

# Avaliação Comparativa entre Classificação Supervisionada por Regiões e Orientada a Objeto para Imagens de Alta Resolução Espacial: Cbers 2B-HRC e QuickBird

Fernando Leonardi<sup>1</sup>  
Cláudia Maria de Almeida<sup>1</sup>  
Leila Maria Garcia Fonseca<sup>1</sup>  
Flávio Fortes Camargo<sup>1</sup>

<sup>1</sup> Instituto Nacional de Pesquisas Espaciais - INPE  
Caixa Postal 515 - 12245-970 - São José dos Campos - SP, Brasil  
{leonardi, almeida, fortes}@dsr.inpe.br; leila@dpi.inpe.br

**Abstract.** In face of the increasing number of new orbital sensors of high spatial resolution currently available, the demand for robust classification methods has accordingly increased. Object-based analysis relies on cognitive approaches, which seek to emulate the contextual vision of the human interpreter in a virtual environment. In this sense, this paper is committed to comparatively evaluate a conventional supervised region-based classification and an object-based method for the extraction of intra-urban land cover targets in Mauá city, São Paulo State, Brazil. For this end, a fused QuickBird and a fused Cbers 2B image were used. The region-based classification was executed in Spring 5.0 (System for Georeferencing Information Process) and the object-based analysis was accomplished in the platform Definiens Developer 7.0. The results show promising possibilities for the application of object-based analysis to the classification of remote sensing images.

**Palavras-chave:** remote sensing, object-based analysis, image classification, sensoriamento remoto, análise orientada a objeto, classificação de imagem.

## 1. Introdução

Uma das fontes mais tradicionais de dados para a confecção de mapas de uso e cobertura do solo são as imagens orbitais de sensoriamento remoto. No entanto, as imagens disponíveis até meados da década de 1990 não possuíam resolução espacial suficiente para discriminar os alvos dentro do ambiente intra-urbano. Desta forma, estudos detalhados sobre o ambiente intra-urbano só possuíam como fonte de dados de sensoriamento remoto as fotografias aéreas, as quais possuem alta resolução espacial (PINHO, 2005).

A extração de informações destas imagens para a geração de mapas de uso e cobertura do solo pode ser realizada por meio de procedimentos de interpretação visual ou por métodos de classificação automática de imagens. No contexto de mapeamento do uso e cobertura do solo de uma cidade inteira, a adoção da interpretação visual torna o procedimento demorado e caro, visto que mobiliza uma grande quantidade de mão-de-obra especializada. A utilização de técnicas automáticas para a extração de informações é, portanto, uma opção viável para a classificação de uso e cobertura do solo intra-urbano em larga escala (PINHO, 2005).

Sendo assim, este trabalho tem por objetivo comparar a classificação de duas imagens por dois diferentes métodos de classificação. No referido trabalho, duas imagens são analisadas: (1) imagem QuickBird fusionada pelo método pansharpening, com resolução espacial de 0,6 m e (2) imagens Cbers 2B CCD-HRC fusionada pelo método pansharpening, com resolução espacial de 2,7 m, processada por Leonardi et al. (2008).

Com o intuito de investigar o desempenho dos diferentes métodos de classificação, propôs-se a realização de classificação supervisionada por regiões (Bhattacharya), utilizando o *software* Spring 5.0 (Sistema para Processamento de Informações Georeferenciadas), e a classificação orientada a objeto, por meio da plataforma *Definiens Developer 7.0*.

Neste contexto, as classificações são realizadas para verificar qual método teria o melhor desempenho quanto à classificação de detalhes e coerência condizente com a realidade. Na utilização da análise de imagens orientada a objeto, foi necessária a definição de uma rede semântica aplicável à classificação de cobertura do solo nas imagens em questão.

## 2. Análise Orientada a Objeto

A análise orientada a objeto baseia-se nos seguintes passos Schwarz et al. (2002): (1) segmentação baseada em multi-resolução; (2) geração da rede semântica; (3) classificação; e (4) análise da exatidão temática da classificação.

