

Classificação da cobertura do solo urbano usando imagens ópticas de altíssima resolução e o sistema InterIMAGE baseado em conhecimento

Hermann Johann Heinrich Kux¹
Tessio Novack¹
Rodrigo Ferreira²
Dario Augusto Oliveira²
Bárbara Maria Giacom Ribeiro¹

¹INPE - DSR - Divisão de Sensoriamento Remoto
Av. dos Astronautas, nº 1.758, Jardim da Granja - CEP: 12.227-010
São José dos Campos - SP, Brasil
{hermann, tessio, barbara}@dsr.inpe.br

²PUC-RIO - Departamento de Engenharia Elétrica,
Rua Marquês de São Vicente, nº 225, Gávea - Rio de Janeiro – RJ, Brasil
Caixa Postal: 38097 - CEP: 22.451-900
{rodrigo, dario}@ele.puc-rio.br

Abstract: This study uses the InterIMAGE system and imagery from the QuickBird II optical sensor for the classification of the land cover of two test-sites in the metropolis of São Paulo, Brazil. InterIMAGE is an open source and free access framework for knowledge-based image classification. Within InterIMAGE human knowledge is represented as a semantic net and by user-defined rules based on the paradigms of object-oriented image analysis. The Segmentation Parameter Tuner system was used to search for appropriate segmentation parameters. This system uses a genetic algorithm for the optimization of parameters. For the description of the land cover classes in terms of features and thresholds, a strategy combining a hierarchical structure of classes and the decision tree algorithm C4.5 was elaborated. The classification model was then formatted according to InterIMAGE's image analysis strategy. The proposed methodology is efficient for the automatic mapping of the land cover in complex urban areas. The final classification achieved an overall accuracy of 73% and a *Kappa* Accuracy Index of 0.69. This study has explored the main functionalities of InterIMAGE, presenting its potentialities for object- and knowledge-based image classification.

Palavras-chave: InterIMAGE, QuickBird-2, Land cover, Urban planning, InterIMAGE, QuickBird-2, Cobertura do solo, Planejamento urbano.

1. Introdução

De acordo com a Organização das Nações Unidas (ONU), atualmente mais da metade da população mundial mora em áreas urbanas e em torno de 2050 serão 70% (UN-HABITAT, 2009), prevendo-se um crescimento absoluto e relativo da população, especialmente em países em desenvolvimento. Tais países apresentam um crescimento urbano caótico com graves problemas como violência, poluição sonora e visual, diminuição da qualidade de vida, aumento de doenças ligadas à poluição do ar, etc. A mitigação e solução destes problemas envolve políticas de planejamento urbano eficientes com base em informação espacial atualizada e confiável.

Conjuntos de dados de sensoriamento remoto podem fornecer informações valiosas sobre coberturas do solo urbano. Segundo Jensen (2007), para a classificação de uso e cobertura do solo urbano nos níveis 3º e 4º do USGS são necessárias imagens multi-espectrais de sensoriamento remoto, com uma resolução temporal de pelo menos 3 a 5 anos e resolução espacial superior a 5 metros (< 5m). Na década passada diversos sistemas sensores orbitais com estas características foram lançados (Ehlers, 2007). A grande disponibilidade de dados exige agora metodologias adequadas (mais precisas, padronizadas e rápidas) para a extração de informações. A classificação de imagens

baseada em objeto e em conhecimento é no momento o enfoque mais vantajoso para a análise de imagens de alta resolução espacial para aplicações em planejamento urbano.

Neste contexto, o objetivo deste trabalho é apresentar um modelo de classificação de uso do solo urbano usando o sistema InterIMAGE (InterIMAGE, 2010) e imagens do sensor *QuickBird-2* (DigitalGlobe 2008). InterIMAGE é um sistema de classificação de livre acesso e fonte aberta, cujo conceito de análise de imagem é bastante flexível, com grande potencial para a interpretação automática de imagens de sensoriamento remoto (InterIMAGE, 2010).

1.1 O sistema InterIMAGE

A concepção de análise de imagem do InterIMAGE (2010) baseia-se num modelo de conhecimento estruturado anteriormente, denominado GeoAIDA, desenvolvido na Universidade Leibniz em Hannover (Alemanha) (Bückner et al., 2001; Pahl, 2008). A estratégia de classificação implementada pelo InterIMAGE baseia-se num modelo de conhecimento estruturado como uma rede semântica definida pelo usuário, apresentando dois passos, a saber *Top-Down* (TD) e *Bottom-Up* (BU).

