

## INCONSISTÊNCIAS DAS ÁREAS DE PRESERVAÇÃO PERMANENTE DO CADASTRO AMBIENTAL RURAL POR MEIO DA GEOBIA

### INCONSISTENCIES OF THE PERMANENT PRESERVATION AREAS OF THE RURAL ENVIRONMENTAL REGISTRY THROUGH GEOBIA

**Luis Fernando Chimelo RUIZ<sup>1</sup>, Pâmela Caroline Barros FERNANDES<sup>2</sup>, Laurindo Antonio GUASSELLI<sup>3</sup>**

<sup>1</sup>Pós-doutorando do Departamento de Ciência do Solo da Escola Superior de Agricultura "Luiz de Queiroz" da Universidade de São Paulo – ESALQ/USP. Endereço Profissional: Avenida Bento Gonçalves, 9500, Bairro Agronomia. Porto Alegre, RS – Brasil.

E-mail: ruiz.ch@gmail.com

<sup>2</sup>Acadêmica do Curso de Engenharia Ambiental da Universidade Federal do Rio Grande do Sul – UFRGS. Avenida Bento Gonçalves, 9500, Bairro Agronomia. Porto Alegre, RS – Brasil E-mail: pamcbf@gmail.com

<sup>3</sup>Programa de Pós-Graduação em Geografia da Universidade Federal do Rio Grande do Sul – UFRGS. Avenida Bento Gonçalves, 9500, Bairro Agronomia. Porto Alegre, RS – Brasil. E-mail: laurindo.guasselli@ufrgs.br

Introdução  
Materiais e métodos  
Aquisição e correção das imagens  
Segmentação e avaliação  
Atributos preditivos e amostragem  
Índices espectrais  
Textura  
Amostragem  
Classificação e validação  
Determinações das inconsistências  
Resultados e discussões  
Segmentação  
Classificação da cobertura e do uso da terra  
Inconsistências das Apps averbadas no CAR  
Considerações finais  
Referências

**RESUMO** - As regras de exploração e de conservação da vegetação nativa, no Brasil, estão instituídas no Novo Código Florestal. O registro das informações dos imóveis rurais é realizado a partir do Cadastro Ambiental Rural (CAR). O objetivo desse estudo é desenvolver e avaliar uma metodologia para mapear conflitos da cobertura e uso da terra em APPs averbadas no CAR, integrando imagens orbitais de multissensores e de multirresoluções com GEOBIA. Para isso, foram utilizadas imagens Sentinel 1 e 2A. As bandas ópticas do Sentinel 2A com resolução espacial de 10 m foram utilizadas no processo de segmentação, considerando os parâmetros limiar de similaridade e o Tamanho Mínimo do Objeto (TMO). A segmentação com a menor distância Euclidiana (D) foi utilizada na avaliação dos parâmetros do método *Random Forest* (RF). Os resultados mostram que o desvio padrão das texturas Momento da Diferença Inversa e Variância foram os mais relevantes para discriminar as classes de cobertura e uso da terra. Nas APPs averbadas em áreas menores que 1 módulo fiscal e entre 1 e 2 módulos fiscais, a maior parte foi classificada como Campo e Mata nativa. Nas APPs averbadas em propriedades entre 2 e 4 módulos fiscais e maiores que 4 módulos fiscais, observa-se aumento de Solo exposto e Agricultura. Os resultados permitiram quantificar que as maiores inconsistências entre as APPs averbadas e a classificação da cobertura e uso da terra foram identificadas em propriedades superiores a 4 módulos.

**Palavras-chave:** Classificação da Cobertura e Uso da Terra. Mineração de Dados. Código Florestal.

**ABSTRACT** - In Brazil, the rules for exploration and conservation of native vegetation are established in the New Forest Code, the registration of information on rural properties is carried out through the Rural Environmental Registry (CAR). The objective of the study is to develop and evaluate a methodology for mapping the inconsistencies between land cover and land use with Permanent Preservation Areas (APPs) recorded in the CAR. For this, Sentinel 1 and 2A images were used. The optical bands of Sentinel 2A with spatial resolution of 10 m were used in the segmentation process, considering the similarity threshold parameters and Minimum Object Size (TMO). Segmentation with the shortest Euclidean distance (D) was used in the evaluation of the parameters of the Random Forest (RF) method. The standard deviation of the Moment of the Inverse Difference and Variance textures were the most relevant to discriminate the classes of land cover and use. For APPs registered with areas smaller than 1 fiscal module, for a total of 95.96 ha, most were classified as native Field and Forest. In areas between 1 and 2 fiscal modules, total of 119.62 ha, the most prevalent classes were also the native Campo and Mata classes.

**Keywords:** Classification of Land Cover. Data mining. Forest Laws.

## INTRODUÇÃO

No Brasil, as regras de exploração e de conservação da vegetação nativa estão instituídas no Novo Código Florestal sancionado pela Lei N° 12.651, de 25 de maio de 2012. A lei tem como objetivo a regularização ambiental das propriedades rurais sobre áreas desmatadas,

Áreas de Reserva Legal (RL), Áreas de Preservação Permanente (APP) e de reflorestamento. Imóveis rurais com áreas consolidadas em APP devem apresentar faixas de recuperação de acordo com o módulo fiscal estabelecido perante legislação estadual. Para as áreas de reserva legal, que não estão inseridas na Amazônia Legal, delimita-se um total de 20% da área total do imóvel rural. No cálculo dessas áreas, podem ser somadas as APPs do imóvel (Brasil, 2012).

O registro das informações dos imóveis rurais é realizado a partir do Cadastro Ambiental Rural (CAR), onde a república federativa e órgãos ambientais têm acesso à localização de cada imóvel e sua situação de regularização ambiental. A efetivação do CAR é realizada a partir do Sistema de Cadastro Ambiental Rural (SICAR), via sistema eletrônico, com caráter auto declaratório de informações. O proprietário demarca a área do imóvel, e classifica o uso e cobertura da terra a partir de filtros automáticos. A execução do sistema é realizada através de sensoriamento remoto com imagens do satélite RapidEye, de resolução espacial de 5 m e radiométrica de 12 bits.

No entanto, esse método apresenta custos elevados, financiados com recursos do FIP (Programa de Investimento Florestal) do

Governo Brasileiro e demais investidores. A fiscalização e a determinação de inconsistências das informações autodeclaradas pelos proprietários rurais custariam mais alguns milhões para os cofres públicos, visto que, demandariam monitoramento periódico.

Atualmente, o acesso a imagens de sensoriamento remoto com resolução espacial e temporal adequadas para esse propósito é gratuita, e estão disponíveis em diferentes regiões do espectro eletromagnético. A integração dessas imagens de multissensores e de multirresoluções, propicia mapeamentos mais acurados da cobertura e do uso da terra (Sousa & Ferreira, 2014). A Análise de Imagens Baseada em Objetos Geográficos (GEOBIA- *Geographic Object-Based Image Analysis*) facilita essa integração, uma vez que, a unidade de processamento básica é o objeto geográfico formado pela segmentação, e permite amostragem de imagens de multirresoluções (Schultz et al., 2016).

