. al.*, 2006; ZHONG *et. al.*, 2005; AVCI *et al.* 2006; ARGIALAS & TZOTSOS, 2006; MOELLER & BLÄSCHKE, 2006; EHLERS *et. al.*, 2006; SHIBA & ITAYA, 2006; CHUNYANG, 2005; FRAUMAN & WOLFF, 2005; WILLHAUCK, 2000). Esta nova abordagem pretende aproximar as técnicas de processamento e extração de informações com o raciocínio humano, ou seja, com a forma de pensar e de reconhecer padrões que intuitivamente adotamos ao interpretar uma imagem ou apreciar uma paisagem (BAATZ & SCHÄPE, 2001).

O primeiro passo para que o cérebro humano seja capaz de identificar e separar as informações contidas em uma imagem se dá no reconhecimento da forma dos objetos, sendo posteriormente comparados com padrões já pré-definidos em nossas mentes. Em busca de um

processo capaz de delinear os objetos contidos em uma imagem de alta resolução espacial próximo ao raciocínio humano, criou-se um método de delineamento denominado segmentação multiresolução (ZHONG *et al.*, 2005). A técnica empregada pela segmentação multiresolução realiza o agrupamento de pixels com características espectrais semelhantes, analisando o tamanho do objeto, homogeneidade espectral, homogeneidade espacial e a forma do objeto (CHUBEY *et al.*, 2006).

De acordo com ANTUNES (2003), o conjunto de segmentos que formam os objetos ou feições de uma imagem, pode ser organizado hierarquicamente. Assim as segmentações em diferentes níveis de escala podem ser obtidas pelo agrupamento dos objetos do nível ligeiramente abaixo (WILLHAUCK, 2000) dando origem à terminologia denominada subobjeto e superobjeto. A palavra subobjeto é empregada para indicar que um determinado objeto se encontra em um nível de segmentação mais detalhada, enquanto a expressão superobjeto é utilizada para caracterizar o objeto em um nível mais grosseiro sendo este resultante do agrupamento dos subobjetos. A rede hierárquica permite também que as feições de diferentes escalas possam ser representadas simultaneamente e classificadas umas em relação às outras (KERSTING, 2006).

Após a realização do processo de delineamento dos objetos em uma imagem, a próxima etapa consiste em atribuí-los à determinada classe, através da comparação dos objetos identificados na imagem com padrões anteriormente pré-definidos, realizando assim a classificação dos objetos da imagem considerando-os tematicamente homogêneos, sendo chamada de classificação orientada a objetos (WHITESIDE & AHMAD, 2005).

A classificação orientada a objetos é realizada respeitando a hierarquia da segmentação, porém parte do nível mais grosseiro (superobjeto) para o nível mais detalhado (subobjeto). Durante o processo de classificação dos objetos de uma imagem, dois fatores devem ser considerados: os descritores dos objetos que permitem o processo de diferenciação de cada classe e o classificador a ser utilizado (ZHANG, 2006).

Os descritores empregados para efetuar a caracterização das classes equivalem às aplicações de funções matemáticas que possibilitam revelar os atributos dos objetos da imagem. Dentre as possibilidades de classificação, sobressai-se o classificador que adota a regra *fuzzy* de pertinência para associar os objetos às classes seguindo um raciocínio próximo à lógica humana. Este trabalho tem como objetivo realizar uma avaliação preliminar desta nova abordagem de classificação, aplicado a uma imagem do satélite Spot-5 para uma área no estado do Paraná, adotando-se uma legenda pré-definida para o mapeamento do uso do solo do estado. O mapeamento mencionado vem sendo realizado utilizando-se classificadores tradicionais pixel-a-pixel.

2. ÁREA DE ESTUDO

Para a realização deste trabalho, foram utilizadas imagens do satélite Spot-5, sensor HRS (High Resolution Stereoscopic), obtidas em 26 de maio de 2005 de uma região no interior do estado do Paraná (Figura 1) adquiridas com nível de processamento 1A (ortorretificada com modelo numérico do terreno com curvas equidistantes de 20m). As imagens têm resolução espacial de 5m, sendo que neste trabalho foram utilizadas somente as bandas da região do visível. Adicionalmente às imagens, arquivos digitais contendo informações vetoriais dos rios existentes na área imageada também foram incluídos no processamento, visando à melhor classificação dos leitos e áreas adjacentes a estes.



Figura 1. Localização da área de estudo.