No passo TD, a análise de imagem desce pela rede semântica disparando os assim chamados operadores holísticos. Trata-se de operadores de processamento de imagem, externos ao núcleo do sistema, especializados na detecção de uma classe. Cada nó da rede semântica pode ou não conter um operador holístico, que podem ser desenvolvido por qualquer usuário com capacidade de programação. Para a detecção de objetos de uma certa classe, operadores holísticos geralmente executam 3 procedimentos, na seguinte ordem: (1) segmentação (ou importação de dados SIG); (2) extração de atributos e (3) classificação. As regiões geográficas, detectadas por um operador holístico inserido num dado nó, são transmitidas como máscaras (hipóteses) a seus nós filhos no nível inferior da rede semântica, onde seus próprios operadores holísticos trabalharão. Atualmente o usuário pode elaborar um operador holístico considerando: (1) um dos dois algoritmos de segmentação disponíveis no sistema, a saber: aqueles desenvolvidos por Baatz & Schäpe (2000) e Bins et al. (1996); (2) feições espectrais, texturais e geométricas e (3) regras de classificação usando diferentes operadores booleanos estruturados, se necessário, hierarquicamente.

No passo BU, o sistema sobe na rede semântica, resolvendo conflitos espaciais entre hipóteses baseadas em regras definidas pelo usuário, inseridas em cada nó que não seja um nó folha. Procedendo desta maneira, o sistema descarta parcial- ou totalmente as hipóteses ou transforma-as em instâncias (isto é válido as hipóteses). As regras definidas pelo usuário podem ou não envolver seleções lógicas adicionais. Se após o descarte de hipóteses, posteriormente às seleções lógicas, ainda houver conflitos espaciais, estes serão resolvidos ou pela definição supervisionada de prioridade para as classes ou pela competição de valores de pertinência dados pelas funções de pertinência *fuzzy* definidas pelo usuário. As regras do BU são customizadas numa interface amigável, que permite o desenvolvimento de uma complexa descrição de classes e critérios de julgamento de hipóteses.

2. Áreas-teste e métodos

As áreas-testes para a aplicação da metodologia são dois bairros do município de São Paulo: uma área residencial de alto padrão com dois tipos de uso do solo: horizontal e vertical. Os alvos mais comuns nesta área são: cobertura de árvores e gramíneas, telhas de cerâmica, piscinas e prédios de concreto pintados de branco. A segunda área-teste é uma região industrial e residencial contendo solos nus, telhados de cerâmica, diferentes tipos de telhados de asbesto e de pavimentos.

A classificação de cobertura do solo em ambas as áreas-teste foi efetuada, combinando-se redes semânticas para a representação do conhecimento humano e algoritmos para aprendizado da máquina, para a pesquisa de parâmetros de segmentação e definição de regras de classificação. Esta combinação serve para minimizar a intervenção do usuário na coleta de amostras para cada classe de cobertura da terra e para organizar as redes semânticas.

2.1 Pesquisa e definição de parâmetros de segmentação

O algoritmo desenvolvido por Baatz & Schäpe (2000) foi usado para a segmentação de imagens, considerando dois conjuntos de parâmetros para a segmentação: 1^o para áreas vegetadas (denominado CP 1) e 2^o para telhados de tamanho médio a pequeno (denominado CP 2) (Tabela 1).

Tabela 1 – Conjunto de parâmetros aplicados na segmentação de objetos de uso do solo.

