



Classificação Baseada em Objeto de Tipologias de Cobertura Vegetal em Área Úmida Integrando Imagens Ópticas e SAR

Object-based Classification of Vegetation Cover Typologies in Wetland, Integrating Optical Images and SAR

Tássia Fraga Belloli¹, Laurindo Antonio Guasselli², Tatiana Kuplich³, Luis Fernando Chimelo Ruiz⁴, João Paulo Delapasse Simioni⁵

¹ Universidade Federal do Rio Grande do Sul, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Porto Alegre, Brasil. tassiabellolif@gmail.com.

ORCID: <https://orcid.org/0000-0001-6365-7796>

² Universidade Federal do Rio Grande do Sul, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Porto Alegre, Brasil. laurindo.guasselli@ufrgs.br.

ORCID: <https://orcid.org/0000-0001-8300-846X>

³ Instituto Nacional de Pesquisas Espaciais, Centro Regional Sul de Pesquisas Espaciais, Santa Maria, Brasil. tatiana.kuplich@inpe.br

ORCID: <https://orcid.org/0000-0003-0657-4024>

⁴ Santos Lab, Núcleo de pesquisa e desenvolvimento de tecnologias inovadoras, Rio de Janeiro, Brasil. ruiz.ch@gmail.com.

ORCID: <https://orcid.org/0000-0003-3800-6902>

⁵ Universidade Federal do Rio Grande do Sul, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Porto Alegre, Brasil. geojoapaulo@gmail.com.

ORCID: <https://orcid.org/0000-0001-7426-4584>

Recebido: 05.2021 | Aceito: 11.2021

Resumo: Delinear com precisão os limites das Áreas Úmidas (AUs) e os padrões de cobertura vegetal é um passo essencial para a rápida avaliação e gestão destes ecossistemas. A Análise de Imagens Baseada em Objeto (*Object-Based Image Analysis* - OBIA) a partir de aprendizado de máquina e da integração de dados ópticos e de radar apresentam vantagens em relação a outras técnicas no mapeamento da cobertura vegetal nos ecossistemas de AUs. Este estudo tem como objetivo classificar tipologias de cobertura vegetal em áreas úmidas, integrando imagens ópticas e SAR dos satélites Sentinel-1 e 2A e o algoritmo Random Forest à classificação OBIA, utilizando como estudo de caso o Banhado Grande, localizado no Rio Grande do Sul. Como resultados, as polarizações VH e VV do Sentinel-1 obtiveram a maior relevância na classificação (18,6%). Entre as bandas ópticas as maiores relevâncias ocorreram para as bandas Borda Vermelha e Infravermelho Médio. A partir dos atributos ópticos, a classificação obteve acurácia de 86,2%. Quando inseridos os atributos SAR mais importantes, a acurácia aumentou para 91,3%. A classe Macrófitas Emergentes (ME), correspondente à espécie *Scirpus giganteus*, alcançou a melhor acurácia (91%), com área estimada em 1.507 ha. Concluímos que a integração de imagens aliada ao método de classificação possibilitou identificar e delimitar a extensão das tipologias vegetais e a área total do ecossistema. Os resultados acurados demonstram que esta abordagem metodológica pode ser expandida para outras áreas úmidas palustres subtropicais.

Palavras-chave: Mapeamento de vegetação em Banhados. OBIA. Random Forest. Sentinel-1 e 2A.

Abstract: Accurately mapping the boundaries of wetlands and patterns of vegetation cover is an essential step for rapid assessment and management of wetlands. The Object-Based Image Analysis (OBIA) as from machine learning and fusion of optical and radar data has advantages over other techniques for mapping vegetation cover in wetlands ecosystems. This study aims to classify vegetation cover typologies in wetlands, integrating optical and SAR images from the Sentinel-1 and 2A satellites and the Random Forest algorithm in OBIA classification, using Banhado Grande, located in the Rio Grande do Sul as a case study. As a result, the VH and VV polarizations of Sentinel-1 obtained the highest relevance in the classification (18.6%). Among the optical bands, the greatest relevance occurred for the Red Edge and Medium Infrared bands. From the optical attributes, the classification obtained an accuracy of 86.2%. When the most important SAR attributes were inserted, the accuracy increased to 91.3%. The Emergent Macrophyte (ME) class, corresponding to the species *Scirpus giganteus*, achieved the best accuracy of the classifier (91%), with an estimated area of 1,507 ha. We conclude that the integration of images combined with the classification method made it possible to delimit the extent of vegetation typologies and the total area of the ecosystem. Accurate results show that this methodological approach can be expanded to other subtropical palustrine wetlands.

