

## Delineamento de copas de *Araucaria angustifolia* utilizando lógica Fuzzy em imagens Quickbird II

Vagner Alex Pesck<sup>1</sup> Thiago Floriani Stepka<sup>2</sup> Gerson dos Santos Lisboa<sup>3</sup> Luciano Cavalcante de Jesus França<sup>4</sup> Clebson Lima Cerqueira<sup>5</sup>

<sup>1</sup> Universidade Estadual do Centro Oeste, R. Salvatore Renna, 875 - Santa Cruz, Guarapuava - PR, 85015-430.

<sup>2</sup> Universidade do Estado de Santa Catarina, Luiz de Camões, 2090 - Conta Dinheiro, Lages - SC, 88520-000.

<sup>3</sup> Universidade Federal do Sul da Bahia, Rodovia de Acesso para Itabuna, km 39 - Ferradas, Itabuna - BA, 45613-204.

<sup>4</sup> Universidade Federal dos Vales do Jequitinhonha e Mucuri, R. Cruzeiro, 1 - Jardim Sao Paulo, Teófilo Otoni - MG, 39803-371.

<sup>5</sup> Universidade Federal do Paraná, Rodovia Régis Bittencourt, 9082-9174 - Jardim Botânico, Curitiba - PR, CEP: 80050-540.

\*Author for correspondence: thiago.stepka@udesc.br

Received: October 2017 / Accepted: May 2018 / Published: September 2018

### Resumo

O presente estudo consistiu do uso da técnica de classificação orientada ao objeto, utilizando o algoritmo K *Nearest Neighbor*, e baseada em regras com uso da lógica Fuzzy para mapear copas de *Araucaria angustifolia* (Bertol.) Kuntze em um fragmento de Floresta Ombrófila Mista (FOM), localizada na Floresta Nacional de Irati, PR (Brasil), utilizando imagem de alta resolução Quickbird II. Primeiramente foi efetuado o trabalho de campo para coleta de informações sobre a espécie com base em fotografias aéreas em escala 1:2000, para validação dos resultados da classificação. A imagem Quickbird II foi fusionada pelo método de Gram-Schmidt, pelo qual realizou-se a segmentação da imagem utilizando níveis de escalas iguais para ambos os métodos, sendo 80 para a segmentação e 90 para a opção *merge segments*. Na classificação orientada ao objeto foram testados dois métodos, sendo um supervisionado e outro utilizando regras de classificação com a composição das bandas 4R, 3G e 2B. Para as classes tipológicas *Araucaria angustifolia* e Folhosas foram destacadas as regras espectrais como valores mínimos e máximos da banda infravermelho próximo, e as regras referentes ao NDVI (razão de bandas), e o atributo espacial "área". Para a classe sombra destacaram-se as regras de "intensidade" e valores espectrais, como valores máximos e mínimos da banda verde. O acerto para os métodos supervisionado e por regras foi classificado como excelente, com valores de Kappa de 0,83 e 0,82 respectivamente. Tanto a classificação por regras como supervisionada utilizando a lógica *fuzzy*, mostraram-se acuradas no delineamento das copas de Araucária.

**Palavras-chave:** Floresta Ombrófila Mista, Classificação Orientada ao Objeto, Alta Resolução, Sistema de Informações Geográficas.

### Abstract

The present study consisted of the use of the object-oriented classification with algorithm K *Nearest Neighbor*, and based on rules with use of Fuzzy logic to mapping crowns of *Araucaria angustifolia* (Bertol.) Kuntze in a fragment of Araucaria Forest, located in the National Forest of Irati, PR (Brazil), using high resolution image Quickbird II. Firstly, the field work was carried out to collect information on the species, based on aerial photographs in 1:2000 scale, to validate the results of the classification. The Quickbird II image was merged by the Gram-Schmidt method where image segmentation was performed using equal scaling levels for both methods, 80 for segmentation and 90 for the merge segments option. In the object-oriented classification two methods were tested, one being supervised and another using classification rules using the composition of the 4R, 3G and 2B. To *Araucaria angustifolia* and Hardwoods typological classes the spectral rules were highlighted as the minimum

and maximum values of the near infrared band, and the rules related to NDVI (band ratio), and the spatial attribute "area". For the shadow class we highlighted the rules of "intensity", and spectral values as maximum and minimum values of the green band. The fit for supervised and rule methods was rated as excellent, with Kappa values 0.83 and 0.82 respectively. Both the classification by rules and supervised using the fuzzy logic, were shown to be accurate in the delineation of the Araucaria crown.