Parâmetros	Conjuntos de parâmetros (CP)	
	CP 1	CP 2
Escala	21	41
Forma	0.25	0.84
Compacidade	0.61	0.8
Pesos das bandas(B1, B2, B3, B4)	0.24, 0.07, 0.42, 0.26	1,1,1,1

Considerando que a relação entre os conjuntos de parâmetros e os segmentos gerados pelo algoritmo não é intuitiva, sempre é necessária uma calibração dos parâmetros. Ao invés de se usar um processo de tentativa e erro bastante demorado, o Otimizador de Parâmetros de Segmentação (SPT: *Segmentation Parameter Tuner*) Costa et al. (2008) foi usado para esta finalidade. O SPT usa um algoritmo genético para pesquisar o conjunto de parâmetros otimizado, baseado na aptidão das amostras obtidas pelo usuário na imagem e nos segmentos gerados pelo algoritmo. O conjunto de parâmetros que gera os segmentos mais ajustados às amostras é recomendado pelo SPT como o melhor conjunto quando o processo de pesquisa termina. A medida de ajuste usada foi o Segmento individual mais próximo da referência (*Reference Bounded Segment Booster (RBSB)*). Costa et al. (2008) fornecem uma explicação detalhada de como a calibração de parâmetros usando o sistema SPT trabalha, bem como sobre o cálculo da medida de ajuste RBSB. O SPT pode ser baixado pela Internet e brevemente será integrado ao InterIMAGE.

2.2 Descrição das classes de cobertura

De modo similar à calibração dos parâmetros de segmentação, a descrição das classes em termos de feições e limiares foi obtida automaticamente. Inicialmente os segmentos gerados no SPT foram importados para o *Definiens Developer System* (Definiens 2007) e 45 amostras de cada classe de cobertura do solo foram coletadas e exportadas, junto com 96 feições espectrais, geométricas e texturais. As amostras foram então organizadas de acordo com a rede hierárquica apresentada na Figura 1.

A rede hierárquica serviu como estratégia para obter a descrição das classes de cobertura do solo através de uma série de sub-classificações no processo TD. Inicialmente todas as amostras foram agrupadas como pertencentes ou à classe “Sombra” ou “Não-sombra” e então as amostras de “Não-sombra” foram divididas nos grupos “Vegetação” e “Não-vegetação”, etc. Cada uma dessas sub-classificações foi então derivada usando o algoritmo da árvore de decisão C4.5 (Quinlan, 1993).

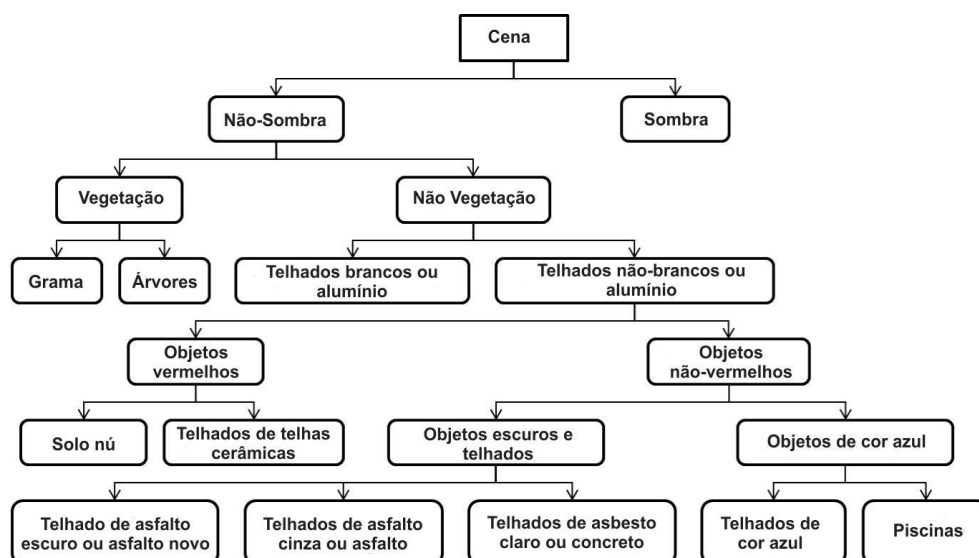


Figura 1. Rede hierárquica usada como estratégia para obtenção da descrição de classes de cobertura do solo.