Keywords: Vegetation mapping in marshes. OBIA. Random Forest. Sentinel-1 e 2A.

1 INTRODUÇÃO

A vegetação possui papel fundamental na provisão e manutenção de múltiplas funções e serviços ambientais fornecidos por Áreas Úmidas (AUs), como manguezais, marismas, turfeiras e banhados (SAINTILAN, 2009; BARBIER et al., 2011; GALLANT, 2015). O reconhecimento e classificação dos padrões de vegetação são importantes ferramentas no planejamento estratégico e conservação desses ecossistemas (DRIVER et al., 2011; WHITESIDE; BARTOLO, 2015; SIEBEN et al., 2016), pois as comunidades vegetais são excelentes indicadores para sinais precoces de distúrbios naturais e de degradação física ou química em AUs (DENNISON et al., 1993; WHITESIDE; BARTOLO, 2015).

Apesar dos seus benefícios ambientais, nas últimas décadas, as AUs têm sofrido drástica degradação e perda de área em todo o mundo, associadas a expansão agrícola e a urbanização (ASSELEN et al., 2013; SAHA; PAL, 2018), e devido a processos naturais como mudanças climáticas, processos costeiros e erosão (TINER et al., 2015). Métodos de classificação de vegetação eficazes em AUs permitem aos cientistas ou gestores de recursos naturais verificar tendências espaciais e temporais das AUs em diferentes escalas e inferir sobre a composição e funções do ecossistema (JANOUSEK; FOLGER, 2018). São ferramentas indispensáveis frente à necessidade de conservação mundialmente reconhecida das AUs (RAMSAR, 2013; IPCC, 2014).

Metodologias baseadas em sensoriamento remoto são amplamente utilizadas para mapeamento, classificação, monitoramento e estimativa de variáveis biofísicas, pois superam as principais dificuldades de cobertura e acessibilidade às AUs (KANDUS et al., 2018). São métodos mais econômicos do que os baseados exclusivamente em trabalho de campo e fornecem informações em diversas escalas temporais (BRISCO et al., 2011; GALLANT, 2015).

Os métodos de classificação da cobertura vegetal em AUs são tipicamente baseados em diferenças estruturais e funcionais entre diferentes comunidades vegetais e regimes hidrológicos (FRANKLIN et al., 2017). Trata-se de uma das questões mais desafiadoras na ciência de sensoriamento remoto devido à alta variabilidade hidrológica temporal (BERHANE, 2018) e ao complexo padrão de distribuição espacial e heterogeneidade espectral das associações de vegetação (DRONOVA et al., 2012).

Uma das técnicas mais utilizadas para classificação da cobertura vegetal é a *Pixel-based Image Analysis* (PBIA) (MOFFET; GORELICK, 2013). Esta abordagem automatizada associa cada pixel da imagem a uma determinada classe, com base na sua assinatura espectral. A abordagem PBIA apresenta algumas restrições no mapeamento de AUs como, por exemplo, a heterogeneidade nos valores de pixels próximos, a existência de pixels mistura, e a variação da umidade do solo e da vegetação que podem gerar diferenças espectrais em uma mesma classe (DRONOVA, 2015).

Análise de Imagens Baseada em Objetos (*Object-Based Image Analysis* - OBIA) é mais adequada para estas restrições em AUs heterogêneas, pois segmenta a imagem em objetos, ou grupos de pixels, com padrão espacial para a etapa de classificação (DRONOVA, 2015; MAHDIANPARI et al., 2019) e utiliza formas e características contextuais e texturais, consistindo em objetos relativamente homogêneos (MISHRA, 2014). Com OBIA, objetos podem ser classificados a partir de aprendizado de máquina, mineração de dados e amostras de treinamento (PU et al., 2011).

Algoritmos de aprendizado de máquina, como *K-nearest neighbor* (KNN), *support vector machine* (SVM), *classification and regression tree* (CART) e *random forest* (RF), têm sido utilizados para classificar a vegetação de AUs nos últimos anos devido a sua flexibilidade na interpretação de relações complexas não lineares (LOU et al., 2020). Estudos anteriores demonstraram que o RF supera métodos como KNN e SVM na classificação da cobertura vegetal em AUs (TIAN et al., 2016; WANG et al., 2019). Ademais, RF tem mostrado alta acurácia de classificação (>88%) na identificação de tipologias de vegetação em AUs (ZHANG e XIE, 2013; FU et al., 2017; MAHDIANPARI et al., 2019; WANG et al., 2019) e de categorias de AUs (TIAN et al., 2016; FRANKLIN; AHMED, 2017).