3. MÉTODO E RESULTADOS

3.1 CLASSIFICAÇÃO DA IMAGEM

3.1.1 Rede Semântica e Hierarquia de Classes

O desenvolvimento da hierarquia de classes representando a rede semântica existente entre as mesmas pode ser considerada uma das etapas mais importantes do processo de classificação orientada a objetos. A separabilidade progressiva dos objetos facilita a discriminação entre as classes, permitindo que sejam aplicadas funções fuzzy a pares de classes, permitindo a utilização de descritores mais apropriados a tarefas específicas.

A hierarquia de classes desenvolvida é composta por três níveis hierárquicos, conforme representado na Figura 2, a partir da qual pretende-se representar as relações semânticas entre as classes. Os objetos classificados no Nível 1 são resultantes da última segmentação realizada, gerada com fator de escala 30 em nível de detalhe mais grosseiro. Estes objetos portanto podem ser considerados como super-objetos, aos quais são atribuídas as classes denominadas mãe. Esta estrutura de segmentação tem a característica, portanto, de ser realizada de baixo para cima (*bottom up*), ou seja, de um nível de maior para o menor detalhe (sub-objetos, objetos e super-objetos) e a classificação de cima para baixo (*up bottom*), iniciando-se pelos super-objetos.

A rede semântica desenvolvida é composta por três classes mães, vegetação, não vegetação, e rios, formando um primeiro nível. O fator determinante na adoção destas classes para a classificação dos super-objetos é a existência de grandes diferenças na resposta espectral destes grandes grupos de objetos. O significado semântico desta divisão, no entanto, há que ser considerado. A separação da imagem em áreas com e sem vegetação é uma seqüência de raciocínio que poderia ser de fato adotada por um analista ou especialista no reconhecimento de padrões, independente de sua área de atuação.

Formando o segundo nível tem-se as classes filhas de vegetação e não vegetação, já que a classe rios não tem herdeiros nos demais níveis. Assim, as classes filhas de vegetação seriam vegetação arbórea e vegetação arbustiva e herbácea, e sob a classe de não vegetação tem-se a classe filha composta por áreas urbanas e solos expostos. Finalmente, em um terceiro nível tem-se as classes de solo exposto, área urbana, agricultura e pastagem, floresta em estágio inicial de desenvolvimento, floresta em estágio avançado de desenvolvimento e reflorestamento

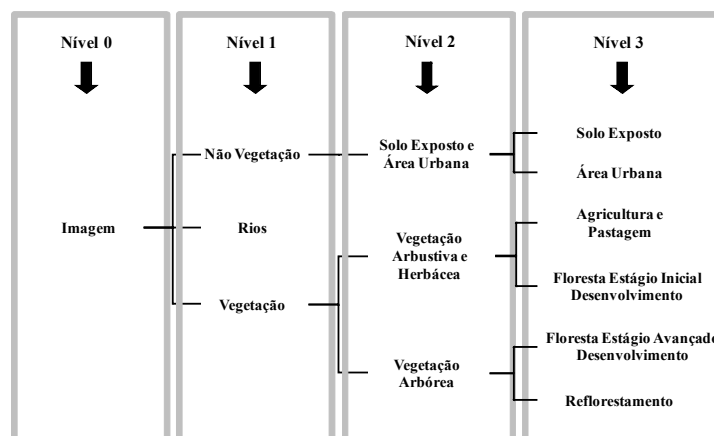


Figura 2. Hierarquia de classes gerada para a classificação da imagem Spot 5 utilizada neste estudo.

3.1.2 Descritores

3.1.2.1 Análise Estatística dos Descritores

Considerando-se a abundância de informação passível de ser extraída das imagens originais através da geração de descritores de forma, padrão, textura e vizinhança dos objetos no software, fez-se necessário a avaliação preliminar das características dos descritores. Optou-se, portanto pela análise estatística dos descritores, visando identificar aqueles que possibilitam maior separabilidade entre as classes, sobretudo aquelas de maior semelhança espectral (como as classes de vegetação, em especial vegetação arbórea). As análises estatísticas multivariadas pelos métodos de componentes principais e de discriminantes auxiliaram na seleção dos melhores descritores para a separabilidade entre as classes.

Dos 360 descritores calculados, incluídos na análise estatística multivariada, foram selecionados os 39 apresentados na, utilizados nas análises visuais dos gráficos de valores dos objetos amostrais para cada descritor, comparando-se os pares de classes. A partir desta análise, foi possível eleger os descritores com maior potencial de separação entre as classes, podendo-se assim elaborar as funções fuzzy a partir daqueles descritores selecionados. Desta forma, diversos testes de classificação foram realizados, visando o ajuste das funções fuzzy de pertinência (Tabela 1).