Este algoritmo fornece, numa estrutura hierárquica, as feições e limiares que melhor separam as amostras de diferentes classes baseadas na heurística de redução da entropia. Simultaneamente a esta tarefa, o Filtro Baseado em Correlação Rápida (FCBF, vide Yu & Liu, 2003), um algoritmo de seleção de feições, foi usado para extrair feições que melhor separem as amostras que pertençam a nós folha da rede hierárquica, ou seja das classes de interesse. As distribuições de frequência das amostras concernentes às duas feições que foram melhor ranqueadas pelo algoritmo FCBF foram consideradas para a definição da forma, das funções de pertinência associadas a estas feições. O FCBF também foi usado para a seleção das feições para ativar a árvore de decisão. Novack & Kux (2009) observaram que a redução da dimensionalidade causa um aumento da precisão da árvore de decisão e reduz o seu tamanho. Desta forma foram obtidos o conjunto de seleções lógicas (dadas pelas árvores de decisão) e as funções de pertinência que descrevem as classes de cobertura da terra de interesse. Por exemplo, a descrição da classe “Gramma” compõe-se das regras fornecidas pelas árvores de decisão para a classificação de “Não-sombra” e “Vegetação”, bem como as duas funções de pertinência que foram melhor consideradas pelo algoritmo FCBF para a separação de “Gramma” e “Árvores”. Portanto a descrição da classe “Árvores” apresenta as mesmas regras e feições de “Gramma”, porém as funções de pertinência são diferentes apesar de estarem associadas às mesmas feições. O mesmo processo foi aplicado para obter a descrição das demais classes. Na descrição destas classes foi aplicado o operador “Mínimo” para a agregação dos valores de pertinência retornados pelas funções associadas às duas feições melhor ranqueadas pelo algoritmo FCBF. Todas as feições usadas nas descrições de classe de cobertura do solo foram então implementadas no InterIMAGE, para a aplicação do modelo.

2.3 Formatando o modelo de classificação de cobertura da terra

Como o sistema InterIMAGE usa uma estratégia de análise de dois passos foi elaborada a nova rede semântica (Figura. 2), onde as expressões de classe estão organizadas e estruturadas para a geração de hipóteses no passo TD e a resolução de conflitos espaciais entre estas hipóteses no passo BU. O objetivo aqui é explorar o potencial da estratégia de análise dos 2 passos, numa rede semanticamente mais coerente e computacionalmente menos cara.

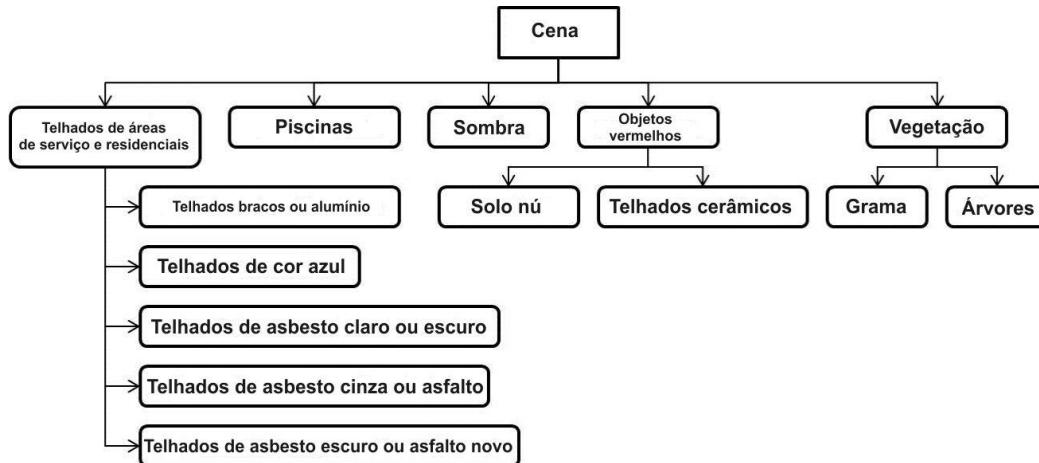


Figura 2. Rede semântica elaborada no sistema InterIMAGE para a classificação da cobertura do solo.

