

## INFLUÊNCIA DA SEGMENTAÇÃO NO MAPEAMENTO DO USO E OCUPAÇÃO DO SOLO COM IMAGENS RAPIDEYE

MARIA CAROLINE GARCIA PASCHOAL<sup>1</sup>, CARLOS HENRIQUE WACHHOLZ DE SOUZA<sup>2</sup>, MARCELO JOSÉ DA SILVA<sup>2</sup>

<sup>1</sup> Graduanda em Engenharia Agrícola, Universidade Federal do Paraná (UFPR) – Campus Jandaia do Sul, Jandaia do Sul-PR, (43) 99634-2479, maria\_carolineg@hotmail.com

<sup>2</sup> Engenheiro Agrícola, Professor Adjunto, Universidade Federal do Paraná (UFPR) – Campus Jandaia do Sul, Jandaia do Sul-PR, carlossouza@ufpr.br; marcelo.jose@ufpr.br.

Apresentado no  
XLVIII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2019  
17 a 19 de setembro de 2019 - Campinas - SP, Brasil

**RESUMO:** O mapeamento do uso e ocupação do solo é um importante instrumento para o planejamento e administração do meio ambiente. O objetivo geral deste estudo foi testar um sistema automático de mapeamento da cobertura da terra, por meio de classificação digital do tipo random forest, utilizando dados do satélite RapidEye para a região do município de Cidade Gaúcha - PR. Analisou-se o tempo de duração do processo de classificação entre imagens segmentadas e não segmentadas, bem como as acurácias dos mapas gerados. Os resultados demonstraram que a segmentação das imagens é uma ferramenta que agiliza muito o processo de classificação sem perda efetiva de acurácia em imagens Rapideye.

**PALAVRAS-CHAVE:** *Random Forest*, Classificação Digital, Sensoriamento Remoto.

## SEGMENTATION INFLUENCE ON MAPPING OF LAND USE AND COVER WITH RAPIDEYE IMAGES

**ABSTRACT:** The mapping of land use and cover is an important instrument for the planning and administration of the environment. The objective of this study was test the automatic mapping of land cover, using a random forest digital classification, using data from the RapidEye satellite for the region of Cidade Gaúcha - PR municipality. The time spend in the classification process was analyzed between segmented and non-segmented images, as well as the accuracy of the generated maps. The results showed that the segmentation of images is a tool that greatly accelerates the process of without losing accuracy in Rapideye images.

**KEYWORDS:** Random Forest, Digital Classification, Remote Sensing.

**INTRODUÇÃO:** O Ministério do Meio Ambiente (MMA) vem fornecendo cobertura completa do Brasil em imagens RapidEye (5 m de resolução espacial) para serem utilizadas por órgãos públicos, a fim de pesquisas e ações que visam apoiar a gestão ambiental pelo governo, em uma forma de contribuir com desenvolvimento sustentável das áreas rurais do Brasil. Para utilizar completamente as informações oferecidas pelas imagens de média e alta resolução, são necessários métodos de classificação mais avançados, métodos que vão além de análises estatísticas e classificação de pixel individual (BLASCHKE et al. 2001; MICHEL et al., 2015). Pois, quando os tamanhos de pixels são relativamente pequenos em comparação com os tamanhos dos objetos na superfície terrestre, as abordagens tradicionais de classificação, podem não capturar a variabilidade do objeto devido à sua percepção limitada do contexto espacial de cada pixel (SCHULTZ et al., 2015). Para superar esse problema, novas abordagens têm sido desenvolvidas, como a classificação orientada a objeto, em inglês OBIA (Object-Based Image Analysis). Essa técnica consiste primeiramente de um processo de segmentação da imagem, ou seja, dividir a imagem em grupos com regiões homogêneas

(objetos), para posteriormente realizar uma classificação (BLASCHKE, 2010; CASTILLEJO-GONZÁLEZ et al., 2014). Essa técnica vem sendo utilizada com frequência para realizar o mapeamento do uso e cobertura da terra, utilizando dados de alta e média resolução espacial (RIBEIRO, 2010; ZHOU et al., 2015). Nesse sentido, o objetivo geral deste estudo foi testar a eficiência de um sistema baseado em mineração de dados para o mapeamento automático do uso e ocupação do solo em imagens Rapideye originais e segmentadas.