Neste sentido, este estudo tem como objetivo desenvolver e avaliar uma metodologia para mapear conflitos da cobertura e do uso da terra em APPs averbadas no CAR, integrando imagens orbitais de multissensores e de multirresoluções com GEOBIA, com base em imagens e programas de computadores gratuitos.

## MATERIAIS E MÉTODOS

O fluxograma da metodologia (Figura 1) contempla as seguintes seções: Aquisição e correção das imagens; Segmentação e avaliação; Atributos preditivos e amostragem; Classificação e validação; e Determinação das inconsistências.

### Aquisição e correção das imagens

Foi adquirida uma imagem satélite Sentinel 2A, de 10/12/2016, 13 bandas do sensor *Multispectral Instrument* (MSI), nível 1C de pré-processamento, ortoretificada e convertida para reflectância do topo da atmosfera. A imagem foi pré-processada para o nível 2A, como a ferramenta Sen2Cor da Plataforma de Aplicação do Sentinel (*Sentinel Application Platform - SNAP*). No nível 2A são removidos os efeitos atmosféricos e convertidos os valores dos pixels para reflectância da superfície ( $\rho$ ). A banda 10 não foi considerada neste estudo, pois está localizada em uma faixa espectral fora das janelas atmosféricas.

Também foi utilizada uma imagem de Radar de Abertura Sintética (RAS), banda C, produto *Ground Range Detected* (GRD), satélite Sentinel 1,

resolução espacial de 10 m, do dia 20/12/2016, e pré-processamento de nível 1 nas polarizações VV e HH. Para que a imagem represente uma medida de reflexão dos alvos da superfície, foram aplicados os pré-processamentos: calibração radiométrica, filtragem do ruído *speckle* e a correção do terreno, utilizando a SNAP.

A calibração radiométrica corrige os valores dos pixels com intuito de representar verdadeiramente o retroespalhamento da superfície imageada, assim os valores foram convertidos para intensidade. O ruído *speckle* causa o cancelamento (interferência destrutiva) ou a soma do sinal (interferência), gerando imagens com efeito de “sal e pimenta”, para amenizar esse efeito, foi aplicado o filtro de Lee sigma, com uma janela móvel de 5x5. Devido à geometria lateral de uma imagem RAS, a imagem gerada está mapeada no plano inclinado (*Slant Range Domain*). A correção do terreno converte a imagem do plano inclinado para nível do terreno (*Ground Range Geometry*) e define um sistema cartográfico. Para a correção do terreno da imagem

RAS, foram utilizadas imagens de altimetria do *Shuttle Radar Topography Mission* (SRTM), resolução espacial de 30 m e sistema de projeção

*Universo Transversa de Mercator* (UTM), fuso 22, hemisfério Sul, Datum horizontal SIRGAS/2000 (Abdikan et al., 2016).

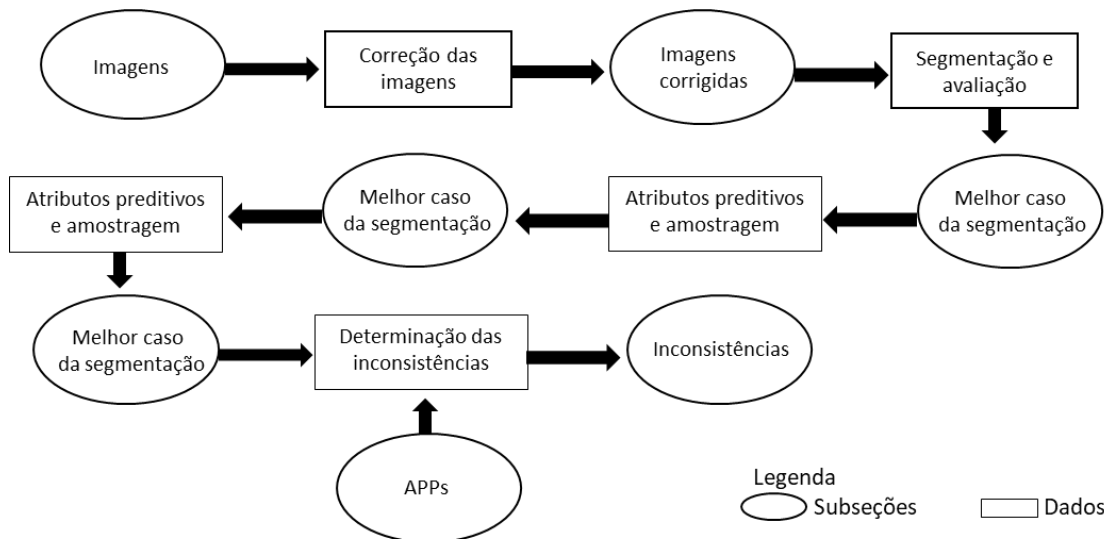


Figura 1 - Fluxograma da metodologia.

### Segmentação e avaliação

Para segmentar a imagem Sentinel 2, bandas ópticas com resolução espacial de 10 m (B2, B3, B4 e B5), foi utilizado o método crescimento de regiões disponível no Sistema de Processamento de Informações Georreferenciadas (SPRING) do Instituto Nacional de Pesquisas Espaciais (INPE). Esse método inicia rotulando cada pixel da imagem em uma região distinta, calcula a similaridade para cada par de regiões adjacente. Para que as regiões sejam unidas, a similaridade deve ser menor que o limiar preestabelecido e mutuamente próximo. O critério de similaridade considera as médias entre regiões. A segmentação agrupa regiões com valores menores que o tamanho mínimo do objeto (TMO). Os resultados desse método são sensíveis aos valores dos limiares de similaridade e do tamanho mínimo das regiões (Câmara et al., 1996). Foram avaliados valores de similaridade entre 5 e 100, variando 5, e para o tamanho mínimo da região, entre 10 e 200, variando 10.

As segmentações foram validadas determinando a distância euclidiana, Equação (3), entre a subsegmentação e a supersegmentação, conforme Clinton et al. (2009). A supersegmentação (SU) corresponde a regiões da segmentação maiores que os objetos geográficos de uma imagem, conforme Equação (1):

$$SU = 1 - \frac{\text{área}(x \cap y)}{\text{área}(x)} \quad (1)$$

Em que: x é o objeto geográfico da imagem (objeto de referência); y é a região formada pela segmentação; área (x ∩ y) é a área com intersecção

entre x e y. A subsegmentação (SO) corresponde a regiões menores que os objetos geográficos de uma imagem, Equação (2):

$$SO = 1 - \frac{\text{área}(x \cap y)}{\text{área}(y)} \quad (2)$$

A distância euclidiana (D) entre a subsegmentação e a supersegmentação, Equação (3):

$$D = \sqrt{SU^2 + SO^2} \quad (3)$$

Em que: valores iguais a zero para D significam que as regiões formadas pela segmentação, correspondem, perfeitamente, aos objetos geográficos da imagem.

Os objetos geográficos foram obtidos pela vetorização de pequenas áreas de mata nativa, banhado e solo exposto, interpretáveis na imagem Sentinel 2 (B2, B3, B4 e B5), formando os objetos de referência.

A validação foi automatizada utilizando a linguagem de programação Python 2.7 e a biblioteca de programação PyQGIS. A segmentação com menor valor de D foi selecionada para a classificação da cobertura e do uso da terra.