### 2.1 Segmentação

No processo de segmentação objetos em diferentes escalas são criados (segmentação em diferentes níveis), conectados entre si, e definidos de acordo com algum critério de similaridade. O sistema *Definiens Developer* utiliza a segmentação em multi-resolução, que realiza a fusão de regiões (*region-merging*), na qual os segmentos da imagem são agrupados par a par, usando a técnica de crescimento de regiões. O agrupamento de regiões ocorre segundo um critério de homogeneidade, descrevendo a semelhança dos objetos vizinhos (HOFFMANN; VEGT, 2001). No algoritmo implementado no sistema *Definiens Developer*, atributos de forma, compactidade e suavidade, e cor são utilizados para caracterizar os diferentes segmentos (BAATZ; SCHÄPE, 2000). O parâmetro compactidade é um atributo que representa quão agrupado estão os pixels de um determinado objeto. A suavidade representa o grau de regularidade do contorno de um objeto. E, por fim, o parâmetro fator de escala controla o tamanho de cada objeto, de modo que este corresponda a uma Unidade Mínima de Mapeamento (*Minimal Mapping Unit - MMU*).

### 2.2 Rede Semântica

No segundo passo, os objetos passam a se relacionar através da definição da rede hierárquica (herança dos atributos que descrevem a classe) e da rede semântica (estrutura lógica de relação entre as classes). Para a classificação, o objeto é atribuído à classe para a qual o grau de pertinência é maior, sendo que este valor é determinado por meio de lógica fuzzy (PINHO, 2005).

Uma rede semântica é uma notação gráfica composta por nós interconectados. As redes semânticas podem ser usadas para representação de conhecimento, ou como ferramenta de suporte para sistemas automatizados de inferências sobre o conhecimento (SOWA, 2002). Nesta representação as classes herdam atributos e comportamentos das superclasses que as contém.

### 2.3 Classificação

Para classificar a imagem, o *Definiens Developer* 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 com base na distribuição das amostras de treinamento das classes no espaço de atributos. Na lógica fuzzy, o grau de pertinência pode ser representado por diferentes curvas (rígidas ou contínuas). Utilizando regras fuzzy, um objeto pode estar associado a várias classes com diferentes graus de pertinência. O grau de pertinência varia de 0 (não pertence) a 1 (pertence), e a classe considerada é aquela cujo grau de pertinência é maior (FLANDERS et al., 2003).

Depois de definidos os objetos (segmentação) e as hierarquias, o processo de classificação dos objetos é efetuado por meio de regras de decisão. Dois fatores devem ser levados em consideração neste processo: qual tipo de regra de decisão será adotado e quais atributos serão utilizados para diferenciar cada classe. Também é possível a criação de atributos personalizados, aritméticos ou relacionais, a partir de atributos existentes (PINHO, 2005).

### **3. Material Utilizado**

O trabalho foi realizado sobre uma área teste de aproximadamente 13,5 km<sup>2</sup> da área urbana do município de Mauá – SP, que reunia diferentes padrões de ocupação de cobertura do solo.

Foram utilizadas duas imagens de diferentes sensores orbitais, contendo a mesma área e localização: uma multiespectral fusionada pelo método pansharpening (QuickBird) com três bandas na região do visível com resolução espacial de 0,60 m; e uma segunda imagem multiespectral também fusionada pelo método pansharpening (Cbers 2B CCD-HRC) com resolução espacial de 2,7 m (Leonardi et. al., 2008).

A composição IHS e as Principais Componentes das respectivas imagens foram inseridas como dados de entrada, as quais foram utilizadas como atributos para as classificações.

Os materiais utilizados para o processamento da imagem foram: a plataforma *Definiens Developer 7.0* para a análise orientada a objeto; o aplicativo *SPRING 5.0* para as segmentações e classificações pelo método tradicional; além de um arquivo vetorial do tipo *shapefile*, com as quadras e ruas da área urbana obtidos pela vetorização no programa *ArcGis 9.0*.