**Keywords:** Araucaria Forest, Object Oriented Classification, Fuzzy Logic, Geographic Information System.

### Introdução

A disponibilidade de dados de alta resolução trouxe uma reconsideração dos métodos digitais utilizados para a extração de informações para o estudo da vegetação. Novos conceitos de processamento de imagens, bem como de algoritmos Fractais (Baatz et al. 2005), Lógica *fuzzy* (Aksoy et al. 2012; Pham et al. 2016) ou segmentação (Erkol et al. 2005; Jakubowski et al. 2013), foram desenvolvidos. Quanto à complexidade da Floresta Ombrófila Mista, abordagens baseadas em segmentação e lógica *fuzzy* podem ser mais apropriadas e poderiam significar e reforçar o papel da teledetecção na silvicultura.

Durante os últimos anos muitas pesquisas foram dedicadas ao uso de dados de sensoriamento remoto para aplicações florestais. Muitos tipos de sensores foram testados, de multiespectral para hiperspectral, de RADAR para laser aerotransportado (ALS).

Os sensores multiespectrais, têm um alto potencial na classificação de espécies arbóreas quando estas têm diferentes respostas espectrais (Uriarte et al. 2012; Dalponte et al. 2009; Heinzel e Koch 2012) e mostraram um bom desempenho para a discriminação de espécies.

A situação atual das florestas nativas do sul do Brasil, devido a exploração desordenada que ocorreu no passado, onde as árvores de maior porte das espécies mais valiosas foram abatidas, conduziu ao processo de deterioração genética de muitas espécies. A qualidade superior da madeira da *Araucaria angustifolia*, principal espécie explorada, e sua abundância original na região do Sul do Brasil, foram fatores importantes que contribuíram para a destruição quase que completa dos ecossistemas nativos. Todavia, conforme Sanquetta e Tetto (2000) não foi a extração da madeira a principal causa da devastação iniciada no final do século XIX, e intensificada a partir de meados do século XX, mas sim, o desmatamento para finalidades agrícolas e pecuárias os motivos mais fortes da redução da cobertura florestal nos estados do Sul do Brasil.

Diante destes cenários de fragmentação das florestas nativas com cobertura de araucária, estudos devem ser conduzidos com a finalidade de avaliar o seu potencial

madeireiro, proteção e resgate genético das espécies remanescentes com propósito de estimular o desenvolvimento sustentável. Para isto, faz-se necessário a integralização de técnicas de manejo florestal, morfometria e dinâmica das espécies, cujas ferramentas computacionais relacionadas ao processamento de imagens de sensores remotos podem ser usadas para a coleta de informações de maneira rápida e precisa.

Diversas técnicas digitais foram desenvolvidas visando delinear automaticamente as copas de árvores (Gougeon 1999) e seus resultados, em algumas delas, foram usadas posteriormente para estimar, a densidade e a composição florística das espécies arbóreas que ocorrem em áreas consideradas. A maioria desses trabalhos foi conduzida em talhões de coníferas, cujo formato cônico das copas favorece a delimitação automática nas imagens de alta resolução, uma vez que as bordas bem distintas observadas nas copas apresentam um ponto de reflectância máxima, que geralmente é o topo da árvore "local maximum".

A arquitetura das copas das araucárias, sua posição nos estratos superiores da floresta, além da clareza de como aparecem nas imagens digitais de alta resolução são aspectos importantes que determinam a possibilidade de delineamento automático de suas copas, via processamento digital por *softwares* ou rotinas computacionais específicas.

Disperati e Oliveira Filho (2005), utilizando a técnica considerada por Warner et al. (1999), não conseguiram delinear individualmente as copas de *Araucaria angustifolia* e de *Ocotea* spp. apenas pelas suas sombras periféricas em fotografia aérea em escala 1:2.000 escaneizada com 300 dpi e resultando tamanho do pixel de aproximadamente 8 cm.

Alguns estudos florestais nacionais enfocaram no delineamento de copas de árvores via classificação orientada ao objeto em imagens de alta resolução. Gomes et al. (2009) utilizaram segmentação multi-resolução (*E-Cognition*) em uma imagem Quickbird II, com resolução espacial de 61 cm, para o mapeamento de duas espécies de árvores *Sclerobium punicilatum* e *Mabea fistulifera*. Ambas as espécies, usadas para recuperação de áreas degradadas, ocorrem em áreas de fácil acesso, e na maioria das vezes, de forma agrupada onde a identificação das árvores na imagem e sua confirmação no campo foram realizadas com relativa facilidade. O resultado da classificação foi comparado com dados de campo, sendo a acurácia avaliada por meio da matriz de confusão e do cálculo do coeficiente Kappa, tendo este último valor final superior a 80%.