### Atributos preditivos e amostragem

Os atributos preditivos foram formados pelas médias e desvios-padrões das bandas espectrais do Sentinel 2 e das bandas de retroespalhamento do Sentinel 1, calculados para as regiões das segmentações. As médias e os desvios-padrões para as regiões também foram elaborados para os índices espectrais e as texturas, descritos nas subseções a seguir.

## Índices espectrais

Os índices espectrais foram calculados utilizando as bandas do Sentinel 2 (Figura 2), conforme Radoux et al. (2016).

## Texturas

Neste estudo, foram consideradas as seguintes texturas: Momento Angular de Segunda Ordem (MASO), Correlação (Corr), Entropia (Entr), Contraste (Contr), Média da Soma (MS), Entropia da Diferença (ED), Entropia da Soma (ES), Variância (Var), Momento da Diferença Inversa (MDI), Variância da Diferença (VD), Variação da Soma (VS), Medidas de Informação da Correlação (MIC) e Coeficiente de Correlação Máximo (CCM), extraídas utilizando a matriz de co-ocorrência dos níveis de cinza (*Grey Level Cooccurrence Matrix* - GLCM). GLCM pode ser entendida como uma tabulação das possíveis combinações dos valores de intensidades dos pixels que ocorrem em uma região da imagem (Haralick et al., 1973).

As texturas foram derivadas da média das bandas com resolução espacial de 10 m do Sentinel 2 (B2, B3, B4 e B5), a partir da ferramenta *texture* do programa GRASS-GIS 6.4. Foi utilizada uma janela de análise de 3x3 pixels e os ângulos de análise: 0°, 45°, 90° e 145°. O valor final da textura foi obtido da média dos quatro ângulos de análise (Laliberte & Rango, 2009).

## Amostragem

As amostras de treinamento foram geradas por meio de pontos regulares com equidistâncias de 1000 m, sobre toda a área de estudo, num total de 1040 pontos, compreendendo as classes de cobertura e uso da terra: Água, Mata Nativa, Silvicultura, Campo, Solo exposto, Agricultura, Banhado e Área urbana.

As amostras de validação foram compostas a partir de 1000 pontos aleatórios, independentes das amostras de treinamento. As atribuições das classes de cobertura da terra para cada ponto, foram realizadas, por meio de uma imagem cor verdadeira do Sentinel 2 (R:B4-G:B3-B:B2), imagens do *Google Earth Pro* e fotografias terrestres.

## Classificação e validação

As classificações utilizaram o método *Random Forest* (RF) categorizado como classificador do tipo comitê ou *ensemble*. Esse método divide as amostras de treinamento em subconjuntos e gera uma árvore de decisão (AD) para cada subconjunto. Após o modelo treinado, a classificação de um novo exemplo é obtida pela

votação de cada árvore, assim, o novo exemplo é classificado na classe mais votada (Breiman, 2001). O RF tem dois parâmetros fundamentais, o número de árvores, no qual controla o total de subconjuntos gerados, e a profundidade de cada árvore. A profundidade define a complexidade do modelo, quanto maior o valor desse parâmetro, mais regras de decisão são geradas na árvore (Halmenschlager, 2002). Foram avaliados valores de 5 até 50, variando 5, para ambos os parâmetros, e como critério de divisão dos nós das árvores, foi selecionado a impureza Gini (*Mean Decrease in Gini Impurity*).

O método RF estima a relevância dos atributos preditivos, computando a média de decaimento da impureza Gini. Com intuito de desenvolver modelos menos complexos para a classificação da cobertura e uso da terra, foi proposto uma avaliação das relevâncias acumuladas dos atributos preditivos.

Para isso, foi gerada uma classificação RF com todos os atributos preditivos, somadas as relevâncias dos atributos preditivos (relevâncias acumuladas), removidos os atributos preditivos menos relevantes e gerado um novo modelo de classificação RF. Foram avaliadas relevâncias acumuladas de 70% até 100%, variando 5%.

A segmentação com a menor distância euclidiana entre a subsegmentação e a supersegmentação (D), foi classificada pelo método RF, considerando seus parâmetros e as relevâncias acumuladas.

As regiões das segmentações foram selecionadas com as amostras de treinamento e ajustadas às classificações. Com as amostras de validação foram calculadas as acurácias das classificações, considerando a Proporção Correta (PC), o Desacordo de Alocação (DA) e o Desacordo de Quantidade (DQ) (Pontius & Millones, 2011).

A classificação com o menor valor de PC e menores valores de DA e de DQ, foi selecionada para avaliar o CAR. As classificações foram desenvolvidas com a biblioteca SciKit - Learn, e a avaliação das relevâncias acumuladas e as validações elaboradas pela biblioteca Numpy.

## Determinações das inconsistências

Como estudo de caso foi adotado o município de Santo Antônio da Patrulha, Rio Grande do Sul. A escolha se deve a sua inserção na Área de Proteção Ambiental do Banhado Grande (APABG), e a quantidade de imóveis cadastrados no CAR com APPs.

<b>Índices</b>	<b>Fórmulas</b>	<b>Atributos espectrais</b>
<i>Chlorophyll green index (CGI)</i>	$\frac{\rho_{IVP}}{\rho_{verde} + \rho_{BV}}$	B3, B4, B8, (CGI348)
<i>Greenness Index (GI)</i>	$\frac{\rho_{verde}}{\rho_{vermelho}}$	B3, B8 (GI38)
<i>Green normalized difference vegetation index (gNDVI)</i>	$\frac{\rho_{IVP} - \rho_{verde}}{\rho_{IVP} + \rho_{verd}}$	B3, B8 (GNDVI38)
<i>Normalized difference vegetation index (NDVI)</i>	$\frac{\rho_{IVP} - \rho_{vermelho}}{\rho_{IVP} + \rho_{vermelho}}$	B4; B8 (NDVI84)
<i>Soil Adjusted Vegetation Index (SAVI)</i>	$\frac{\rho_{IVP} - \rho_{vermelho}}{\rho_{IVP} + \rho_{vermelho} + L} \times L$	B8, B4, L= 0.5 (SAVI0584) B8, B4, L= 1.0 (SAVI1b84) B8, B4, L= 1.5 (SAVI1584)
<i>Simple ratio NIR narrow and Blue (SRNIRb)</i>	$\frac{\rho_{IVP}}{\rho_{azul}}$	B8, B2 (SRNIRb82)
<i>Simple ratio NIR narrow and Green (SRNIRg)</i>	$\frac{\rho_{IVP}}{\rho_{verde}}$	B8, B3 (SRNIRg83)
<i>Simple ratio NIR narrow and Red (SRNIRr)</i>	$\frac{\rho_{IVP}}{\rho_{vermelho}}$	B8, B4 (SRNIRr84)
<i>Normalized Difference Water Index 2 (NDWI2)</i>	$\frac{\rho_{verde} - \rho_{IVP}}{\rho_{verde} + \rho_{IVP}}$	B3, B8 (NDWI238)
<i>Built-up Area Index (BAI)</i>	$\frac{\rho_{azul} - \rho_{IVP}}{\rho_{IVP} + \rho_{azul}}$	B2, B8 (BAI28) B1, B9 (BAI19)
<i>Moisture stress index (MSI)</i>	$\frac{\rho_{IOC}}{\rho_{IVP}}$	B11, B5 (MSI115) B11, B6 (MSI116) B11, B7 (MSI117) B11, B8A (MSI118a) B12, B5 (MSI125) B12, B6 (MSI126) B12, B7 (MSI127) B12, B8A (MSI128a)
<i>Normalized Difference of Red-edge and SWIR2 (NDRedegeSWIR)</i>	$\frac{\rho_{BV} - \rho_{IOC}}{\rho_{BV} + \rho_{IOC}}$	B11, B5 (NDR511) B11, B6 (NDR611) B11, B7 (NDR711) B12, B5 (NDR512) B12, B6 (NDR612) B12, B7 (NDR712)
<i>Red-edge normalized difference vegetation index (NDVIre)</i>	$\frac{\rho_{IVP} - \rho_{BV}}{\rho_{IVP} + \rho_{BV}}$	B8, B5 (NDVIre85) B8, B6 (NDVIre86) B8, B7 (NDVIre87)
<i>Normalized Difference Water Index 1 (NDWI1)</i>	$\frac{\rho_{IVP} - \rho_{IOC}}{\rho_{IVP} + \rho_{IOC}}$	B11, B5 (NDWI1115) B11, B6 (NDWI1116); B11, B7 (NDWI1117) B11, B8a (NDWI1118a) B12, B5 (NDWI1125) B12, B6 (NDWI1126) B12, B7 (NDWI1127)
<i>Leaf Chlorophyll Content (LChloC)</i>	$\frac{\rho_{B7}}{\rho_{B5}}$	B7, B5 (LCHLOC75)
<i>Normalized Difference Tillage Index (NDTI)</i>	$\frac{\rho_{B11} - \rho_{B12}}{\rho_{B11} + \rho_{B12}}$	B11, B12 (NDTI1112)
<i>Soil Tillage Index (STI)</i>	$\frac{\rho_{B11}}{\rho_{B12}}$	B11, B12 (STI1112)