RF é um algoritmo de previsão não paramétrico baseado em múltiplas árvores de decisão, que pode ser utilizado tanto para classificação de imagens, quanto para regressão (BREIMAN, 2001). RF possui um bom desempenho na identificação de relacionamentos não homogêneos entre variáveis preditoras e a resposta, e com dados multidimensionais, típicos de sensoriamento remoto (TIMM et al., 2012). Entre as vantagens do RF estão a facilidade de implementação, com menor custo computacional para treinar os modelos, determinar

a importância das variáveis e reduzir a dimensão do conjunto de dados, o que possibilita uma classificação mais acurada dos objetos (TIAN et al., 2016; WANG et al., 2019; LOU et al., 2020).

Para lidar com a complexidade física e melhor caracterização da vegetação em AUs, vários estudos destacam a integração de imagens de sensores ópticos e de radares de abertura sintética (*Synthetic Aperture Radar* - SAR) com a técnica OBIA para classificar tipologias de vegetação em AUs, alcançando acurácia superior a 80% (GRENIER et al., 2008; MUI et al., 2015; MAHDIANPARI et al., 2019, LOU et al., 2020). A série Sentinel oferece esta oportunidade com a disponibilidade de imagens ópticas (Sentinel-2A e -2B) e SAR (Sentinel-1A e -1B) (BERGER et al., 2012).

Grenier et al. (2008) aplicaram classificação OBIA com imagens dos satélites SPOT-4 e RADARSAT-1 para classificar vegetação em AUs e adicionar futuramente valores médios de carbono (84% de acurácia). Concluíram que esta integração de imagens permite identificar estrutura e extensão de AUs. Mahdianpari et al. (2019) e Rapinel et al. (2019) destacam o potencial sinérgico dos dados do Sentinel-1e 2A para mapear a vegetação em AUs aplicando RF (acurácia > 90%), e a robustez do modelo RF usando imagens Sentinel.

Para a América do Sul, é fundamental o monitoramento sistemático e consistente das AUs, visto que possui mundialmente a maior porcentagem em área deste ecossistema (45%), com destaque para o Brasil com a maior área úmida tropical (800.720 km²) (GUMBRICHT et al., 2017). Ao longo do século passado as AUs palustres localizadas nas planícies de inundação dos rios e nas áreas costeiras, sofreram severas transformações, induzidas principalmente por sua conversão em área agrícola (MITISCH; GOSSELINK, 2015) e continuam sendo impactadas (ZHOU et al., 2009; ADAM et al., 2010, BELLOLI, 2018).

No Rio Grande do Sul, as AUs palustres conhecidas regionalmente como banhados, foram intensamente modificadas e fragmentadas, principalmente em decorrência da agricultura (BELLOLI, 2016; BELLOLI, 2018). Diante da persistência dos impactos ambientais sobre estes ecossistemas, é essencial delinear com precisão seus limites e o reconhecimento dos padrões de vegetação para sua conservação e manejo sustentável. No entanto, o mapeamento de espécies e tipologias vegetais em AUs palustres é um desafio na comunidade científica, devido ao conteúdo de água na vegetação, a similaridade espectral das espécies aquáticas, a dificuldade de acesso a esses ambientes para o trabalho de campo e a introdução de plantas invasoras, especialmente em pequenas AUs, que desempenham um papel importante na regulação do microclima e mitigação de inundações (WHITESIDE; BARTOLO, 2015).

Deste modo, este estudo objetivou classificar tipologias de cobertura vegetal, integrando imagens ópticas e SAR dos satélites Sentinel-1 e 2A e o algoritmo RF à classificação OBIA, utilizando como estudo de caso o Banhado Grande, uma área úmida palustre, localizada na Região Metropolitana de Porto Alegre, no Rio Grande do Sul.

A partir do método de classificação RF baseado em objeto e da integração de imagens ópticas e SAR, este estudo contribui com a definição dos atributos mais relevantes das imagens dos satélites Sentinel-1 e 2A, bem como com os parâmetros ótimos da segmentação e do classificador RF para obter maior acurácia da classificação de tipologias de cobertura vegetal em uma área úmida palustre do sul do Brasil.