### **4. Metodologia**

Para o desenvolvimento deste trabalho, foram efetuadas as seguintes etapas: definição e caracterização das classes; segmentação; elaboração da rede semântica e seleção de atributos; classificação e avaliação dos resultados (análise qualitativa e quantitativa).

As imagens fusionadas Quickbird e Cbers 2B CCD-HRC, nas resoluções espaciais de 0,6 e 2,7, respectivamente, foram os dados de entrada nos estágios de processamento.

#### **4.1 Definição e caracterização das classes de interesse**

A seleção e caracterização das classes de interesse foram realizadas com base na interpretação visual das imagens, procurando identificar os principais materiais aplicados nas vias pavimentadas, nas coberturas das construções e também os principais tipos de cobertura de feições naturais. Sendo assim, para as duas imagens fusionadas, foram definidas as seguintes classes de interesse: Corpos d'água (Água), Pavimentação Asfáltica (Pav. Asf.), Concreto Escuro/Cimento Amianto/Telha Cerâmica (C.E./C.A./T.C.), Cobertura Claras (Cob. Clara), Solo Exposto (Solo Exp.), Sombra e Vegetação.

A caracterização das classes foi auxiliada pela elaboração de chaves de interpretação para cada uma delas. Nessas chaves, foram analisados os elementos de interpretação: cor, tamanho, forma, localização e textura.

#### **4.2 Segmentação**

Foram criados três níveis de segmentação. Para cada um deles, definiram-se quais seriam os objetos de interesse, e quais objetivos deveriam atender, quais arquivos deveriam ser utilizados na segmentação e qual dos parâmetros (cor ou forma) teria maior peso na segmentação.

O Nível 1 agrega todos os objetos dos níveis inferiores. O Nível 3, onde foram criadas apenas as classes quadras e ruas, foi criado para restringir a existência de algumas classes, baseado no fato de que algumas classes só ocorrem dentro das quadras, ou então, nas ruas. O objetivo do Nível 2 foi mapear as classes de Vegetação em um nível mais grosseiro. O Nível 1 teve como objetivo identificar as classes de cobertura do solo em escala detalhada.

#### **4.3 Elaboração da rede semântica e seleção de atributos para o Nível 1**

As redes semânticas foram definidas para cada nível hierárquico, e foram atribuídas as regras de classificação e descritores para cada classe nos diferentes níveis. Essas duas tarefas

ocorrerem conjuntamente, pois a diferenciação de entre as classes depende de como as classes estão agrupadas na rede semântica (PINHO, 2005).

Para a definição dos descritores e respectivas regras de pertinência, foram inicialmente selecionadas algumas amostras de treinamento para cada uma das classes. Na sequência, o comportamento dessas amostras em relação aos descritores foi analisado com o uso de histogramas, gráficos de dispersão e espacialização de atributos. Em função de existirem dezenas de descritores disponíveis na plataforma utilizada, foram priorizados os atributos identificados pela chave de interpretação apresentada na Seção 4.1.

A Figura 1 ilustra a rede semântica para o Nível 1, elaborada para a classificação da imagem Quickbird, acompanhando os respectivos atributos utilizados para cada classe de interesse.