Este estudo teve como objetivo delinear copas da espécie *Araucaria angustifolia* em um fragmento da Floresta Ombrófila Mista, para avaliar a cobertura de copas em relação a espécies de folhosas, utilizando imagem digital de alta resolução Quickbird II, e técnicas de sensoriamento remoto e GIS como suporte de informações advindas do campo, por meio da classificação supervisionada e orientada ao objeto.

### Materiais e Métodos

O local de estudo está situado na Floresta Nacional (FLONA) de Irati, localizada na microrregião Centro-Sul do Paraná, no Segundo Planalto Paranaense, entre as coordenadas geográficas 25º 25' de latitude Sul, 50º 36' de longitude Oeste, 25º 17' de latitude Sul e 50º 30' de longitude Oeste. Possui área total de 3.495 ha, dos quais 1.279,2 ha são de cobertura florestal nativa protegida por mais de 60 anos, sem similar na região. A Figura 1 apresenta-se a localização da FLONA no contexto Paranaense e da microrregião de Irati, PR.

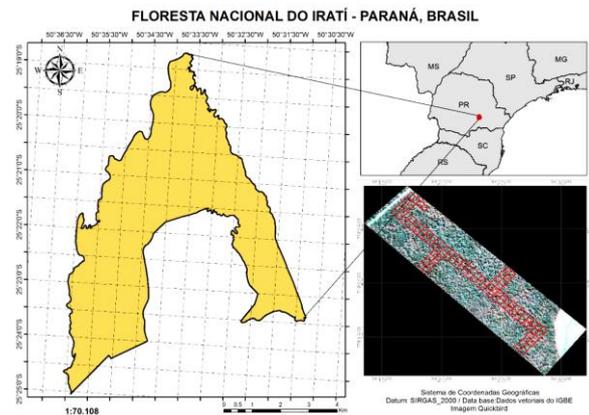


Figura 1. Mapa temático da Flora de Irati, PR, e a Imagem Quickbird na composição falsa cor (Bandas R4, G3 e B2), com parcelas permanentes de 25 ha.

Em função da alta resolução espacial da imagem Quickbird II (Tabela 1), optou-se pelo estudo de uma área pequena com 111 ha. Também se levou em consideração a localização de parcelas permanentes de 25 ha que estão instaladas na cobertura da imagem.

As bandas multiespectrais e a pancromática da imagem Quickbird II foram fusionadas pelo algoritmo de *Componentes Principais* com o objetivo de melhorar a resolução espacial das imagens.

Tabela 1. Escalas testadas para o primeiro e segundo nível de segmentação.

	Primeiro Nível (escala)	Segundo Nível (escala)
Imagem Quickbird II	70	90
	75	90
	80	90
	85	90

Para efeito de comparação, foram utilizadas oito (8) fotografias aéreas de 70 mm colorido normal não-métricas, ampliadas (21 x 28 cm) para a escala 1:2.000, resultantes de uma linha de voo de recobrimento fotográfico com 15 fotografias, em escala original 1:5.000, para validação do resultado da classificação (Figura 2). Também foram utilizadas duas fotografias aéreas restituídas em escala original de 1:25000 referentes ao recobrimento aerofotográfico realizado no estado do Paraná em 1980, para elaboração do DTM e ortorretificação da imagem Quickbird.



Figura 2. Interpretação visual das copas de *Araucaria angustifolia* em mosaico de fotografias aéreas de escala 1:2000

Realizou-se a coleta de pontos de controle necessários tanto para a restituição das fotografias aéreas e para a ortorretificação da imagem Quickbird II, foram coletados 28 pontos com GPS em modo diferencial estático abrangendo toda a área de estudo, destes, 10 pontos foram utilizados para validação da ortorretificação por meio do erro médio quadrático (RMS). Assim foi gerado um arquivo em DXF referente à restituição aerofotogramétrica (perfilamento e rede de drenagem). O perfilamento foi realizado em linhas paralelas com equidistância de 10 m e a coleta da altimetria a cada 10 m em cada linha abrangendo a área de 1326 ha. O

MDT com 0,6 m de resolução espacial foi gerado por meio de uma rotina (*Envi MDT*), disponibilizada pela SULSOFT.