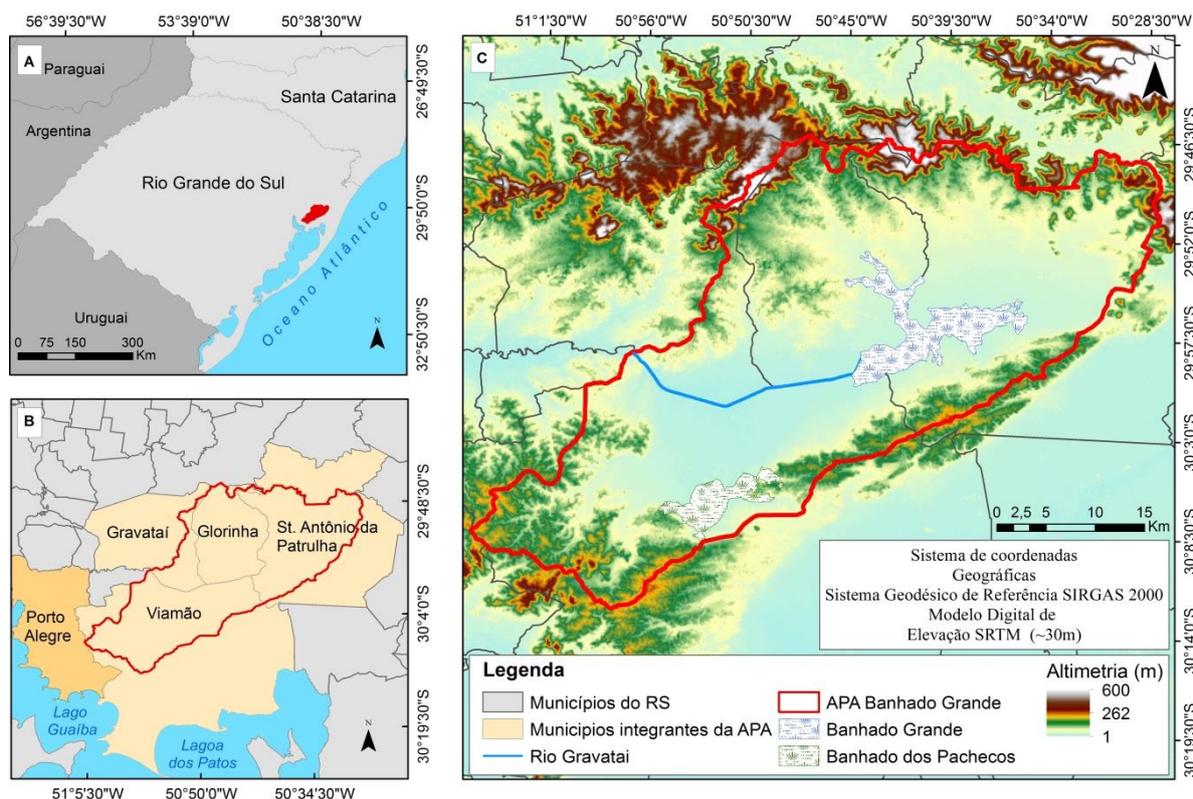
2 ÁREA DE ESTUDO

O Banhado Grande (BG) está situado nas coordenadas 29°57'S e 50°41'W, na região leste do estado do Rio Grande do Sul (RS), com área aproximada de 5.591 ha e altitude de 20 m, (Figura 1). O BG forma o rio Gravataí e atua como seu regulador natural de vazão. É um ambiente palustre inserido em um complexo de AUs, composto por banhados, planícies de inundação, campos inundáveis e arrozais que se conectam em períodos de pulsos de inundação (SIMIONI et al., 2017).

Para proteção e sustentabilidade dos recursos deste complexo de AUs, foi criada a Área de Proteção Ambiental do Banhado Grande (APABG), uma das AUs mais importantes do RS. Com uma área de aproximadamente 137 ha, preserva a diversidade biológica, as funções ecossistêmicas e espécies ameaçadas de extinção (ACCORDI et al., 2003). Nesta região predominam condições climáticas subtropicais, com clima úmido e variação longitudinal das temperaturas médias. A precipitação anual média oscila entre 1700 e 1800 mm, sem estação chuvosa definida (ROSSATO, 2011). Ocorrem diferentes regimes de inundação, com áreas permanentemente inundadas, intermitentes e/ou apenas solos saturados (MALTCHIK et al., 2004; SIMIONI

et al., 2017).