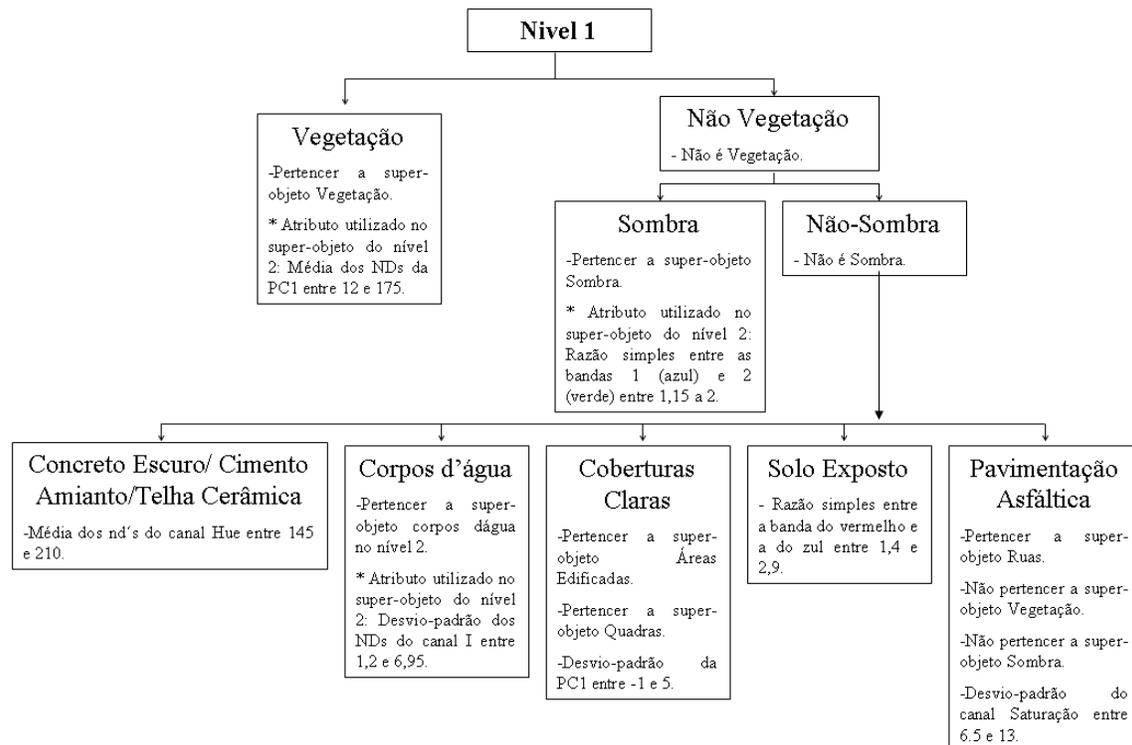


Figura 1 – Rede semântica do Nível 1 para a imagem Quickbird.

A Figura 2 ilustra a rede semântica para o Nível 1, elaborada para a classificação da imagem Cbers 2B CCD-HRC fusionada, apresentando também os respectivos atributos utilizados para cada classe.