**MATERIAL E MÉTODOS:** A área de estudo compreende o município de Cidade Gaúcha, região Noroeste do estado do Paraná, que apresenta altitude média de 404 m, latitude 23°22'30" Sul e longitude 52°56'00" Oeste (Figura 1).

As imagens utilizadas foram adquiridas junto ao site do Ministério de Meio Ambiente (MMA), que disponibiliza imagens adquiridas pelos satélites RapidEye. A Tabela 1 apresenta as cenas utilizadas para criação do mosaico.

Tabela 1. Data de registros das imagens e cenas.

Nº da Cena	2228206	2228207	2228306	2228307	2228406
Data	06/10/11	15/06/11	06/10/11	06/10/11	06/10/11

Após a aquisição das imagens junto ao site do MMA, realizou-se um pré-processamento, utilizando o sistema de informações geográficas QGIS 2.18 (Quantum GIS Development Team, Quantum GIS Geographic Information System, Open Source Geospatial Foundation Project, <http://www.qgis.org>). Primeiramente foi criado um mosaico a fim de contemplar a totalidade do município de Cidade Gaúcha em apenas uma imagem. Após a criação do mosaico e com o auxílio de um arquivo vetorial que delimita o município de Cidade Gaúcha, realizou o recorte da imagem, para conter informações apenas da área em estudo.

Para a região de estudo, a definição das classes foi feita baseada em dados estatísticos do IBGE, juntamente com a análise visual das imagens, sendo as classes definidas como cana-de-açúcar, pastagem, solo exposto e mata.

O procedimento de segmentação das imagens foi realizado no software livre QGIS 2.18, com o auxílio da caixa de ferramentas denominada Orfeo Toolbox (OTB). Sendo que o algoritmo utilizado foi o “Stable Mean-Shift”, que deriva do método de segmentação Mean-Shift.

Como forma de anular a influência da amostragem no procedimento, utilizou-se as mesmas regiões amostrais para ambas as classificações. Para o mosaico segmentado a amostragem da classificação considerou o pixel central de cada objeto (pixels tem o mesmo valor dentro de um mesmo objeto). Já para o mosaico não-segmentado, considerou-se como amostra todos os pixels dentro dos limites dos objetos utilizados na amostragem segmentada.

Utilizou-se o classificador do tipo random forest (ou classificador por árvores de decisão). O algoritmo de classificação foi implementado em linguagem R (versão 3.4.1), utilizando os pacotes: “randomForest”, “rgdal”, “snow” e “tictoc”. Além do mais, o tempo de processamento foi mesurado, juntamente com a acurácia das classificações.

Para a realização destes procedimentos foi utilizado um computador conforme as configurações da Tabela 2.

Tabela 2. Configurações do computador.

Sistema Operacional	Windows 10 PRO, 64 bits
Memória RAM	16 GB
Processador	Intel ® Core™ i7-6700 3,40 GHz
Placa de vídeo	NVIDIA GeForce GT 730
Disco Rígido	SSD 250 GB