No passo TD, o operador *Dummy Top Down* foi inserido nos nós “Telhados de áreas de serviço e residenciais”, “Objetos vermelhos” e “Vegetação”. Este operador somente passa para os nós filho as máscaras que recebeu do seu nó-pai, que neste caso é a imagem inteira. O nó “Piscinas” segmenta somente as imagens usando o conjunto de parâmetros CP 2 (Tabela 1) e o nó “Sombra” seleciona os pixels de uma imagem de brilho (soma das 4 bandas espectrais dividido por 4) com números digitais abaixo de 200. No terceiro nível da rede semântica, os nós “Gramma” e “Árvores” executam a segmentação da imagem aplicando o CP 1 (Tabela 1), bem como a seleção lógica fornecida pelo algoritmo C4.5 para a separação das classes “Vegetação” e “Não-vegetação”. Os mesmos procedimentos são executados nos nós “Solo nu” e “Telhados cerâmicos”, exceto que o conjunto de parâmetros de segmentação é o CP 2 e a seleção lógica é dada pelo algoritmo C4.5 para a separação entre “Objetos vermelhos” e “Objetos não-vermelhos”. Para os nós filho de “Telhados de áreas de serviço e residenciais”, foram aplicados os CP 2. No que se refere às seleções lógicas, aplicaram-se, para a classe “Telhados claros ou alumínio”, aqueles parâmetros dados pelo C4.5 para discriminar tais telhados de “Telhados não-claros ou concreto”, “Telhados de asbesto cinza ou asfalto” e “Telhados de asbesto escuro ou asfalto novo”, as seleções lógicas usadas para a separação de “Objetos escuros e telhados” e “Objetos de cor azul”. O nó “Telhados de cor azul” executa a segmentação da imagem usando o CP 2 bem como as seleções lógicas opostas a aquelas aplicadas para a discriminação das classes “Telhados brancos ou alumínio”, “Telhados de áreas de serviço e residenciais” e “Piscinas” na rede hierárquica mostrada na Figura 2. No passo BU, a regra de decisão no nó “Telhados de áreas de serviço e residenciais” resolve os conflitos espaciais entre as hipóteses dos seus nós filho como segue. As hipóteses da classe “Telhados claros ou alumínio” ganha em todos os conflitos espaciais e as hipóteses da classe “Telhados de cor azul” perde em todos estes conflitos. A solução de conflitos espaciais entre as hipóteses das classes “Telhados de asbesto claro ou concreto”, “Telhados de asbesto cinza ou asfalto” e “Telhados de asbesto escuro ou asfalto novo” é completada pela competição dos valores de pertinência dados pelas funções de pertinência associadas às duas feições melhor ranqueadas pelo algoritmo FCBF. As regras de decisão BU nos nós “Objetos vermelhos” e “Vegetação” também resolvem os conflitos espaciais entre as hipóteses dos seus nós filho usando as funções de pertinência associadas às feições selecionadas pelo algoritmo FCBF. Finalmente os conflitos espaciais restantes entre as hipóteses das classes “Telhados de áreas de serviço e residenciais”, “Piscinas”,

“Sombra”, “Objetos vermelhos” e “Vegetação” são resolvidos de acordo com uma ordem de prioridade. A classe “Sombra” ganha todos os conflitos espaciais seguida pelas classes “Vegetação”, “Objetos vermelhos”, “Telhados de áreas de serviço e residenciais” e “Piscinas”.

3. Resultados e discussão

Para a avaliação da precisão das classificações de cobertura do solo, o seguinte procedimento foi seguido. Inicialmente amostras de cada classe de cobertura do solo foram obtidas visualmente a partir da imagem. A maioria dos objetos cuja classe de cobertura do solo pôde ser nitidamente identificada foi amostrada. A seguir a camada vetorial contendo estas amostras foi convertida numa camada *raster* e o mapa de referencia resultante foi comparado pixel a pixel com as classificações obtidas. A Figura 3 mostra as classificações de cobertura do solo em seções das duas áreas-teste.



Figura 3. Composições coloridas (a e c) e classificações de cobertura do solo (b e d).

A Tabela 2 apresenta a matriz de confusão de ambas as classificações. Obteve-se uma precisão global de 73% e um índice *Kappa* de 0,69 (Congalton & Green, 1999). Tais valores são satisfatórios e corroboram a avaliação visual. Com poucas exceções, todas as classes mencionadas obtiveram boas a muito boas Precisões do Usuário e do Produtor. As áreas com vegetação foram bem mapeadas se considerarmos que a maioria dos erros de omissão da classe “Árvores” foi considerada como “Grama”. Por outro lado 7% das áreas amostradas como “Solo nu” foram erroneamente classificadas como “Grama”, o que diminuiu a Precisão do Usuário para 69%, junto com os erros de comissão em “Árvores” mencionados. De fato há muitas áreas na imagem onde a grama é esparsa, tornando-se uma área de transição para Solo nu. Com relação à confusão entre “Árvores” e “Grama”, isto depende da sua posição com relação ao sol, visto que algumas partes do dossel aparecem num tom mais brilhante de verde, similar às áreas cobertas por grama.