Na Figura 3, apresentam-se os gráficos gerados a partir da análise de discriminantes, dos descritores que apresentaram melhores resultados na análise estatística multivariada, onde se percebe que alguns descritores têm maior potencial de separabilidade entre as classes

Tabela 1. Alguns descritores selecionados a partir da análise estatística multivariada (componentes principais e análise de discriminantes), e suas estatísticas descritivas (média, desvio padrão, mínimo e máximo).

Descritores*	Estatísticas Descritivas			
	Média	Desvio Padrão	Mínimo	Máximo
Área (excluindo-se polígonos internos) (m ²)	3521,45	3287,18	100,00	44212,50
Área média representada pelos segmentos (m ²)	545,29	339,97	43,18	3049,14
Comprimento de borda(m)	422,72	190,47	40,00	1230,00
Brilho	133,14	63,22	27,77	254,99
Distância à borda da imagem (m)	2672,62	1439,91	0,00	6150,00
Distância a linha (m)	3799,69	2037,69	8,21	7700,31
Comprimento(m)	111,27	49,21	10,00	341,77
Valor máximo dos pixels (1)	123,41	87,50	11,00	255,00
Valor máximo dos pixels (2)	164,31	57,49	32,00	255,00
Valor máximo dos pixels (3)	152,79	66,69	42,00	255,00
Diferença média entre vizinhos (1)	5,31	18,85	-33,25	122,43

Descritores*	Estatísticas Descritivas			
	Média	Desvio Padrão	Mínimo	Máximo
Diferença média entre vizinhos (3)	6,86	21,45	-48,16	133,77
Diferença média entre vizinhos mais claros (3)	8,70	8,92	0,00	89,38
Diferença média entre vizinhos mais escuros (1)	12,37	19,15	0,00	122,43
Diferença média entre vizinhos mais escuros (2)	18,68	20,69	0,00	123,81
Diferença média entre vizinhos mais escuros (3)	15,48	20,84	0,00	149,01
Diferença média absoluta entre vizinhos (1) (m)	13,05	17,78	0,33	122,43
Diferença média absoluta entre vizinhos (2) (m)	19,61	19,78	0,00	123,81
Diferença média absoluta entre vizinhos (3) (m)	16,15	19,33	0,40	133,77
Diferença média com relação à cena (1)	40,88	85,98	-62,71	184,60
Diferença média com relação à cena (3)	34,09	67,17	-74,06	149,43
Média (3)	139,50	67,21	31,51	255,00
Valo mínimo dos pixels (1)	98,55	81,30	4,00	254,00
Valo mínimo dos pixels (3)	124,87	66,46	21,00	255,00
Número de segmentos (1)	9,70	4,04	2,00	28,00
Perímetro do polígono (m)	355,64	157,07	40,00	1040,34
Razão (1)	0,25	0,12	0,03	0,56
Razão (2)	0,40	0,12	0,12	0,64
Razão com relação à cena (1)	1,58	1,22	0,11	3,62
Razão com relação à cena (2)	1,19	0,47	0,16	2,03
Razão com relação à cena (3)	1,32	0,64	0,30	2,42
Borda relative a vizinhos mais claros (3)	0,42	0,31	0,00	1,00
Desvio padrão (1)	5,61	5,86	0,04	44,63
Largura (m)	60,63	26,93	5,00	221,18
Coordenada X do centro (m)	456895,69	17567,77	4412,77	465822,72




Figura 3. As amostras de objetos para as 7 classes consideradas (1-agricultura e pastagens, 2-área urbana, 3-floresta estágio avançado de desenvolvimento, 4-floresta estágio inicial de desenvolvimento, 5-floresta estágio médio de desenvolvimento, 6-reflorestamentos, 7-solo exposto) dos descritores média (banda do verde), brilho, razão (banda do vermelho) e diferença média entre vizinhos com relação à cena (banda do azul).

4. FUNÇÕES FUZZY

A avaliação dos descritores selecionados a partir da análise estatística multivariada permitiu identificar os descritores com maior potencial de separação entre determinadas classes. Como a maior dificuldade de discriminação ocorreu entre pares de classes, este procedimento se demonstrou bastante útil, dada a dificuldade de discriminar classes com resposta espectral semelhante. Conforme se pode observar na Figura 2, o último nível da rede semântica possui seis classes, sendo que de cada uma das três classes mãe do nível imediatamente acima provém duas classes. Assim sendo, pela forma como está estruturada a hierarquia de classes, a maior dificuldade de discriminação entre os objetos se deu entre os pares de classes indicados na Figura 3, optando-se, portanto em criar as funções de pertinência para separar estas classes entre si.