**Figura 2** - Índices espectrais e suas respectivas fórmulas, de acordo com bandas do Sentinel 2A/ MSI. Fonte: Adaptado de (Radoux et al., 2016).

As averbações das APPs nesse município foram obtidas no Sistema Nacional de Cadastro Ambiental e Rural (SICAR).

De acordo com o Instituto Nacional de Colonização e Reforma Agrária (INCRA), em Santo Antônio da Patrulha o módulo fiscal equivale a 18 ha. Assim, esse valor utilizado como

referência.

As inconsistências foram geradas por meio da intersecção entre as APPs e a classificação da cobertura e uso da terra mais acurada, considerando os módulos fiscais e as faixas de APP do Código Florestal. Foi utilizando o programa de Sistema de Informação Geográfica QGIS 3.

## RESULTADOS E DISCUSSÃO

### Segmentação

Os valores médios de supersegmentação, de subsegmentação e de distância euclidiana (D), calculados em relação aos objetos de referência, para os parâmetros da segmentação (similaridade e TMO), são apresentados na figura 3. O aumento dos valores de TMO acarretou aumento da supersegmentação dos objetos (Figura 3a). Esse comportamento era esperado, uma vez que, aumentando o valor de TMO, maiores serão os objetos formados pela segmentação e mais propenso a ocasionar uma supersegmentação. A análise da subsegmentação em relação ao TMO (Figura 3b) mostra que aumentando TMO, diminui a subsegmentação. Como os objetos gerados pela segmentação aumentam com o valor de TMO, os objetos tornam-se maiores que os objetos geográficos da imagem (objetos de referência), gerando uma segmentação cada vez mais supersegmentada e menos subsegmentada.

Ma et al. (2015) avaliaram o TMO na classificação baseada em objetos geográficos de uma imagem com altíssima resolução espacial. Os autores observaram um decréscimo na acurácia global para valores de TMO acima de 110, altos valores geraram objetos que representavam mais de uma classe. Ma et al. (2017), revisaram trabalhos sobre classificação baseada em objetos geográficos, e identificaram uma correlação negativa entre os parâmetros ótimos do TMO e a resolução espacial das imagens.

A similaridade apresentou menor influência na supersegmentação (Figura 3a) e na subsegmentação (Figura 3b). O que pode estar relacionado aos objetos de referência coletados na imagem (objetos geográficos) que possuem áreas pequenas e valores internos (pixels) de reflectâncias muito semelhantes. Assim, mesmo variando os valores de similaridade entre 5 e 100, os objetos formados pela segmentação eram todos similares aos de referências (objetos geográficos), resultando em uma mínima variação da supersegmentação para distintos

valores similaridade.

A distância euclidiana (D) entre a supersegmentação e a subsegmentação (Figura 3c) mostra que quanto mais próximo de zero o valor de D, mais o formato dos objetos formados pela segmentação se aproxima dos objetos de referência. As maiores distâncias euclidianas (D) foram encontradas para TMO menor que 20 e para os valores maiores que 50. Isso é explicado avaliando a supersegmentação e a subsegmentação, visto que, os piores valores da supersegmentação foram obtidos para TMO maiores que 50 e, para a subsegmentação os piores valores foram para TMO menores que 20, restringindo a busca do melhor caso da segmentação para TMO iguais a 30 ou a 40.

Na avaliação das distintas similaridades (Figura 3c) para cada TMO, as distâncias euclidianas (D) foram semelhantes. Isso também foi observado na supersegmentação e na subsegmentação. O melhor caso de segmentação foi obtido para similaridade igual 90 e TMO igual a 40, resultando em um valor de D igual 0,45. Essa segmentação foi avaliada na classificação da cobertura e uso da terra, considerando os parâmetros, profundidade e número de árvores do método RF.

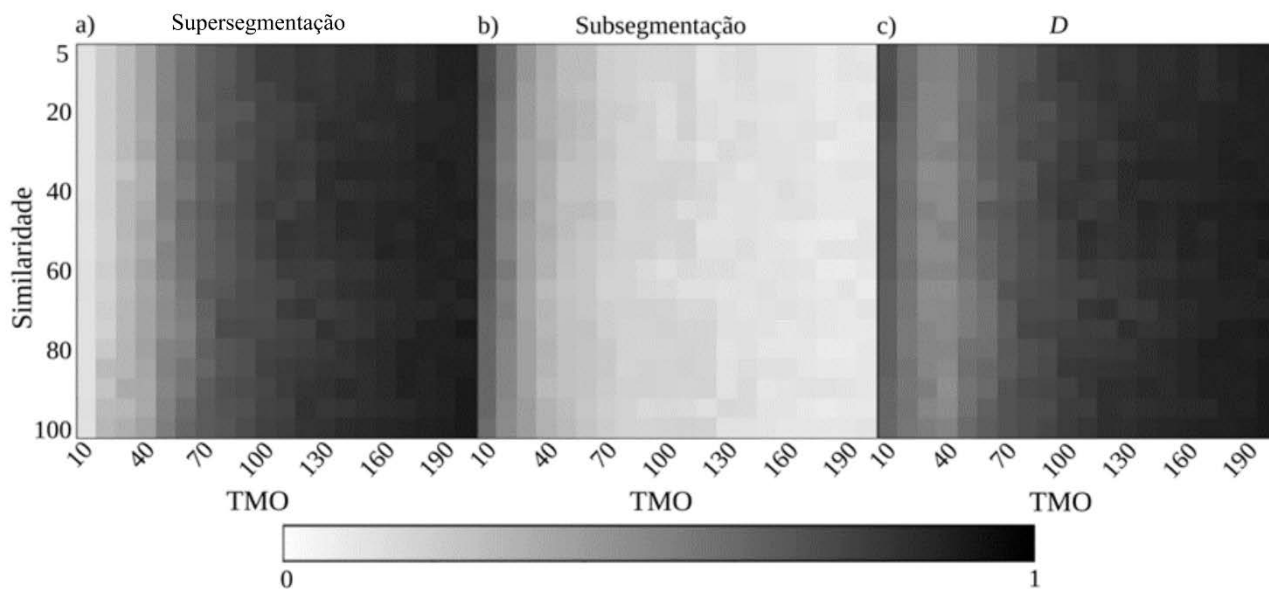
### Classificação da cobertura e uso da terra