Figura 1– Área de estudo: A) Localização da APABG em relação ao Rio Grande do Sul; B) Localização da APABG em relação à Região Metropolitana de Porto Alegre; C) Localização do BG em relação à APABG.



Fonte: Os autores (2022).

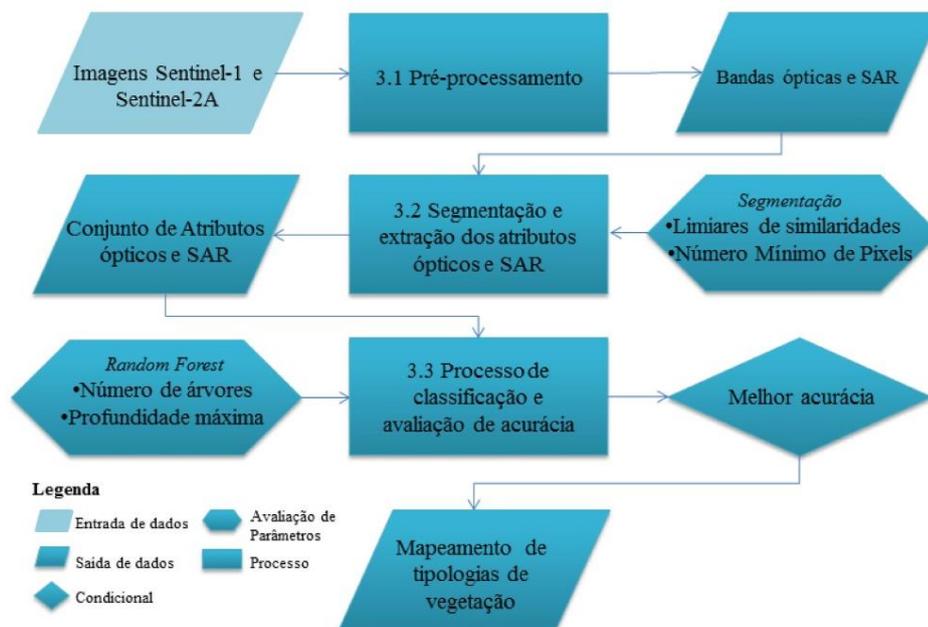
Quanto à geomorfologia, o BG está inserido na Região Geomorfológica da Planície Costeira Interna, na unidade de Planícies e Terraços Lagunares (NIELSEN, 1994). Predominam ambientes sedimentares de turfa heterogênea, interligadas por depósitos de planície de inundação (CPRM, 2020). As turfeiras no BG são ativas, e estão associadas ao maior grau de umidade e maior densidade da vegetação (FRANTZ et al., 1990). Podem ser classificadas como ambiente de “turfeiras não florestadas” cercadas por “terra irrigada”, segunda classificação Ramsar (ACCORDI et al., 2003).

Na cobertura vegetal, predominam as macrófitas aquáticas, com padrão de distribuição e ciclo vital influenciado pela dinâmica de inundações e hidrodinâmica própria no BG, formando um padrão heterogêneo (LEITE; GUASSELLI, 2013). A espécie de maior porte e abrangência em monodominância é a *Scirpus giganteus* (*S. giganteus*), a qual ocorre em áreas com presença de turfa (FRANTZ et al., 1990; LEITE; GUASSELLI, 2013) e distribui-se amplamente no sul da América do Sul, em pântanos de água doce, com forma biológica anfíbia e emergente (IRGANG; GASTAL, 1996; PRATOLONGO et al., 2005). No BG também ocorrem campos úmidos, espécies lenhosas de médio porte, formações arbustivas, e áreas de cultivo de arroz e soja devido às características dos solos e disponibilidade hídrica.

3 ABORDAGEM METODOLÓGICA

Para facilitar a compreensão dos dados, parâmetros e processamentos utilizados nesta pesquisa, o método foi dividido em três etapas: 3.1 Pré-processamento; 3.2 Segmentação e extração dos atributos ópticos e SAR; e 3.3 Processo de classificação e avaliação de acurácia (Figura 2).

Figura 2 – Fluxograma metodológico.



Fonte: Os autores (2022).