Figura 3. Funções fuzzy geradas a partir dos descritores dos objetos para pares de classes com maior dificuldade de discriminação.

5. CLASSIFICAÇÃO RESULTANTE

A abordagem de classificação do software utilizado neste trabalho permite a utilização dos resultados das segmentações sucessivas nos diversos níveis, com diferentes parâmetros de escala, realizando-se classificações também sucessivas, de forma hierárquica, permitindo-se desta forma que a herança das classes mães (ou seja, os atributos dos objetos e suas classes) sejam repassadas às classes filhas. O resultado do 1º nível de classificação, no qual foram atribuídas classes aos objetos resultantes da segmentação no 3º nível, foi considerado bastante satisfatório, conforme se pode observar na Figura 4. Neste nível, foram separadas as classes de vegetação e não vegetação. Na Tabela 2 apresenta-se a matriz de confusão entre as classes resultante da classificação deste 1º nível de classificação. Conforme pode ser observado, os resultados obtidos para este nível foram bastante satisfatórios, já que não houve confusão entre as classes, permanecendo apenas um único objeto não classificado, resultando numa acurácia Kappa total de 0,99 (de um valor máximo de 1). Ainda que tenham sido utilizadas as amostras de treinamento para a avaliação da acurácia da classificação, deve-se ressaltar que o número de amostras coletadas foi bastante grande, dada a facilidade de realização deste procedimento.

Tabela 2. Resultados da avaliação da acurácia da classificação realizada no nível 1 (objetos de imagem resultantes do nível 3 de segmentação). A avaliação da acurácia foi realizada com base nos objetos selecionados como amostras de treinamento.

Classes	Amostras		
	Vegetação	Não Vegetação	Somatório
Vegetação	967	0	967
Não Vegetação	0	366	366
Não Classificados	0	1	1
Somatório	967	367	
Acurácia total	0.99925		

No nível 2 de classificação, foram separadas 4 classes, havendo ainda pouca confusão entre as classes, fato corroborado pelos resultados apresentados na Tabela 3. . Conforme pode-se observar na referida tabela, a maior confusão ocorreu entre as classes de Vegetação Arbustiva e Herbácea e Vegetação Arbórea. No entanto, ainda foram obtidos resultados considerados satisfatórios, já que os maiores erros de classificação não superaram 10% das amostras selecionadas, e a acurácia total obtida foi de 0,95 (de um valor máximo de 1).

Tabela 3. Avaliação da acurácia da classificação realizada no nível 2 (objetos de imagem resultantes do nível 2 de segmentação). A avaliação da acurácia foi realizada com base nos objetos selecionados como amostras de treinamento.

Classes	Amostras			
	Veg. Arbustiva e Herbácea	Vegetação Arbórea	Solo exposto e Área Urbana	Somatório
Vegetação Arbustiva e Herbácea	784	44	0	828
Vegetação Arbórea	37	450	1	488
Solo exposto e Área Urbana	2	0	394	396
Não Classificados	0	0	1	1
Somatório	823	494	396	
Acurácia total	0,95038			

Finalmente, no nível 3, 7 classes foram utilizadas, havendo neste nível confusão entre as classes espectralmente mais próximas, quer sejam: Reflorestamento e Floresta em Estágio Avançado de Desenvolvimento; Floresta em Estágio Inicial de Desenvolvimento e Agricultura e Pastagens, e finalmente Área Urbana e Solo Exposto. A classificação resultante apresenta maiores erros de classificação, no entanto superando os 10% de amostras erroneamente classificadas entre as classes de Floresta em Estágio Avançado de Desenvolvimento e Reflorestamento e Floresta em Estágio Inicial de Desenvolvimento e Agricultura e Pastagem.

Apenas oito objetos não foram classificados e a acurácia total ainda pode ser considerada satisfatória, resultando em 0,84.

Tabela 4. Avaliação da acurácia da classificação realizada no nível 3 .