A partir da segmentação, foram avaliados os parâmetros do RF e as relevâncias acumuladas. As classificações mais acuradas foram com relevâncias acumuladas iguais a 85%, e valores de PC maiores que 80% (Figura 4a). As classificações com menores valores de PC foram com número de árvores e profundidade menores que 10. As classificações mais acuradas, com PC próximo a 80%, (Figura 4a) foram obtidas com número de árvores e profundidades superiores a 15.

Discriminar as classes de cobertura e uso da terra torna-se mais complexo com o aumento do número de classes e do número de atributos preditivos (Justino et al., 2017). No nosso estudo, utilizamos 134 atributos e 8 classes, presumindo

que os modelos mais simples (menores valores para os parâmetros) resultariam em classificações menos acuradas. O modelo com maior

acurácia foi obtido com profundidade igual a 15 e número de árvores igual a 45, resultando em PC igual a 80,5%.



**Figura 3** – Valores médios de: a) Supersegmentação; b) Subsegmentação; c) Distância euclidiana; d) parâmetros de similaridade e de TMO.

Li et al. (2016) indicam que RF e Support Vector Machines são altamente adequados em classificações GEOBIA de áreas agrícolas, mas que a precisão diminui com o aumento da escala de segmentação (TMO). Os classificadores RF e Árvores de Decisão são os mais robustos com ou sem seleção de recursos. Os autores sugerem que RF deve ser considerado em mapeamento de áreas agrícolas. Além disso, a precisão da classificação é diretamente relacionada à homogeneidade/ heterogeneidade dos objetos segmentados. Ahmed et al. (2017) conseguiram uma acurácia global de até 95,0% na classificação de espécies de vegetação utilizando o método RF em imagens multiespectrais.


O comportamento dos valores de PC e do total de atributos preditivos em relação às relevâncias acumuladas, é observado nas figuras 4b e 4c. A figura 4b ilustra os valores de PC, com a classificação mais acurada, em relação às relevâncias acumuladas. As acurácias das classificações se mantiveram próximas a 80%, entre as relevâncias acumuladas de 60% a 100%. No entanto, o total de atributos preditivos (Figura 4c) reduziu gradativamente. Para a relevância acumulada igual a 60%, a redução no número de atributos preditivos foi superior a 96% e PC próximo a 80%. O modelo mais acurado, com relevância acumulada igual a 85%, proporcionou redução superior a 57%, e mostra a importância da relevância acumulada em remover atributos

preditivos redundantes e aumentar a acurácia do mapeamento.

As relevâncias dos atributos preditivos para o modelo mais acurado (Figura 5) foram com número de árvores igual a 45, profundidade igual a 15 e relevância acumulada igual a 85%. O desvio padrão das texturas MDI e VAR foram os mais relevantes para discriminar as classes de cobertura e uso da terra. O MDI retorna à homogeneidade do local e o VAR é uma medida de dispersão em torno da média das combinações entre o pixel de análise com seus vizinhos. Classes como Campo e Agricultura são mais homogêneas e menores valores de variância, ao contrário de Mata Nativa e Banhado menos homogêneas e maiores variações de texturas.

A importância das texturas é destacada por Hurni et al. (2013), que obtiveram um aumento superior a 22% na classificação da cobertura e uso da terra ao adicionar imagens de texturas. Lock & Kirchner (1997) utilizaram algoritmos de medida de textura e observaram que eles foram mais eficientes na separação de classes de cobertura e uso da terra apenas quando as texturas das classes eram bem diferenciadas. Quando as diferenças de texturas não eram significativas as classes não foram bem discriminadas. Jenicka & Suruliandi (2014) utilizaram modelo multivariado de textura (MDLTP) na classificação de cobertura e uso da terra com imagens de sensoriamento remoto, e

destacaram resultados estáveis, mesmo para tamanhos de janela pequenos, um número



**Figura 4** - a) Valores de PC (%) obtidos a partir da relevância acumulada igual a 85%, considerando os parâmetros profundidade e número de árvores; b) valores de PC (%); c) total de atributos preditivos para as relevâncias acumuladas.

No segundo grupo de relevâncias, as imagens RAS, das quatro imagens utilizadas, apenas o desvio padrão da banda VV (DPVV) não foi considerado.

Imagens RAS são importantes na separação de classes com diferenças de umidade, como Campo e Banhado, e com variações de biomassa, como as classes Agricultura e Solo exposto.

Symeonakis et al. (2018) obtiveram aumento de 10% na acurácia no mapeamento da cobertura e uso da terra integrando imagens ópticas e RAS, quando comparado a classificação apenas com imagens ópticas. Van Tricht et al. (2018) utilizaram o classificador RF na discriminação de culturas agrícolas por meio de imagens ópticas e RAS, e alcançaram acurácias globais de 82%, diferenciando até oito tipos de culturas. Outro destaque, é que a combinação de imagens ópticas e RAS resultaram em acurácias maiores, quando comparadas com classificações por meio de imagens únicas.

No terceiro grupo de relevância, as bandas ópticas do Sentinel 2, a banda 11 teve a maior relevância. Os índices espectrais são o último grupo de relevância. O Índice de estresse da umidade calculado com a banda 11 e 7 (MSI17), resultou no maior valor de relevância. A banda 11 está relacionada com a quantidade de água nas folhas.

Como a maioria das classes é de espécies de vegetação com idades diferentes, a concentração de água nas folhas, pode ser o motivo de a banda 11 e o índice MSI17 apresentarem as maiores relevâncias dentro desses grupos.

mínimo de amostras de treinamento a captura de padrões uniformes.

### **inconsistências das Apps averbadas no CAR**

Com intuito de avaliar as APPs averbadas no CAR (Figura 6a), a classificação da cobertura e uso da terra obtida com número de árvores igual a 45, profundidade igual a 15 e relevância acumulada igual a 85%, resultou em um PC de 80,5%.

As áreas da classe Agricultura correspondem a rizicultura, em fase de diferenciação floral e de florescimento, e as áreas de Solo exposto correspondem a rizicultura, ainda em fase de germinação e de perfilamento. As áreas de Mata nativa, Floresta Estacional Semidecidual.