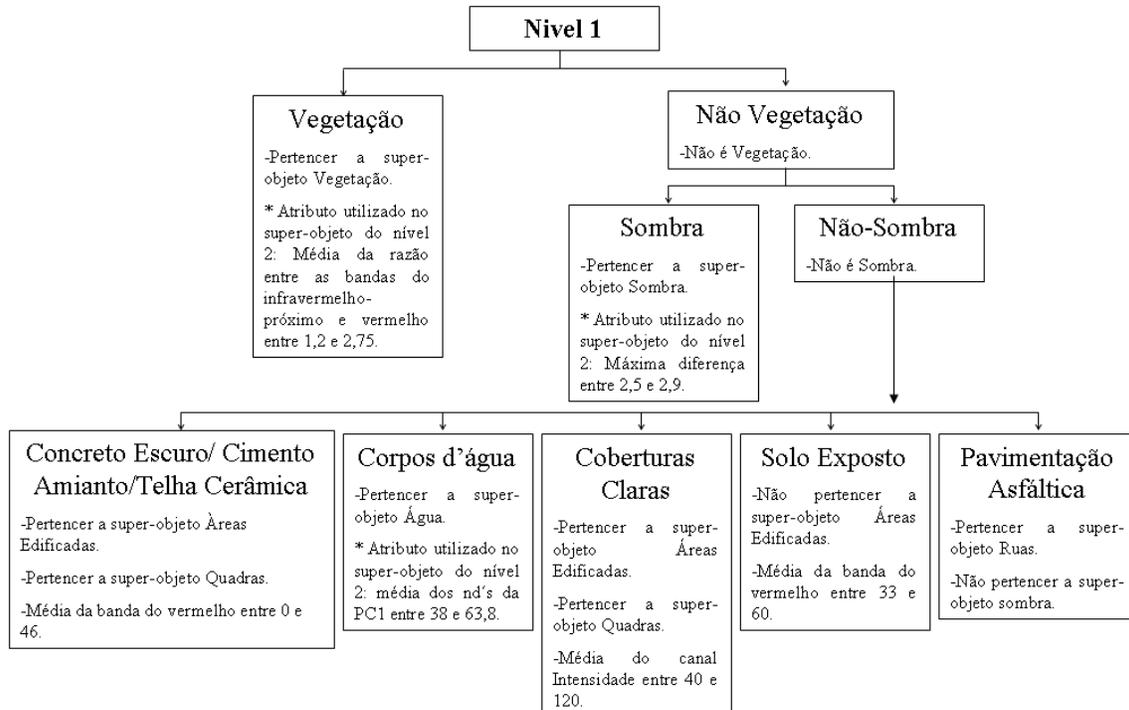


Figura 2 – Rede semântica do Nível 1 para a imagem Cbers 2B CCD-HRC fusionada.

#### 4.5 Classificação e análise dos resultados

Os recortes das imagens fusionadas contendo a área de estudo utilizadas para os processamentos são ilustradas nas Figuras 3 e 4.



Figura 3 – Imagem QuickBird fusionada.



Figura 4 – Imagem Cbers 2B fusionada.

Nesta etapa do trabalho, realizaram-se as segmentações por crescimento de regiões e, posteriormente, as classificações supervisionadas (Bhattacharya) no programa Spring 5.0. A Figura 5 (a) e (b) ilustra a classificação da imagem QuickBird (similaridade = 30 e área = 120) e Cbers 2B CCD-HRC fusionada (similaridade = 3 e área = 30) pelo método tradicional. Neste trabalho, vamos referir os métodos de classificação Bhattacharya e orientada a objeto, por método tradicional e orientado a objeto, respectivamente.

A Figura 5 (c) e (d) ilustra as classificações das imagens QuickBird e Cbers 2B CCD-HRC pelo método orientado a objeto, executadas na plataforma *Definiens Developer 7.0*.