### Classificação Orientada ao Objeto

A segmentação foi realizada utilizando o complemento *Feature Extraction Module*. Foram realizados dois níveis de segmentação, sendo o primeiro executado pela função *Segment Scale Level*, que utiliza o algoritmo *edge-based segmentation*. A escala de segmentação tem uma variação de 0 (zero) a 100 (cem) (Tabela 1), sendo assim, os valores mais próximos de zero correspondem à segmentação detalhista, já a segmentação com valores de escala perto de 100 promove uma generalização dos segmentos (Soares e Bepler 2013).

O segundo nível de segmentação, corresponde ao ajuste relacionado a quantidade de segmentos gerados no primeiro nível. Caracterizado como de uso opcional, esse nível de segmentação é executado pela função *Merge Level*, onde o algoritmo *Full Lambda-Schedule* é responsável pela realização desse processo. O fundamento desse algoritmo corresponde ao ajuste dos segmentos adjacentes em função da combinação espacial e espectral (Pesck 2011). A fusão de segmentos  $t_{i,j}$  ocorre quando o algoritmo encontra um par de regiões adjacentes,  $i$  e  $j$ , de forma que o valor da fusão é menor que um valor de limiar de  $\lambda$ . A expressão 1 representa o modelo matemático que caracteriza o algoritmo *Full Lambda-Schedule*.

$$t_{i,j} = \frac{(|O_i| + |O_j|) * ||u_i - u_j||^2}{|O_i| + |O_j| \text{length}(\partial(O_i, O_j))} \quad (1)$$

Em que:  $O_i$  = a região  $i$ -ésima da imagem;  $O_j$  = a região  $j$ -ésima da imagem;  $|O_i|$  = a área da região  $i$ -ésima da imagem;  $|O_j|$  = a área da região  $j$ -ésima da imagem;  $u_i$  = valor médio da região  $i$ -ésima;  $u_j$  = valor médio da região  $j$ -ésima;  $||u_i - u_j||^2$  = distância euclidiana entre os valores espectrais da região  $i$ -ésima  $j$ -ésima;  $\text{length}(\partial(O_i, O_j))$  = comprimento da borda em comum  $O_i, O_j$ .

Após a análise visual, levando em consideração o formato das copas das araucárias, optou-se por adotar o segundo nível de escala (*merging segments*) para corrigir os erros (*over-segmentation*) da primeira etapa, devido ao fato de que as copas de *Araucaria angustifolia* estarem divididas em mais de um segmento, melhorando assim a definição do perímetro ou limite das copas.

Após a etapa de segmentação, foram testados dois tipos de classificação da imagem Quickbird, sendo um supervisionado empregando amostras (segmentos) para treinamento do algoritmo e outro baseado em regras (atributos espaciais, espectrais, textura e razão de bandas) utilizando a lógica *fuzzy*.

A classificação supervisionada *K Nearest Neighbor* (KNN) é baseada no cálculo da distância euclidiana de cada segmento que constitui a imagem de segmentação, para cada região de treinamento que foi definida. Desta forma, a distância é obtida no espaço  $n$ -dimensional, em que  $n$  é o número de atributos para essa região de treinamento. A expressão 2 descreve o modelo matemático básico desse algoritmo.

$$\sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (2)$$

Em que:  $x$  = ponto de consulta;  $y$  = amostra;  $k$  = número de vizinhos mais próximos que serão considerados pelo algoritmo.

Foram selecionados os objetos como amostras, que serviram como dados de treinamento, sendo utilizados na classificação supervisionada para atribuir objetos às

determinadas classes, onde  $n$  é definido pelo número de objetos.

Para avaliar o resultado da classificação foi gerada uma matriz de confusão (Congalton et al. 1983; Stehman 1997).

$$K = \frac{N \sum_{i=1}^r x_{ij} - \sum_{i=1}^r (x_i * x_j)}{N^2 - \sum_{i=1}^r (x_i * x_j)} \quad (3)$$

Em que  $K$  = coeficiente kappa de concordância;  $N$  = valor total de observações incluídas na matriz;  $r$  = número de linhas da matriz de erros;  $x_{ij}$  observação na linha  $i$  coluna  $j$ ;  $x_i$  = total marginal da linha  $i$ ;  $x_j$  = total marginal da coluna  $j$ .

### Resultados e Discussão

Referente aos pontos utilizados como teste para avaliar a ortorretificação, pode-se afirmar que a precisão foi suficiente para obter a correção adequada na imagem. Os resultados deste processamento indicaram que o erro médio quadrático (RMS) para  $x$  e  $y$  (planimetria) utilizando 10 pontos para validação, foi de 0,42 m, sendo assim, satisfatório para a sua utilização em etapas subsequentes (Figura 3).