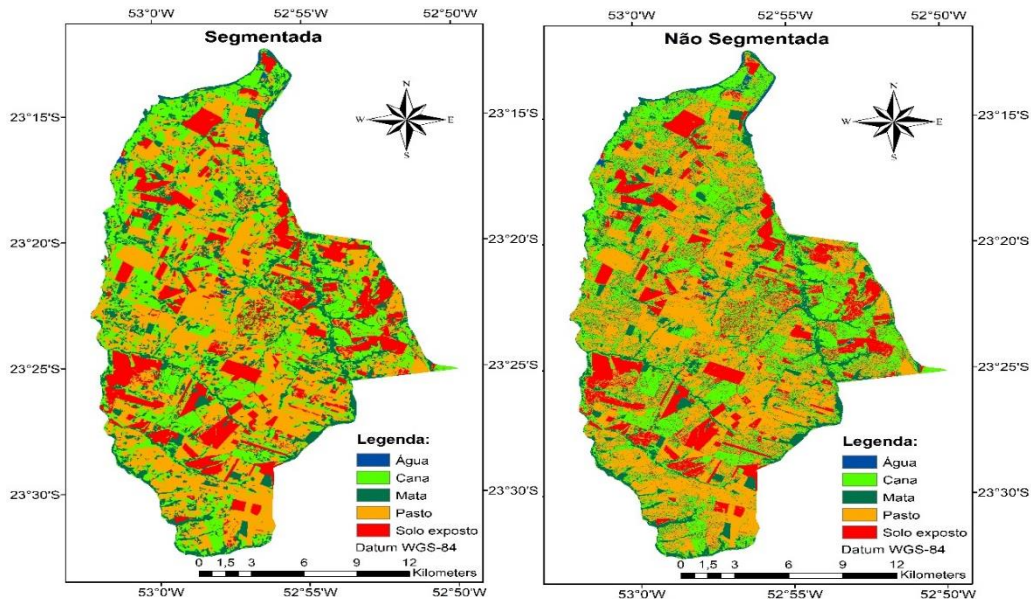


Figura 1. Resultado da classificação para a imagem segmentada e não-segmentada.

Para realizar a avaliação das classificações, foi utilizado o método da matriz de confusão/erro, onde os valores da coluna representam os dados de referência e os valores da linha os dados classificados. Na análise da acurácia foi utilizada a metodologia proposta por PONTIUS e SANTACRUZ (2014), que consiste em gerar erros de quantidade e distribuição. Em que o erro de quantidade representa os erros cometidos pelo classificador em relação a proporção de cada classe, e o erro de distribuição os erros cometidos na distribuição espacial de cada classe no mapa.

**RESULTADOS E DISCUSSÃO:** Ao analisamos visualmente as classificações percebe-se pouca diferença entre a imagem não-segmentada e segmentada (Figura 1). Em relação ao tempo de processamento a imagem não-segmentada, a classificação levou um tempo de 708 minutos. Já para imagem segmentada o processo de segmentação levou cerca de 32,06 minutos, e a classificação um tempo de 24,09 minutos (Figura 2). Portanto, ao executar a segmentação, que realiza a união de pixels em regiões homogêneas e transforma os pixels individuais em objetos maiores, diminuimos o tempo de processamento. Além do mais, ao analisar a acurácia das classificações, que é dividido em dois elementos principais: a diferença de quantidade e diferença de distribuição (PONTIUS et al., 2011), verificamos que a concordância global que é 100% menos a diferença total, foi de 92,52% para a não segmentada e 88,16% para a segmentada.

Além disso, as abordagens tiveram uma diferença entre si de 2,68% para o erro de quantidade, ou seja, na proporção das classes. E de 1,69% para diferença de distribuição, em termos de desacordo na distribuição espacial das classes. Portanto, a imagem segmentada tem acurácia equivalente à não-segmentada, com a vantagem de ter um tempo bem menor de processamento.

**CONCLUSÕES:** Com a realização do presente estudo pode-se concluir que:

- i) O sistema automático desenvolvido mostrou-se satisfatório no mapeamento do uso e cobertura do solo;
- ii) O softwares livres utilizados se mostraram eficientes nos processos desenvolvidos;

iii) A segmentação das imagens para posterior classificação é uma ferramenta de que reduz consideravelmente o tempo de processamento, sem perda significativa na acurácia em imagens Rapideye.