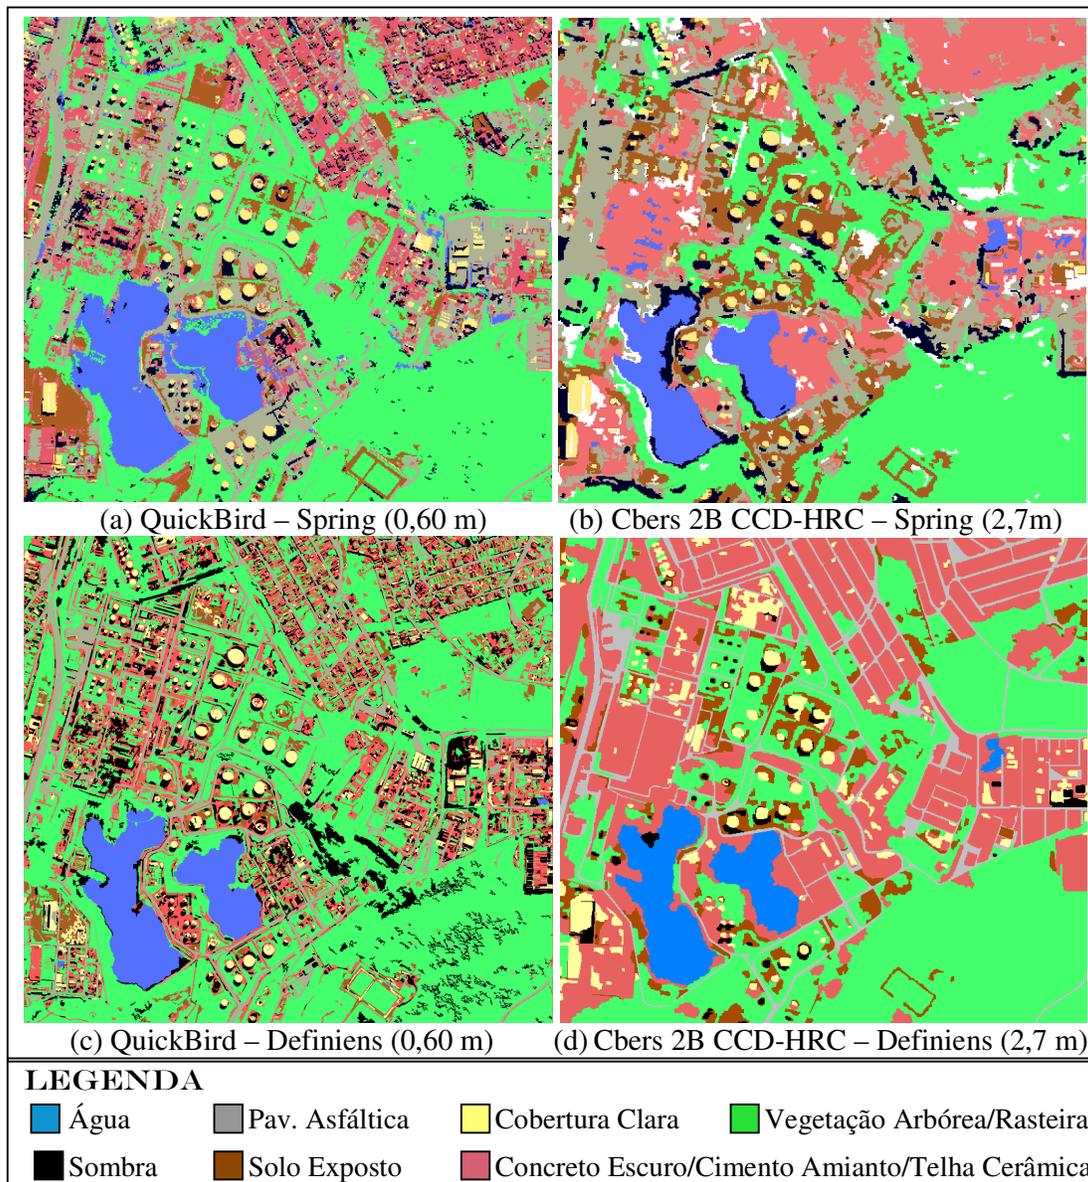


Figura 5 – Resultados das classificações.

Nota-se que para as imagens processadas pelo método tradicional (Figura 5 (a) e (b)), obteve-se resultado mais condizente com a realidade para a QuickBird, o que se justifica em face da resolução espacial da mesma ser quatro vezes superior à do Cbers 2B.

Para as imagens processadas pelo método orientado a objeto (Figura 5 (c) e (d)), observou-se que houve alguns erros de comissão no caso da imagem Cbers 2B para as classes Concreto Escuro/Cimento Amianto/Telhado Cerâmico, e para a classe Vegetação na imagem QuickBird. Alguns erros de omissão foram notados para a classe sombra na imagem Cbers 2B (Figura 5 (d)) e para a classe Concreto Escuro/Cimento Amianto/Telhado Cerâmico na imagem QuickBird (Figura 5 (c)). De modo geral, pode-se dizer que os resultados foram mais coerentes usando a classificação orientada a objeto para ambas as imagens.

Após a realização das classificações das imagens, procedeu-se à avaliação dos resultados por meio da análise da matriz de confusão. As Tabelas 1 e 2 ilustram os resultados da validação para as imagens processadas pelo método tradicional, e as Tabelas 3 e 4 ilustram os resultados da validação para as imagens processadas pelo método orientado a objeto.

Tabela 1 – Validação da imagem Cbers 2B fusionada classificada no Spring.