Araújo (2006) comenta que a correção sobre a imagem fusionada por um lado é positiva, pois diminui o número de etapas (há apenas um procedimento de ortorretificação). Por outro lado, a imagem poderia ficar “borrada” uma vez que as bandas multi e PAN são coletadas em tempos ligeiramente diferentes.

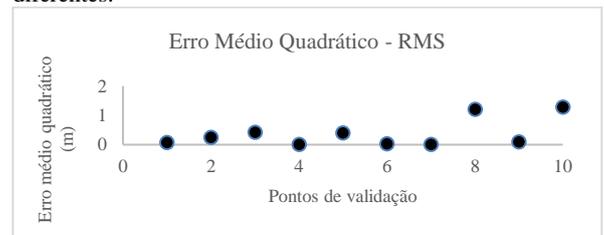
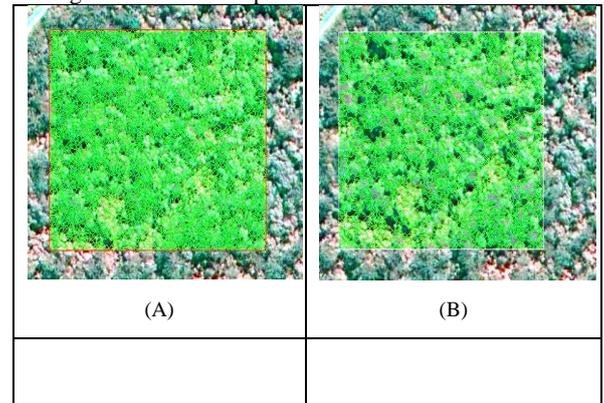


Figura 3. Erro médio quadrático (em metros), referente aos pontos de controle utilizados para validação da ortorretificação.

### Segmentação

Os níveis de escala 70 e 75 respectivamente (Figura 4 A e B), apresentaram grande número de segmentos gerados, sendo que ambas as escalas não se ajustam ao perímetro das copas. O nível de escala 80 (C) foi o que mais se aproximou da realidade da arquitetura da copa, contudo foram observadas inconsistências na segmentação, gerando mais de um segmento em uma copa.



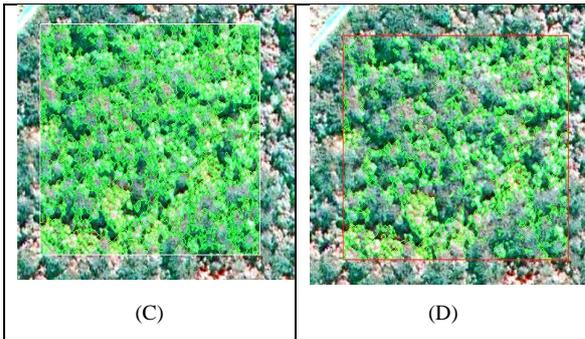


Figura 4. Representação das imagens segmentadas de acordo com o primeiro nível de escala, A(70), B (75), C(80) e D(85).

O nível de escala com valor 85 foi muito alto, gerando segmentos que agruparam muitas copas. Este fator está relacionado a característica de ocorrência da espécie, que devido à proximidade das árvores as copas se sobrepõe no dossel.

A densa vegetação desta área de estudo demonstrou a necessidade de se utilizar o segundo nível da segmentação. Foi aplicado um nível de escala 90 para agrupamento desses segmentos que fazem parte das copas das árvores. Com base nestas considerações pode-se inferir que a combinação de nível de escala 80 para o primeiro nível e 90 para o segundo nível da segmentação foi o que apresentou melhores resultados. Pinho (2005), utilizando a segmentação multiescala no *Software eCognition*, encontrou melhores resultados dando maior peso ao parâmetro de escala (nos 3 níveis), por ser o parâmetro de maior relevância na segmentação. A avaliação da segmentação em imagens digitais ainda é realizada visualmente na maioria das vezes em que esta técnica é empregada (como por ex.: Shimabukuro et al. (1998)). Segundo Shandley et al. (1998), pesquisadores têm encontrado dificuldade em fazer afirmativas quantitativas sobre resultados de segmentação. Darwish et al. (2003) afirmaram que a avaliação da segmentação é feita indiretamente pela avaliação da classificação.