Tabela 2 – Matriz de Confusão e Precisão do Usuário e Produtor por classe.

Classes	Árvores (AR)	Grama (GR)	Telhados Brilhantes (TB)	Telhados de asfalto cinza ou asfalto (TACA)	Telhados de asfalto claro ou concreto (TACC)	Telhados de asfalto escuro ou asfalto novo (TAEA)	Sombra (S)	Piscinas (P)	Telhados de telha cerâmica (TTC)	Telhados de cor azul (TCA)	Solo nu (SN)	Total (T)
AR	2950	28	0	63	0	92	0	0	8	0	0	3141
GR	1084	17136	0	16	0	23	0	3	0	0	1820	20082
TB	0	0	2780	0	0	0	0	0	0	38	659	3477
TACA	14	761	26	3064	266	572	0	27	122	6	452	5310
TACC	0	2	1237	94	9554	15	0	71	198	388	12412	23971
TAEA	154	165	0	881	0	6033	96	3	129	133	87	7681
S	11	0	0	9	0	9	7328	0	0	2	0	7359
P	0	0	158	0	0	0	0	1308	0	221	0	1687
TTC	9	0	0	0	0	3	0	0	9034	0	2899	11945
TCA	0	0	0	0	114	0	0	99	0	9654	0	9867
SN	0	0	0	0	0	0	0	0	1935	0	6167	8102
Total	4222	18092	4201	4127	9934	6747	7424	1511	11426	10442	24496	102622
Precisão do usuário	0.94	0.85	0.80	0.58	0.40	0.79	1.00	0.78	0.76	0.98	0.76	
Precisão do produtor	0.70	0.95	0.66	0.74	0.96	0.89	0.99	0.87	0.79	0.92	0.25	

As classes “Telhados de asbesto ou asfalto”, “Telhados de asbesto claro ou concreto” e “Telhados de asbesto escuro ou asfalto novo” apresentaram principalmente erros de comissão e omissão entre si e com a classe “Telhados brilhantes”. Isto é explicável pelo fato de que não foi possível definir um critério claro e objetivo para a distinção entre estas classes, especialmente devido a diferentes condições de preservação e de ângulos de inclinação de áreas pavimentadas e telhados. Isto diminuiu os índices de precisão destas classes. Na classe “Sombra” houve tão-somente poucos erros de comissão com “Árvores” e “Telhados de asbesto” e uma pequena porcentagem (1,2%) de amostras desta classe foram erroneamente classificadas como “Telhados de asbesto escuros ou asfalto novo”, que é a segunda classe menos refletora considerada neste trabalho. Outra confusão de classificação a ser mencionada é aquela entre “Telhados de cerâmica” e “Solos nus”. Ambas as classes possuem uma composição química muito semelhante sendo que Kux & Araújo (2008) e Novack (2009) já mencionaram as características espectrais semelhantes destas duas classes ao trabalharem com imagens multi-espectrais com alta resolução espacial. Conforme mostrado na Tabela 2, quase 22% das amostras coletadas para “Telhados de cerâmica” foram erroneamente classificadas como “Solo nu” e todos os erros de comissão desta classe foram atribuídos a classe anteriormente mencionada.

4. Conclusões e observações finais

InterIMAGE executou complexas classificações de cobertura do solo em duas áreas-testes urbanas diferentes e complexas usando feições espectrais e geométricas calculadas tanto no passo TD e nas regras BU. Suas funcionalidades tornaram esta aplicação possível. A classificação de cobertura do solo obteve muito bons índices de precisão e foi qualitativamente avaliada como muito boa. Sua limitação é o modesto número de segmentos que pode processar, o que determina diretamente o limite do tamanho da imagem. Esta restrição, no entanto, está sendo superada. Os resultados parciais apresentados neste estudo demonstram que o sistema InterIMAGE pode ser usado por agências de planejamento urbano de modo rápido e padronizado sem custos para licenças de software. Em trabalhos futuros, feições topológicas recentemente implementadas no InterIMAGE podem ser exploradas e o modelo será testado em áreas mais extensas para a avaliação da sua estabilidade da precisão.