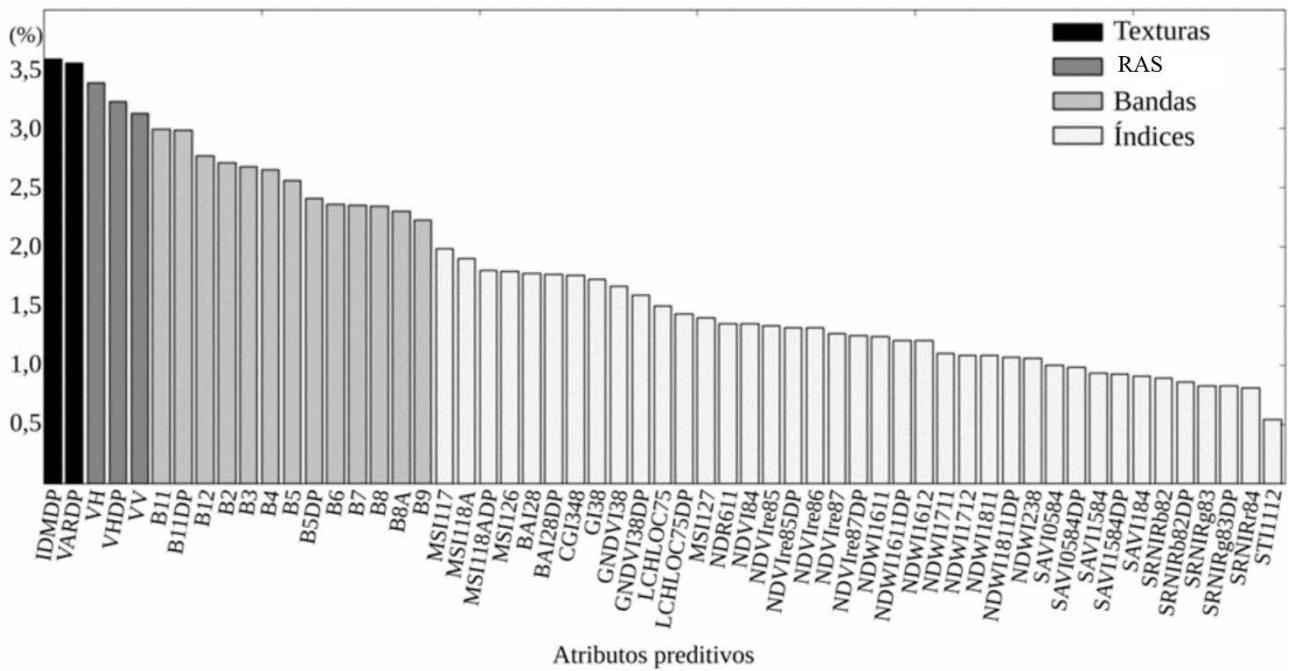
A classe Silvicultura ocorre apenas em pequenas áreas, principalmente a espécie *Pinus Elliottii*.

A classe Campo é a maior área de cobertura e uso da terra no município, composta por vegetação campestre nativa, utilizada no pastoreio de bovinos, bubalinos e equinos. A classe Banhado se concentra na área do Banhado Grande. A classe Água, é formada por corpos d'água artificiais, rios e lagoas. O urbano de Santo Antônio da Patrulha está representado na classe Área urbana.

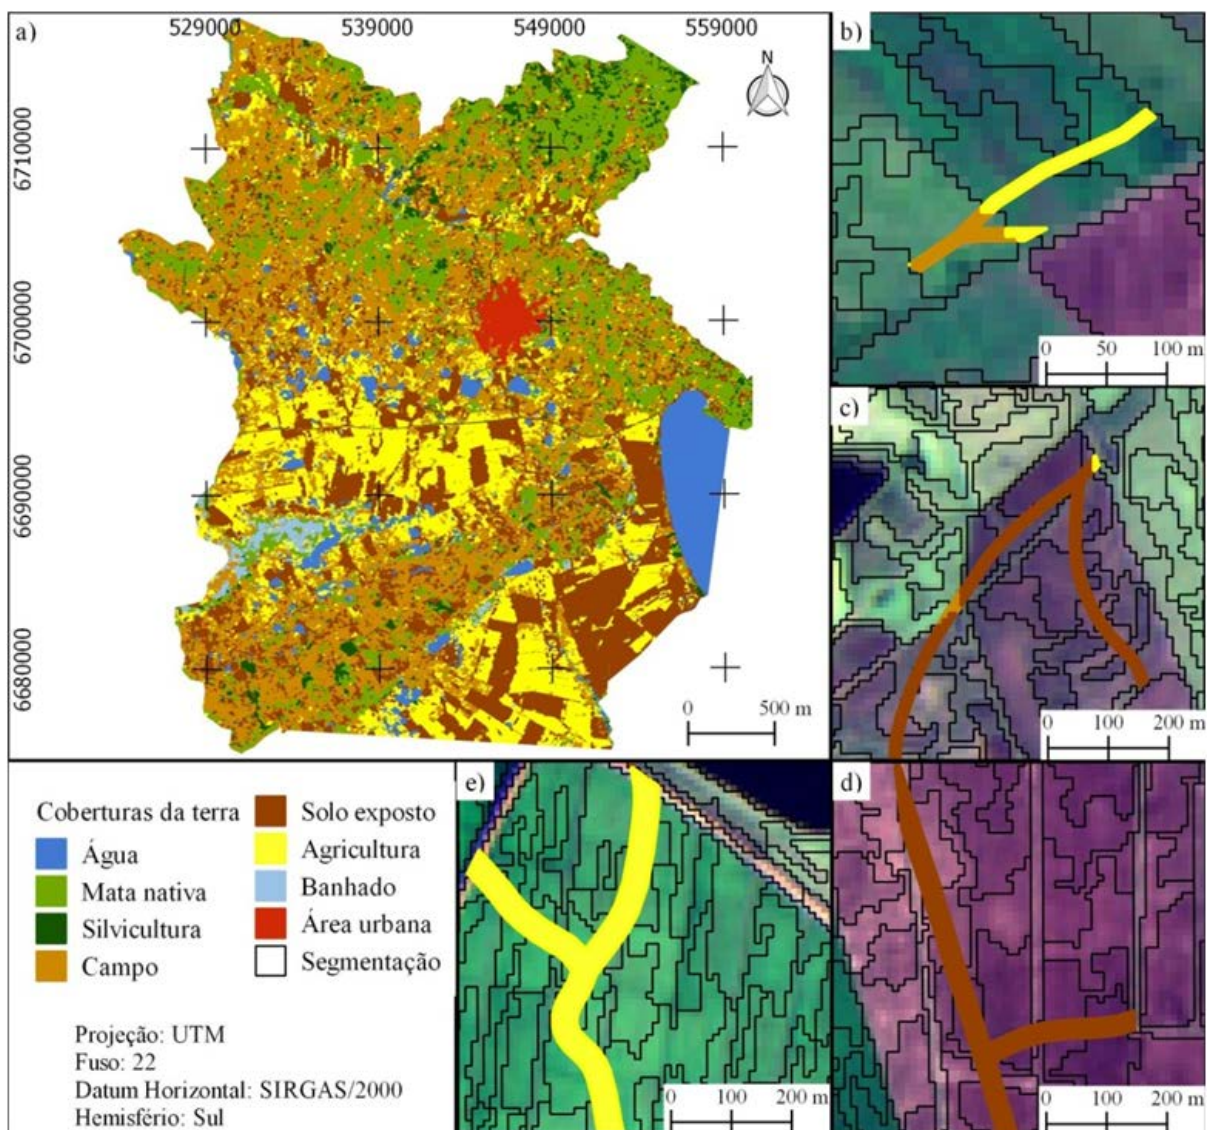
A figura 6b ilustra uma APP averbada em área menor que 1 módulo fiscal (18 ha), com uma faixa de recuperação igual a 5 m, em que parte da APP averbada no CAR foi classificada como Agricultura.