#### Classificação K-Nearest Neighbor e lógica Fuzzy

Para o resultado da classificação supervisionada, foi obtida uma acurácia geral de 89%, um índice *Kappa* (K) de 0,83 e uma variância de *Kappa* de 0,001577, que segundo Landis e Koch (1977) e Fonseca (2000) é avaliado como classificação excelente ( $0,8 < K \leq 1,0$ ). O resultado da classificação é apresentado na Figura 5.

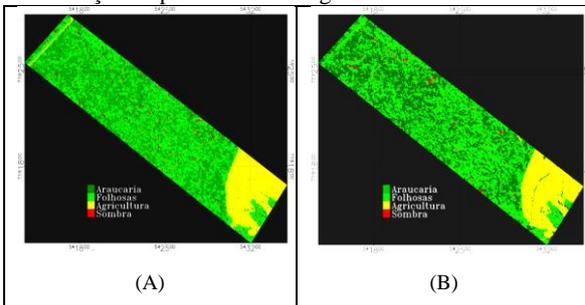


Figura 5. Classificações geradas. (A) Classificação supervisionada pelo método K-Nearest Neighbor; (B) Classificação por regras baseada em lógica Fuzzy.

Foi obtido o índice *Kappa* para as duas classes de maior importância consideradas, sendo as classes *Araucaria angustifolia* e Folhosas com *Kappa* de 0,81 e variância de *Kappa* de 0,002857. O índice para essas duas classes foi menor comparando com as demais, devido à menor confusão entre as classes Agricultura e Sombra. Disperati et al (2009) verificaram o uso da banda infravermelho próximo em uma imagem Quickbird não ortorectificada, para esta mesma área de estudo para mapear as copas de araucária, e obtiveram o

índice *Kappa* de 0,79, sendo este valor inferior ao encontrado nesta pesquisa, tanto para a classificação por regras como a classificação supervisionada. Esta diferença pode ser explicada pelo fato de que foi empregada apenas a banda do IR no processo de classificação, e nesta presente pesquisa foi usada uma combinação de bandas (4RG2B).

Na classificação por regras, (lógica *fuzzy*) foi obtido um índice *Kappa* de 0,82 e variância de *Kappa* de 0,001634, indicando a classificação como excelente (Congalton et al. 1983). Ainda, foram calculados o índice *Kappa* somente para as classes Araucária e Folhosas, que resultou num índice de 0,89 com variância de *Kappa* de 0,001717. Pode-se inferir que ambos os métodos de classificação (regras e supervisionada) obtiveram resultados aceitáveis (maior que 80%) para classificar as tipologias florestais de maior interesse nesta pesquisa.

As regras baseadas na textura dos objetos, não se mostraram eficientes, confundindo especialmente as classes Araucária e Folhosas, por apresentarem o elemento textura ligeiramente próximas, sendo assim, não foram aplicadas nesta classificação. Wang et al. (2005) relataram que a textura da imagem Quickbird não apresentou vantagem sob a imagem IKONOS. Isso pode estar atribuído as características texturais dos objetos, pois computacionalmente é difícil captar as diferenças texturais entre os duas classes (Araucária e Folhosas), que podem ser facilmente observadas por fotointerpretação. Pode-se verificar na Tabela 2 o resultado da classificação referente à área de cada classe.

Tabela 2. Avaliação das áreas classificadas por regras e supervisionada da imagem Quickbird.

Classes	Classificação por Regras		Classificação Supervisionada	
	Área (ha)	%	Área (ha)	%
<b>Araucária</b>	44,40	40,00	52,72	47,50
<b>Folhosas</b>	49,77	44,83	37,93	34,17
<b>Agricultura</b>	16,02	14,44	16,99	15,31
<b>Sombra</b>	0,81	0,73	3,37	3,03
<b>Total</b>	111,00	100,00	111,00	100,00

A classe Araucária para a classificação supervisionada resultou em diferença de 8,32 ha a mais em relação à classificação por regras. Isto também ocorreu para as classes agricultura (0,97 ha), e sombra (2,56 ha). Para a classe Folhosas houve diferença de 11,84 ha a mais na classificação por regras.

Foi possível analisar a acurácia do produtor e do usuário (Tabela 3) para ambas as classificações. A classe de menor valor foi a Araucária, com 84,4% e 85,3%, para a classificação por regras e supervisionada, respectivamente. Na classificação por regras, as classes Folhosas e Araucária apresentaram os maiores valores de acurácia do usuário, com 96,36% e 92,86% respectivamente. As classes Agricultura (80%) e Sombra (53,33%) foram encontrados valores menores de acurácia. Esses baixos valores, são devidos, principalmente no caso da sombra, sendo obtidos devido à dificuldade de encontrar a regra ou o conjunto de regras que pudessem classificar com exatidão esta classe. Vale ressaltar que a classe Sombra representa apenas 3,3% da imagem, tendo baixa representatividade em relação às demais classes.