		Referência							
		Água	Pav. Asf.	C.E./C.A./T.C.	Cob. Claras	Solo Exp.	Sombra	Vegetação	
Classificação	Água	1	1	3	0	0	6	0	11
	Pav. Asf.	0	53	12	0	8	4	0	77
	C.E./C.A./T.C.	0	22	50	1	16	1	0	90
	Cob. Claras	0	3	1	47	11	0	0	62
	Solo Exp.	0	8	1	0	52	5	0	66
	Sombra	13	8	4	0	3	47	1	76
	Vegetação	1	6	19	0	10	17	45	98
		15	101	90	48	100	80	46	480
<b>Exatidão Global = 0,61</b>		<b>Kappa = 0,54</b>							

Tabela 2 – Validação da imagem QuickBird fusionada classificada no Spring.

		Referência							
		Água	Pav. Asf.	C.E./C.A./T.C.	Cob. Claras	Solo Exp.	Sombra	Vegetação	
Classificação	Água	1	0	0	0	0	1	1	3
	Pav. Asf.	1	30	9	2	3	13	4	62
	C.E./C.A./T.C.	0	12	106	1	6	15	0	140
	Cob. Claras	0	5	1	23	3	1	2	35
	Solo Exp.	0	3	1	0	14	0	4	22
	Sombra	2	4	20	0	0	85	6	117
	Vegetação	4	8	1	0	0	21	23	57
		8	62	138	26	26	136	40	436
<b>Exatidão Global = 0,64</b>		<b>Kappa = 0,54</b>							

Tabela 3 – Validação da imagem Cbers 2B fusionada classificada no *Definiens*.

		Referência							
		Água	Pav. Asf.	C.E./C.A./T.C.	Cob. Claras	Solo Exp.	Sombra	Vegetação	
Classificação	Água	8	0	4	0	0	0	0	12
	Pav. Asf.	0	46	8	4	1	0	0	59
	C.E./C.A./T.C.	0	0	87	6	0	0	8	101
	Cob. Claras	0	0	3	20	0	1	0	24
	Solo Exp.	0	0	3	0	26	1	7	37
	Sombra	0	0	6	0	0	2	6	14
	Vegetação	0	1	16	0	4	0	82	103
		8	47	127	30	31	4	103	350
<b>Exatidão Global = 0,77</b>		<b>Kappa = 0,71</b>							

Tabela 4 – Validação da imagem QuickBird fusionada classificada no *Definiens*.

		Referência							
		Água	Pav. Asf.	C.E./C.A./T.C.	Cob. Claras	Solo Exp.	Sombra	Vegetação	
Classificação	Água	7	0	0	0	0	0	1	8
	Pav. Asf.	0	39	13	1	0	0	9	62
	C.E./C.A./T.C.	0	0	46	1	1	0	10	58
	Cob. Claras	0	2	6	11	0	0	0	19
	Solo Exp.	0	0	7	3	11	0	2	23
	Sombra	0	1	1	0	0	18	29	49
	Vegetação	0	0	15	0	1	0	115	131
		7	42	88	16	13	18	166	350
<b>Exatidão Global = 0,70</b>		<b>Kappa = 0,61</b>							

Para a classificação tradicional, foi obtida uma estatística *Kappa* de 0,54, o que segundo Landis e Koch (1977) indica uma classificação de boa qualidade (0,40 a 0,60). Para a classificação orientada a objeto, obteve-se uma estatística *Kappa* de 0,71 para a imagem Cbers 2B, e uma estatística *Kappa* de 0,61 para a imagem QuickBird, o que segundo Landis e Koch (1977) corresponde a classificações de qualidade muito boa (0,60 a 0,80).

Esperavam-se resultados ainda melhores para a imagem QuickBird, porém os processamentos foram dificultados em vista da ausência da banda do infravermelho próximo, que é muito importante no mapeamento de objetos urbanos.