Essas Inconsistências, também podem ser verificadas na figura 6c, em que a APP averbada (8 m de recuperação) foi classificada como Solo Exposto.





**Figura 5** - Relevâncias dos atributos preditivos obtidos com número de árvores igual a 45, profundidade igual a 15 e relevância acumulada igual a 85%.



**Figura 6** - a) Classes de cobertura e uso da terra; b) APP em área de 1 módulo fiscal; c) APP em área de 2 módulos fiscais; d) APP em área de 4 módulos fiscais; e) APP em área superior a 4 módulos fiscais.

Com base na resposta espectral da imagem em composição cor verdadeira, a reflectância se assemelha a solo úmido exposto.

Destacamos a qualidade da classificação da cobertura e uso da terra utilizando OBIA, uma vez que, mesmo que as APPs averbadas sejam menores que a resolução espacial da imagem, foi possível discriminar as classes e localizar inconsistências. Nas áreas maiores, entre 2 e 4 módulos fiscais, também foram verificadas inconsistências. Na figura 6c, a APP averbada com uma faixa de recuperação de 15 m está sobre área de solo exposto.

Nessa área, são observados objetos geográficos gerados pela segmentação, representando diques de irrigação da rizicultura. Na figura 6d, uma APP com faixa de recuperação de 20 m (áreas maiores que 4 módulos fiscais), a APP foi classificada como Agricultura. Com base nas características da reflectância na imagem, são áreas de rizicultura.

As porcentagens das APPs contidas nas classes de cobertura e uso da terra, tabela 1, consideram as divisões dos módulos fiscais propostas no CAR. A análise das APPs averbadas em propriedades menores que 1 módulo fiscal (18 ha), mostra que dos 95,96 ha, a maior parte, foi classificada como Campo e Mata nativa, ou seja, 74,44% do total das APPs. As classes Solo exposto e Agricultura representaram 19,82 ha (20,66%). O restante foi classificado como Silvicultura (2,06%), Água (2,69%) e Banhado (0,15%). Em APPs averbadas em propriedades entre 1 e 2 módulos fiscais, tabela 1, os resultados foram semelhantes, mas com predomínio das classes Campo e Mata nativa.

Em APPs averbadas em propriedades entre 2 e 4 módulos fiscais (36 a 72 ha), observa-se aumento das classes Solo exposto e Agricultura, e decréscimo das classes Campo e Mata nativa. Comportamento semelhante ocorre nas APPs averbadas em propriedades maiores que 4 módulos fiscais (72 ha), aumento nas classes

Solo exposto e agricultura, totalizando 1078,14 ha (64,67%) das áreas averbadas como APP, e diminuição das classes Campo e Mata nativa 411,78 ha (24,70%) das áreas de APPs.

Nossos resultados permitiram quantificar as inconsistências entre as APPs averbadas e a classificação da cobertura e uso da terra, e evidenciar que grande parte das áreas averbadas como APPs estão ocupadas para fins agrícolas. As maiores inconsistências foram identificadas em propriedades superiores a 4 módulos.

**Tabela 1** - Total de APPS (ha) e percentual das classes de cobertura e uso da terra.

Módulo Fiscal	1	2	4	> 4
<b>Total APPs (ha)</b>	95,96	119,62	293,96	1667,14
<b>Água (%)</b>	2,69	4,51	10,63	8,44
<b>Mata nativa (%)</b>	32,17	28,56	17,13	10,46
<b>Silvicultura (%)</b>	2,06	2,28	1,55	1,62
<b>Campo (%)</b>	42,27	36,85	28,32	14,24
<b>Solo Exposto (%)</b>	13,02	19,85	26,29	29,22
<b>Agricultura (%)</b>	7,64	7,26	15,85	35,45
<b>Banhado (%)</b>	0,15	0,69	0,23	0,57

As devidas tomadas de decisão devem ser feitas a campo. A metodologia aplicada neste trabalho teve como proposta apenas identificar inconsistências nas informações declaradas no CAR. Mas, destacamos que a identificação dessas inconsistências permitiria maior agilidade restringindo os locais de fiscalização.

Nossas análises são corroboradas pelos estudos de Tupiassu et al. (2017); Coutinho & Carneiro (2017), que indicaram que o CAR priorizou o estímulo às adesões, em oposição ao interesse de rigor no controle dos dados e documentações apresentados, e que transferiu aos produtores rurais uma responsabilidade que deveria ser do governo. Tais fatos, e a ausência de condições técnicas, físicas e financeiras para validação dos cadastros pode gerar uma série de inconsistências nos bancos de dados do sistema e na política fundiário-ambiental brasileira.

## CONSIDERAÇÕES FINAIS

A avaliação das segmentações mostrou aumento da supersegmentação para os maiores valores do parâmetro TMO e um comportamento contrário para os valores da subsegmentação, ou seja, aumentando TMO o valor da subsegmentação diminui. E a similaridade apresentou menor influência na supersegmentação e na subseg-

mentação.

A classificação mais acurada foi obtida com número de árvores igual a 45, profundidade igual a 15 e relevância acumulada igual a 85%. As classificações mais acuradas, com PC próximo a 80%, foram obtidas com número de árvores e profundidades superiores a 15. Utilizando rele-

vância acumulada igual a 85%, reduziu em 57% o número de atributos preditivos, o que indica a importância da relevância acumulada em remover atributos redundantes e aumentar a acurácia do mapeamento de cobertura e uso da terra.

A metodologia proposta permitiu quantificar inconsistências entre as APPs averbadas e a classificação de cobertura e uso da terra, evidenciando que grande parte das áreas averbadas como APPs estão ocupadas para fins agrícolas. As maiores inconsistências foram

identificadas em propriedades superiores 4 módulos. Destaca-se que o município adotado como estudo de caso, inserido em uma Área de Proteção Ambiental do Banhado Grande (APABG), ainda está em fase de aprovação do Plano de Manejo para a gestão dos empreendimentos. Então, análises baseadas no Novo Código Florestal podem ser extremamente relevantes. No entanto, também devemos considerar que algumas das propriedades analisadas, podem estar se adequando aos prazos estipulados em Lei.