Tabela 3. Acurácia do produtor e do usuário para a classificação por regras e supervisionada.

Classificação por Regras			Classificação Supervisionada		
Classes	Acurácia do Produtor	Acurácia do Usuário	Classes	Acurácia do Produtor	Acurácia do Usuário
Araucária	84,42	92,86	Araucária	85,33	91,43
Folhas	89,83	96,36	Folhas	89,09	89,09
Agri-cultura	100	80	Agri-cultura	100	100
Sombra	100	53,33	Sombra	100	66,67

É importante ressaltar que nenhuma operação de pós-classificação foi efetuada. As operações de pós-classificação, dependendo da ocasião, podem proporcionar melhorias à classificação digital e, conseqüentemente, na acurácia temática do mapeamento, mas a subjetividade do analista pode introduzir obliquidades nos resultados, tornando-os inconsistentes para a análise de desempenho de algoritmos (Dlugosz 2005).

A detecção, delineamento e identificação automática da cobertura de espécies florestais utilizando o sensoriamento remoto tornam-se cada vez mais importante no setor florestal (Sousa et al. 2010). As imagens satelitárias de alta resolução, podem contribuir com a distribuição espacial das espécies florestais de forma mais rápida e com menor custo, auxiliando na tomada de decisões em inventários florestais, gestão de povoamentos florestais, estimativa de biomassa e área basal. No manejo florestal, as áreas sombreadas podem facilitar os trabalhos de análise interpretativa da composição de espécies da floresta, sobretudo do dossel, principalmente com o uso da automatização desses processos interpretativos, utilizando-se técnicas de reconhecimento de padrões de copas (Disperati e Oliveira Filho, 2005).

A maior resolução espacial em imagens digitais proporcionada pelos novos sensores disponíveis no mercado não representa, necessariamente, o aumento na eficácia dos classificadores digitais. Acredita-se que a incorporação de elementos clássicos de fotointerpretação como textura, ou de novas abordagens analíticas como o modelo linear de mistura e a fusão com dados LIDAR ou imagens SAR, possam vir a melhorar a acurácia temática.

### Conclusões

O algoritmo de segmentação para o primeiro nível, não foi eficaz no delineamento das copas de *Araucaria angustifolia*, devido à proximidade das copas e resolução espacial da imagem Quickbird, sendo necessária a aplicação do segundo nível.

No processo de classificação por regras e supervisionada, ambas apresentaram resultados satisfatórios com índice *Kappa* de 0,81 e 0,89 respectivamente, sendo, portanto, aceitáveis na delimitação das tipologias florestais relacionadas a esta pesquisa, porém a classificação supervisionada apresentou-se ligeiramente superior.

### Referências

Araújo EHG (2006). *Análise multi-temporal de cenas do satélite Quickbird usando um novo paradigma de classificação de imagens e inferências espaciais: estudo de caso-Belo Horizonte, MG*. Dissertação, Mestrado em

Sensoriamento Remoto, Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, 175p.

Aksoy B, Murat E (2012). Landslide identification and classification by object-based image analysis and fuzzy logic: An example from the Azdavay region (Kastamonu, Turkey). *Computers & Geosciences* 38 (1), 87-98.

Baatz M, Schäpe A, Schmidt G, Athellogou M, BINNIG G (2005). Cognition network technology: object orientation and fractal topology in biomedical image analysis. Method and applications. In *Fractals in Biology and Medicine* (67-73). Birkhäuser Basel.

Congalton RG, Oderwald RG, Mead RA (1983). Assessing Landsat classification accuracy using discrete multivariate statistical techniques. *Photogrammetric Engineering & Remote Sensing*, 49 (12), 1671-1678.

Dalponte M, Bruzzone L, Vescovo L, Gianelle D (2009). The role of spectral resolution and classifier complexity in the analysis of hyperspectral images of forest areas. *Remote Sensing of Environment*, 113(11), 2345-2355.

Disperati AA, Oliveira Filho PC (2005). Delineamento de copas de árvores em fotografias aéreas de alta resolução, através de suas sombras periféricas: estudo de caso na Floresta Ombrófila Mista. *Revista Árvore*. 29 (2), 195-202.