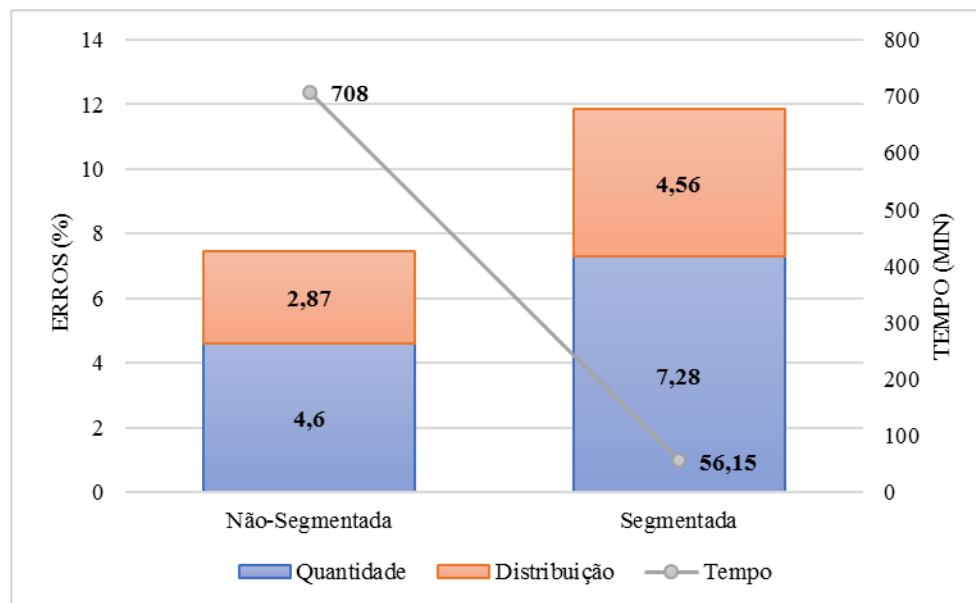


Figura 2. Erros de distribuição e quantidade juntamente com o tempo de processamento de cada classificação.

## REFERÊNCIAS

- BLASCHKE, T., HAY, G. J. Object-oriented image analysis and scale-space: theory and methods for modeling and evaluating multiscale landscape structure. *International Archives of Photogrammetry and Remote Sensing*, Athens, v. 34, n. 4, p. 22-29, Out, 2001.
- BLASCHKE, T. Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 65, n. 1, p. 2-16, 2010.
- CASTILLEJO-GONZÁLEZ, I. L., PE NA-BARRAGÁN, J. M., JURADO-EXPÓSITO, M., et al. Evaluation of pixel- and object-based approaches for mapping wildoat (*Avena sterilis*) weed patches in wheat fields using QuickBird imagery for site-specific management. *European Journal of Agronomy*, set, 2014, v. 59, p.57-66.
- CONGALTON, R.G. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, v. 37, n. 1, p. 35-46, 1991.
- E. Christophe and J. Inglada, "Open source remote sensing: Increasing the usability of cutting-edge algorithms," *IEEE Geosci. Remote Sens. Newslett.*, pp. 9-15, Mar. 2009.
- MICHEL, J.; YOUSSEFI, D.; GRIZONNET, M. Stable Mean-Shift Algorithm and Its Application to the Segmentation of Arbitrarily Large Remote Sensing Images. *IEEE Transactions on Geoscience and Remote Sensing*, v. 53, n. 2, p. 952-964, 2015.
- MMA - MINISTÉRIO DO MEIO AMBIENTE, Geo Catálogo. Disponível em: <<http://geocatalogo.mma.gov.br/sobre.jhtml>>. Acesso em 14 maio 2018.
- PONTIUS, R. G.; MILLONES, M. Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, v. 32, n. 15, p. 4407-4429, 2011.
- PONTIUS, R. G.; SANTACRUZ, A. Quantity, exchange, and shift components of difference in a square contingency table. *International Journal of Remote Sensing*, v. 35, n. 21, p. 7543-7554, 2014.
- RIBEIRO, B. M. G. Avaliação das imagens WORLDVIEW-II para o mapeamento da cobertura do solo urbano utilizando o sistema Interimage. 2010. 179 f. Dissertação (Mestrado Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010.
- SCHULTZ, B.; IMMITZER, M.; FORMAGGIO, A.; et al. Self-Guided Segmentation and Classification of Multi-Temporal Landsat 8 Images for Crop Type Mapping in Southeastern Brazil. *Remote Sensing*, v. 7, n. 11, p. 14482-14508, 2015.
- ZHOU, Z.; HUANG, J.; WANG, J.; et al. Object-oriented classification of sugarcane using time-series middle-resolution remote sensing data based on AdaBoost. *PLoS ONE*, v. 10, n. 11, p. 1-16, 2015.