## 5. Considerações Finais

Este trabalho apresentou a comparação entre dois métodos de classificação, Bhattacharya e orientada a objeto para processar duas imagens de alta-resolução Quickbird e CBERS-2B. Para a realização da classificação orientada a objeto, foi elaborada uma rede semântica para o mapeamento de cobertura do solo em ambientes intra-urbanos. O propósito principal foi comparar o potencial do método de análise orientada a objeto em relação a um método tradicional supervisionado por regiões para a classificação de imagens orbitais de alta resolução espacial. Os resultados obtidos indicaram que o método orientado a objeto produziu um mapa de cobertura do solo intra-urbano com boa exatidão temática para a área de estudo. No entanto, a rede proposta precisa ser aperfeiçoada, inserindo-se novas classes e validando-a por meio de sua reaplicação em outras áreas.

## Agradecimentos

Ao suporte financeiro da CAPES pela bolsa de pesquisa e à Empresa Imagem por ceder gentilmente a imagem QuickBird.

## Referências

- BAATZ, M.; SCHÄPE, A. Multiresolution segmentation – an optimization approach for high quality multi-scale image segmentation. In: STROBL, J., BLASCHKE, T. *Angewandte Geographische Informationsverarbeitung XII. Beiträge zum AGITSymposium Salzburg . Karlsruhe*. Herbert Wichmann Verlag, p. 12–23, 2000.
- Foley, J. D.; Van Dam, A.; Feiner, S.K.; Hughes, J. F. **Computer graphics: principles and practice**. Reading, MA: Addison-Wesley, 1990. 1176p.
- Fonseca , L. G. M. et al. **Apostila de processamento digital de imagens**. São José dos Campos: INPE, jun. 2000.
- FLANDERS, D.; HALL-BEYER, M.; PEREVERZOFF, J. Preliminary evaluation of eCognition object-based software for cut block delineation and feature extraction. **Canadian Journal of Remote Sensing**, v. 29, n. 4, p. 441–452, 2003.
- Hoffmann, A.; Vegt, J. W. V. New sensor systems and new classification methods: laser and digital camera-data meet object-oriented strategies. **GeoBIT/GIS**, n. 6, p. 18-23, June, 2001.
- Landis, J. R.; Koch, G. G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174. 1977.
- Leonardi, F.; Almeida, C. M.; Fonseca , L. G. M.; Camargo, F. F. Fusão de Imagens Cbers 2B: CCD-HRC. In: Simpósio Brasileiro de Sensoriamento Remoto, 14. (SBSR), 2009, Natal. **Anais...** São José dos Campos: INPE, 2009. CD-ROM.
- Li, J. **Spatial quality evaluation of fusion of diferent resolution images**. IAPRS. Vol. 33. Amsterdam, 2000.
- Pinho, C.M.D.; Rennó, C.D. ; Kux, H. Avaliação de técnicas de fusão aplicadas à imagem QuickBird. In: Simpósio Brasileiro de Sensoriamento Remoto. 12, 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. p. 4225 – 4232. CD-ROM.
- Pitas, I. **Digital image processing algorithms**. Londres: Prentice Hall, 1995. 362p.
- TU, T.; SU, S.; SHYU, H.; HUANG, P.S. **Efficient intensity-hue-saturation-based image fusion with saturation compensation**. *Optical Engineering*, Redondo Beach, v.40, n.5, p.720-8, 2001.
- Wald, L., Ranchin, T., Mangolini, M. **Fusion of satellite images of different spatial resolutions: assessing the quality of resulting images**. *Photogrammetric Engineering & Remote Sensing*, 63, 6, pp. 691-699. 1997.
- Zhang, Yun. **Problems in the fusion of commercial high-resolution satellite, Landsat 7 images, and initial solutions**. ISPRS, Vol. 34, Part 4, “Geospatial Theory, Processing and Applications”, Ottawa, 2002.
- SOWA, J. F. Semantic networks. 2002. Disponível em: <http://www.jfsowa.com/pubs/semnet.htm>.