Disperati AA, Pesck VA, Disperati J, Santos JR, Rudek A, Figueiredo Filho A (2009). Identificazione di chiome di *Araucaria angustifolia* nella banda dell'infrarosso vicino, fornite da Quickbird 2, In: *13ª Conferenza Nazionale ASITA* (Federazione Italiana delle Associazioni Scientifiche per le Informazioni Territoriali e Ambientali). Bari, Itália.

Darwish A, Leukert K, Reinhardt W (2003). Image segmentation for the purpose of object-based classification. In *International Geoscience and Remote Sensing Symposium*. Toulouse, France.

Dlugosz F (2005). *Classificação orientada a regiões na discriminação de tipologias da Floresta Ombrófila Mista usando imagens orbitais Ikonos*. Dissertação, Mestrado em Ciências Florestais, Universidade Federal do Paraná-UFPR, Curitiba, PR. 135 p.

Erkol B, Moss RH, Stanley JR, Stoecker WV, Hvatum E (2005). Automatic lesion boundary detection in dermoscopy images using gradient vector flow snakes. *Skin Research and Technology*, 11(1), 17-26.

Fonseca LMG (2000). *Processamento digital de imagens*. São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE). 105p.

Gomes P, Ferreira MC, Lingnau C, Bolfe E, Siqueira M (2009). Segmentação e classificação de dossel florestal em imagens Quickbird. *Ambiência*, 4(4), 35-46.

Gougeon FA (1999). Automatic individual tree crown delineation using a valley-following algorithm and a rule-based system. In *International Forum Automated Interpretation of High Spatial Resolution Digital Imagery for Forestry*, Victoria, Canada.

Heinzel J, Koch B (2012). Investigating multiple data sources for tree species classification in temperate forest and use for single tree delineation. *International Journal of Applied Earth Observation and Geoinformation*, 18, 101-110.

- Jakubowski MK, Li W, Guo Q, Kelly M. (2013). Delineating individual trees from LiDAR data: A comparison of vector-and raster-based segmentation approaches. *Remote Sensing* 5.9. 4163-4186.
- Landis J, Koch GG (1977). The measurements of agreement for categorical data. *Biometrics*. 33 (3) 159-179.
- Pham BT, Bui DT, Prakash I, Dholakia MB (2016). Rotation forest fuzzy rule-based classifier ensemble for spatial prediction of landslides using GIS. *Natural Hazards*, 1-31.
- Pinho CD (2005). *Análise orientada a objetos de imagens de satélites de alta resolução espacial aplicada à classificação de cobertura do solo no espaço intra-urbano: o caso de São José dos Campos*. Dissertação, Mestrado Sensoriamento Remoto, Instituto Nacional de pesquisas Espaciais, São José dos Campos, 180 p.
- Sanquetta CR, Tetto AF (2000). *Pinheiro-do-Paraná: lendas e realidades*. Curitiba: FUPEF do Paraná, 112p.
- Shandley J, Franklin J, White T (1998). Testing the Woodcock-Harward image segmentation algorithm in an area of southern California chaparral and woodland vegetation. *International Journal of Remote Sensing*. 19(3), 535-541.
- Shimabukuro YE, Batista G, Mello EMK, Moreira JC, Duarte V (1998). Using shade fraction image segmentation to evaluate deforestation in Landsat Thematic Mapper images of the Amazon region. *International Journal of Remote Sensing*. 19(3), 535-541.
- Soares AR, Beppler M (2013). Estudo Comparativo entre Softwares na Classificação de Imagens de Alta Resolução Espacial. In.: *Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, Foz do Iguaçu - PR, Brasil.
- Sousa AMO, Mesquita P, Gonçalves AC, Silva JRM (2010). Segmentação e classificação de tipologias florestais a partir de imagens Quickbird. *Ambiência* 6(Edição Especial) 57 - 66.
- Stehman SV (1997). Selecting and interpreting measures of thematic classification accuracy. *Remote sensing of Environment*, 62(1), 77-89.
- Uriarte M, Clark JS, Zimmerman JK, Comita LS, Forero-Montaña J, Thompson J (2012). Multidimensional trade-offs in species responses to disturbance: implications for diversity in a subtropical forest. *Ecology*, 93(1), 191-205.
- Wang Z, Ziou D, Armenakis C, Li D, Li Q (2005). A comparative analysis of image fusion methods, *IEEE Transactions on Geoscience and Remote Sensing*, 43 (6)1391-1402.