## REFERÊNCIAS

- ABDIKAN, S.; SANLI, F.B.; USTUNER, M.; CALO, F. Land cover mapping using Sentinel-1 sar data. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 41, 2016.
- AHMED, O.S.; SHEMROCK, A.; DOMINIQUE, C.; DILLON, C.; WILLIAMS, G.; WASSON, R.; FRANKLIN, S.E. Hierarchical land cover and vegetation classification using multispectral data acquired from an unmanned aerial vehicle. **International Journal of Remote Sensing**, v. 38, n. 8– 10, p. 2037–2052, 2017.
- BRASIL. **Decreto nº 7.830, de 17 de outubro de 2012**. Dispõe sobre o Sistema de Cadastro Ambiental Rural, o Cadastro Ambiental Rural, estabelece normas de caráter geral aos Programas de Regularização Ambiental, de que trata a Lei nº 12.651, de 25 de maio de 2012, e dá outras providências. 2012. Diário Oficial da União, Brasília, DF, 18 de outubro de 2012. Seção 1, p.1. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/\\_Ato2011-2014/2012/Decreto/D7830.htm](http://www.planalto.gov.br/ccivil_03/_Ato2011-2014/2012/Decreto/D7830.htm)>. Acesso em 10 novembro de 2018.
- BRASIL. **Lei nº 12.651, de 25 de maio de 2012**. Dispõe sobre a proteção da vegetação nativa; altera as Leis nos 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006; revoga as Leis nos 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, e a Medida Provisória nº 2.166-67, de 24 de agosto de 2001; e dá outras providências. 2012. Diário Oficial da União, Brasília, DF, Ano CXLIX, n. 102, 28 maio 2012. Seção 1, p.1. Disp.em: <[http://www.planalto.gov.br/ccivil\\_03/\\_ato2011-2014/2012/lei/112651.htm](http://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/112651.htm)>. Acesso em 10 novembro de 2018.
- BREIMAN, L. Random Forests. **Machine Learning**, v. 45, p. 5-32, 2001.
- CÂMARA, G.; SOUZA, R.C.M.; FREITAS, U.M.; GARRI, J. SPRING: Integrating remote sensing and GIS by object-oriented data modelling. **Computers and Graphics**, v. 20, n. 3, p. 395-403, 1996.
- CLINTON, N.; HOLT, A.; SCARBOROUGH, J.; YAN, L.; GONG, P. Accuracy assessment measures for object based image segmentation goodness. **Photogramm. Eng. Remote Sens.**, v. 76, p. 289–299, 2010.
- COUTINHO, L.S. & CARNEIRO, R.A. PONDERAÇÕES SOBRE O CAR – CADASTRO AMBIENTAL RURAL E SUA EFETIVIDADE. **Revista Jurídica Direito, Sociedade e Justiça/RJDSJ**, v. 5, n. 1, p. 141-153, 2017.
- HALMENSCHLAGER, C. **Um Algoritmo para indução de árvores e regras de decisão**. Porto Alegre, 2002. 112 f. Dissertação (mestrado), Instituto de Informática, Universidade Federal do Rio Grande do Sul.
- HARALICK, R.M.; SHANMUGAM, K.; DINSTEN, H. Textural Features for Image Classification. **IEEE Transactions on systems, man and cybernetics**, v. 3, n. 6, p. 610-621, 1973.
- HURNI, K.; HETT, C.; EPPRECHT, M.; MESSERLI, P.; HEINIMANN, A. A Texture-Based Land Cover Classification for the Delineation of a Shifting Cultivation Landscape in the Lao PDR Using Landscape Metrics. **Remote Sens.**, v. 5, n. 7, p. 3377-3396, 2013.
- JENICKA, S. & SURULIANDI, A. A textural approach for land cover classification of remotely sensed image. **CSI Transactions on ICT**, v.2, p. 1-9, 2014.
- JUSTINO, R.C.; MARTINES, M.R.; KAWAKUBO, F. Classificação do Uso da Terra e Cobertura Vegetal utilizando Técnicas de Mineração de Dados. **Revista do Departamento de Geografia Universidade de São Paulo**, v. 33, p. 36-46, 2017.
- LALIBERTE, A. & RANGO, A. Texture and Scale in Object-Based Analysis of Subdecimeter Resolution Unmanned Aerial Vehicle (UAV) Imagery. **IEEE Transactions on Geoscience and Remote Sensing**, v.47, n. 3, p. 761 - 770, 2009.
- LI, M.; MA, L.; BLASCHKE, T. A systematic comparison of different object-based classification techniques using high spatial resolution imagery in agricultural environments. **International Journal of Applied Earth Observation and Geoinformation**, v. 49, p. 87-98, 2016.
- LOCK, R.E.N. & KIRCHNER, F.F. Classificação de imagens multiespectrais Landsat TM e feições de textura: Mapeamento da cobertura da terra. **Floresta**, v. 27, n. (1/2), p. 41-58, 1998.
- MA, L.; CHENG, L.; LI, M.; LIU, Y.; MA, X. Training set size, scale, and features in Geographic Object-Based Image Analysis of very high resolution unmanned aerial vehicle imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 14–27, 2015.
- Ma, L.; Fu, F.; Blaschke, T.; Li, M.; Tiede, D.; Zhou, Z.; Ma, X.; Chen; D Evaluation of Feature Selection Methods for Object-Based Land Cover Mapping of Unmanned Aerial Vehicle Imagery Using Random Forest and Support Vector Machine Classifiers. **ISPRS International Journal of Geoinformation**, v. 6, n. 2, p. 51, 2017.
- PONTIUS, R. & MILLONES, M. Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, p. 4407-4429, 2011.
- RADOUX, J.; CHOMÉ, G.; JACQUES, D.; WALDNER, F.; BELLEMANS, N.; MATTON, N.; LAMARCHE, C.; D'ANDRIMONT, R.; DEFOURNY, P. Sentinel-2's Potential for Sub Pixel Landscape Feature Detection. **Remote Sens.**, v. 8, n. 6, p. 488, 2016.
- SCHULTZ, B.; FORMAGGIO, A.R.; EBERHARDT, I.D.R.; SANCHES, I D.A.; OLIVEIRA, J.C.; LUIZ A. J.B. Classificação orientada a objetos em imagens multitemporais Landsat aplicada na identificação de cana-de-açúcar e soja. **Revista Brasileira de Cartografia**, v. 68, n. 1, p. 131-143, 2016.
- SOUSA, S.B. & FERREIRA, L.G. Mapeamento da cobertura e uso da terra: uma abordagem utilizando dados de sensoriamento

- remoto óptico multitemporais e provenientes de múltiplas plataformas. **Revista Brasileira de Cartografia**, v. 66, n. 2, p. 321-336, 2014.
- SYMEONAKIS, E.; HIGGINBOTTOM, T.P.; PETROULAKI, K.; RABE, A. Optimisation of Savannah Land Cover Characterisation with Optical and SAR Data. **Remote Sens.**, v. 10, n. 4, p. 499, 2018.
- TUPIASSU, L.; GROS-DESORMAUX, J.R.; CRUZ, G.A.C. Regularização Fundiária e Política Ambiental: Incongruências do Cadastro Ambiental Rural no Estado do Pará. **Rev. Bras. Polít. Públicas (Online)**, Brasília, v. 7, n. 2, p. 187-202, 2017
- VAN TRICHT, K.; GOBIN, A.; GILLIAMS, S.; PICCARD, I. Synergistic Use of Radar Sentinel-1 and Optical Sentinel-2 Imagery for Crop Mapping: A Case Study for Belgium. **Remote Sens.**, v. 10, p. 1642, 2018.

*Submetido em 14 de julho de 2020*

*Aceito para publicação em 29 de dezembro de 2020*