Classes	Amostras						Somatório
	1	2	3	4	5	6	
1-Agricultura e Pastagens	211	4	0	0	16	0	231
2-Área Urbana	0	54	8	0	0	0	62
3-Solo Exposto	0	9	82	0	0	0	91
4-Floresta Estágio Avançado Desenvolvimento	0	0	0	211	27	51	289
5-Floresta Estágio Inicial Desenvolvimento	14	0	0	1	87	0	102
6-Reflorestamento	0	0	0	22	1	206	229
Não classificados	2	6	0	0	0	0	8
Somatório	227	73	90	234	131	257	
Acurácia total	0.84091						

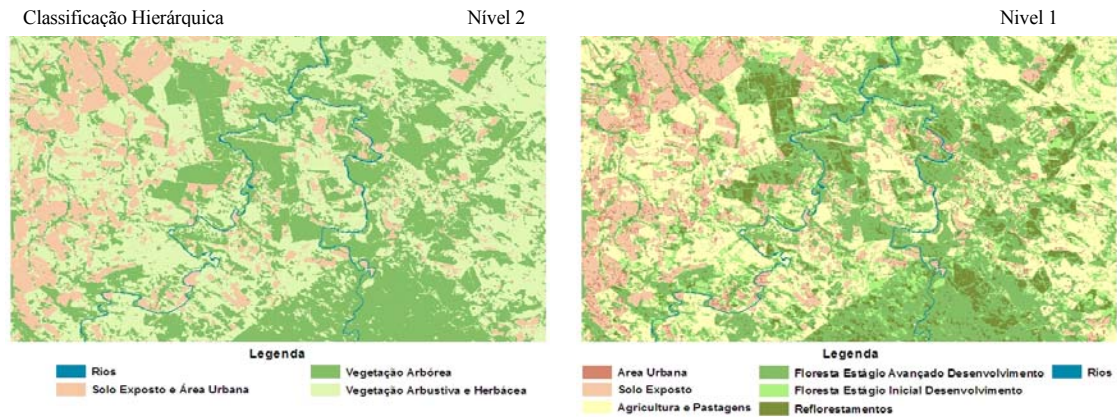


Figura 4: Classificação Resultante dos níveis mais detalhados

6. CONCLUSÕES

A avaliação preliminar da aplicação, não só do método de classificação orientada a objetos mas também de segmentação multiresolução apresentou resultados satisfatórios, pretendendo-se portanto prosseguir no desenvolvimento de uma metodologia para o mapeamento do uso do solo no estado do Paraná.

Pela indisponibilidade da banda do infravermelho neste trabalho, acredita-se que estes resultados podem ser muito melhores, caso esta banda seja incluída. Este fato é corroborado pelo conhecido comportamento espectral bastante diferenciado nesta banda, para os pares de classes acima citados.

As florestas de folhosas apresentam resposta espectral bastante diversa de reflorestamentos, formados por espécies coníferas. Da mesma forma, diferenças na resposta espectral na banda do infravermelho são relatadas em literatura para objetos encontrados em áreas urbanas e solos expostos, bem como diferenças conhecidas em termos espectrais para áreas agrícolas ou pastoris e vegetação arbustiva ou gramínea.

Como próximos desenvolvimentos, esta técnica de classificação deve ser comparada com a de classificação pixel-a-pixel atualmente adotada pelo projeto que desenvolve o mapeamento do uso do solo do estado do Paraná, bem como classificações padrão realizadas através da interpretação visual da imagem.

De forma específica, pode-se dizer, a respeito desta abordagem de extração de informações a partir de imagens de alta resolução, que :