5. Referencias bibliográficas

Baatz, M.; Schäpe, A. 2000. Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. In: Strobl, J., Blaschke, T. *Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGIT Symposium Salzburg 2000*, Herbert Wichmann Verlag, Karlsruhe.

Bins, S.A., Fonseca, L. M. G., Erthal, G. J., 1996. Satellite Imagery segmentation: a region growing approach, *Proceedings of the VIII Simpósio Brasileiro de Sensoriamento Remoto (SBSR)*, Salvador, Brazil, pp. 677-680.

Bückner, J.; Stahlhut, O., Pahl, M., Liedtke., C. E., 2001. GEOAIDA - A knowledge based automatic image data analyzer for remote sensing data. *Proceedings of the II International ICSC Congress on Computational Intelligence: Methods & Applications*, Millet, Alberta: ICSC, Bangor, Wales, United Kingdom.

Congalton, R.G., Green, K., 1999. *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices*, Lewis Publishers, New York.

Costa, G. A. O. P.; Feitosa, R. Q.; Cazes, T. B.; Feijó, B., 2008. Genetic adaptation of segmentation parameters. In: Blaschke, T.; Lang, S.; Hay, G.F. (Eds) *Object-Based Image Analysis – Spatial Concepts for Knowledge-Driven Remote Sensing Applications*, Springer Verlag, Berlin, Germany, pp. 679-695.

Definiens, 2007. Definiens Developer User Guide. <http://www.definiens-imaging.com/down/ecognition>

DigitalGlobe, 2008. QuickBird Imagery Products – Products Guide. <http://www.digitalglobe.com> (acessado em 23.04.08)

InterIMAGE, 2010. InterIMAGE – Interpreting Images Freely. <http://www.lvc.ele.puc-rio.br/projects/interimage/> (acessado em 03.01.10).

Jensen, J. R., 2009. *Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres*. Parêntese Editora, São José dos Campos, 599 p.

Kux, H.J.H.; Araújo, E.H.G., 2008. Object-based image analysis using Quickbird satellite images and GIS data, case study Belo Horizonte (Brazil). In: Blaschke, T.; Lang, S.; Hay, G.F. (Eds) *Object-Based Image Analysis – Spatial Concepts for Knowledge-Driven Remote Sensing Applications*, Springer Verlag, Berlin, Germany, pp 571-588.

Novack, T., Kux, H. J. H., 2009. Classificação da cobertura do solo urbano inserindo árvores de decisão a rede hierárquica. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto (SBSR), Natal, Brasil. Disponível em: <http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.17.17.11> (acessado em 03.01.10).

Novack, T., 2009. *Classificação da cobertura da terra e do uso do solo urbano utilizando o sistema InterIMAGE e imagens do sensor QuickBird*. Dissertação de Mestrado, INPE (Brasil). <http://mtc-m18.sid.inpe.br/rep/sid.inpe.br/mtc-m18@80/2009/08.31.21.23>. (acessado em 03.01.10).

Pahl, M. Arquitetura de um sistema baseado em conhecimento para a interpretação de dados de sensoriamento remoto de múltiplos sensores. Tese de Doutorado Leibniz Universität Hannover (Alemanha) 2003. Versão para o português Kux, H.J.H. (INPE) e Feitosa, R.Q. (PUC-Rio), 2008. disponível em: <http://www.lvc.ele.puc-rio.br/projects/interimage/documentation/files/Martin%20Pahl%20Thesis.pdf>

Quinlan, J.R. 1993. *C4.5: Programs for Machine Learning*, Morgan Kaufmann, San Francisco.

SPT.,2008. *Segmentation Parameter Tuner*. Lab. de Visão Computacional (LVC) da PUC-Rio. www.lvc.ele.puc-rio.br. (Acessado em 23.04.2010).

UN-HABITAT, 2009. *Global Report on Human Settlements 2009: Planning Sustainable Cities*, Abridged Edition, ISBN: 9781844078998.

Yu, L.; Liu, H., 2003 Feature selection for high-dimensional data: a fast correlation-based filter solution. *Proceedings of the XX International Conference on Machine Learning*, Washington DC, United States.