- o processo de segmentação multiresolução demonstrou-se bastante útil na obtenção de objetos significativos a partir de imagens de alta resolução espacial, diferentemente dos resultados obtidos tradicionalmente com métodos de classificação pixel-a-pixel;
- este processo também permitiu a obtenção de resultados finais mais promissores, permitindo o melhor delineamento dos polígonos posteriormente classificados;
- a classificação orientada a objetos apresenta-se mais eficaz do que os métodos de classificação tradicionais, graças à utilização de objetos como unidade de análise e processamento, à possibilidade de inserção do conhecimento através da rede semântica e do uso dos descritores dos objetos aliado à lógica fuzzy para a melhoria da classificação.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- ANTUNES, A. F. B. **Classificação de ambiente ciliar baseada em orientação a objeto em imagens de alta resolução espacial**. 2003. 147f. Tese (Doutorado em Ciências Geodésicas) - Universidade Federal do Paraná, UFPR, Curitiba, 2003.
- ARGIALAS, D. & TZOTSOS, A. Automatic extraction of physiographic features and alluvial Fans in Nevada, USA from digital elevation models and satellite imagery through multiresolution segmentation and object-oriented classification. In: Proceedings of the American Society for Photogrammetry and Remote Sensing (ASPRS) Annual Conference, 2006, Reno, Nevada. **Proceedings** ... p. 150.
- BAATZ, M & SCHÄPE, A. **Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation**. München. Disponível em <www.definiens.com> Acesso em julho 2007.
- BARROS, L. C. Sobre Conjuntos Fuzzy. **Revista do Professor de Matemática**, São Paulo, v. 56, p. 2-9, 2005.
- BLÄSCHKE, T. & STROBL, J. **What's wrong with pixels? Somerecent deselopments interfacing remote sensing and GIS**. 2001. Disponível em: <http://www.definiens.com>. Acesso em julho de 2007.
- CHUBEY, M. S.; FRANKLIN, S. E.; WULDER, M. A. Object-based analysis of Ikonos-2 imagery for extraction of forest inventory parameters. **Photogrammetric Engineering & Remote Sensing**, v. 72, n. 4, p. 383-394, 2006.
- CHUNYANG, H., LI, J.; ZHANG, J.; PAN, Y.; CHEN, Y. H. Dynamic monitor on urban expansion based on a object-oriented approach. In: Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS'2005), Julho 2005, Seoul, Korea. **Proceedings**... p. 25-29.
- EHLERS, M., U. MICHEL, G. B., TOMOWSKI, D. Decision based data fusion techniques for the analysis of settlement areas from multisensor satellite data. In: Proceedings of the American Society for Photogrammetry and Remote Sensing (ASPRS) 2006 Annual Conference, May 2006, Reno, Nevada. **Proceedings**... p.150.
- FRAUMAN, E. & WOLFF, E. Segmentation of very high spatial resolution satellite images in urban areas for segments-based classification. In: International Society for Photogrammetry and Remote Sensing (ISPRS) 3rd International Symposium Remote Sensing and Data Fusion Over Urban Areas (URBAN 2005) and 5th International Symposium Remote Sensing of Urban Areas (URS 2005), March Tempe, AZ, USA. **Proceedings**... p.14 - 16.
- MOELLER, M. S. & T. BLASCHKE, T. A new index for the differentiation of vegetation fractions in urban neighbourhoods based on satellite imagery. In: Proceedings of the American Society for Photogrammetry and Remote Sensing (ASPRS) Annual Conference, 2006, Reno, Nevada. **Proceedings** ... p. 150.
- RUHOFF, A. L.; SOUZA, B. S. P.; GIOTTO, E.; PEREIRA, R. S. *Lógica Fuzzy e Zoneamento ambiental da Bacia do Arroio Grande*. In: Simpósio Brasileiro de Sensoriamento Remoto, 12, 2005, Goiânia. **Resumos**... São José dos Campos, S.P.: Instituto Nacional de Pesquisas Espaciais (INPE), 2005. p. 4568 p. 2355-2362.
- SHIBA, M. & ITAYA, A.: Using eCognition for improved forest management and monitoring systems in precision forestry. In: International Precision Forestry Symposium, March 2006, Stellenbosch, South Africa. **Proceedings**... p.351-359.
- WHITESIDE, T. & AHMAD, W. A comparison of object-riented and pixel based classification methods for mapping land cover in North Australia. In Spatial Science Institute Biennial Conference SSC2005. Spatial Intelligence, Innovation and praxis, 2005, Melbourne, Australia. **Proceedings**...
- WILLHAUCK, G.; SCHNEIDER, T.; DE KOK, R.; AMMER, U. Comparison of object oriented classification techniques and standard image analysis for the use of change detection between SPOT multispectral satellite images and aerial photos. In: Congress of the International Society for Photogrammetry and Remote Sensing, 19, 2000, Amsterdam, Holanda. **Proceedings**...CD-room.
- HANG, Y. A fuzzy logic approach to supervised segmentation for object-oriented classification. In: Proceedings of the American Society for Photogrammetry and Remote Sensing (ASPRS) Annual Conference, 2006, Reno, Nevada. **Proceedings** ... p. 150.
- ZHONG, C.; ZHONGMIN, Z.; DONGMEI, Y.; RENXI, C. **Multi-scale segmentation of the high resolution remote sensing image**, 2005. Disponível em: <<http://ieeexplore.ieee.org/iel5/10226/32599/01526648.pdf?arnumber=1526648>>. Acesso em: 02 jul. 2007.