3.1 Pré-processamento

Para a classificação das tipologias vegetais no BG foram utilizadas duas imagens obtidas no *website* Copernicus (<https://scihub.copernicus.eu/>). Uma imagem foi obtida do satélite Sentinel-2A, com data de 9 de fevereiro de 2018, utilizando as 13 bandas do sensor *Multispectral Instrument* (MSI), com nível de pré-processamento 1C e com resoluções espaciais de 10 m e 20 m, sendo ortoretificada e convertida para reflectância no topo da atmosfera. A outra imagem provém do satélite Sentinel-1, do sensor SAR, que opera em banda C, com data de 25 de fevereiro de 2018, produto *Ground Range Detected* (GRD) com nível 1 de pré-processamento em polarizações VV e VH, com resolução espacial de 10 m.

A imagem óptica foi pré-processada para o nível 2A para remover os efeitos atmosféricos e converter os valores dos pixels para reflectância da superfície. O pré-processo foi realizado na ferramenta Sen2Cor da ESA (MAIN-KNORN et al., 2017), na Plataforma de Aplicação do Sentinel (*Sentinel Application Platform – SNAP*). Não foram utilizadas as bandas 1 e 10, por serem sensores destinados a armazenar aerossóis costeiros e radiação de nuvem tipo cirrus, respectivamente.

A imagem SAR foi convertida para valores de retroespalhamento e foram aplicados os processos de calibração radiométrica, filtragem do ruído speckle (filtro de Lee Sigma e janela móvel de 5x5) e correção do terreno, utilizando as ferramentas do SNAP. Para a correção do terreno foram utilizadas imagens do Shuttle Radar Topography Mission (SRTM), resolução espacial 30 m, sistema de projeção Universal Transversa de Mercator (UTM), fuso 22, hemisfério Sul, datum horizontal SIRGAS 2000.

As datas das imagens compreendem o período de maturação dos principais cultivos na região da área de estudo, que ocorre a partir do mês de fevereiro no Rio Grande do Sul (CONAB, 2019). Ademais, optamos por usar imagens com ausência de pulsos de inundação, pois estudos prévios indicam que condições submersas ou inundadas introduzem fatores que alteram as características espectrais gerais da vegetação (SILVA et al., 2008), causando confusão entre classes e erros de classificação (MIDWOOD; CHOW-FRASER, 2010).

3.2 Segmentação e extração de atributos ópticos e SAR

O processo de segmentação foi gerado a partir de um conjunto de pixels sementes e de uma análise das similaridades dos pixels com seus vizinhos. Pixels com valores similares são agrupados e assim, formados os objetos. A segmentação foi aplicada às bandas ópticas (2, 3, 4 e 8) com resolução espacial de 10 m da imagem Sentinel-2A. Nesta etapa foi utilizado o método de crescimento de regiões (CARLER et al., 2005), disponível na ferramenta *i.segment* do Sistema de Apoio à Análise de Recursos Geográficos (GRASS-GIS).

Na ferramenta *i.segment*, a segmentação é controlada por dois parâmetros principais, o limiar de

similaridade e o Número Mínimo de Pixels. O limiar de similaridade controla o crescimento dos objetos, e quanto maior for seu valor, maior será a liberdade de crescimento das regiões (objetos). Isto significa que os pixels com valores muito diferentes podem ser agrupados e formar objetos maiores. Os pixels sementes foram iniciados de forma aleatória e avaliados os limiares de similaridades entre 0 e 1, variando 0,1.

O parâmetro Número Mínimo de pixels (NMP) determina o tamanho mínimo dos objetos (MOMSEN, 2012). Os valores de NMP foram avaliados entre 200 e 600, variando 200 pixels. Foi usada uma abordagem iterativa de tentativa e erro para ajustar os parâmetros limiar de similaridade e NMP, selecionando, por fim, os que resultaram no maior valor de acurácia para classificar as tipologias vegetais (ZHOU; TROY, 2008).

A definição de valores para os limiares na segmentação de imagens depende, principalmente, do conhecimento dos padrões de repartição espacial dos objetos da área e da definição da generalização cartográfica ideal, em função da escala cartográfica da abordagem realizada. Esta etapa exige maior atenção devido à inexistência de valores padronizados para as variáveis do algoritmo e, também, por influenciar diretamente na acurácia dos resultados da segmentação (COUTINHO, 1997). Se os valores dos limiares forem muito baixos, o processo não atribuirá pixels aos objetos (fragmentação excessiva). Por outro lado, se forem muito altos, pixels representativos de diferentes classes serão incorretamente agrupados (NASCIMENTO; ALMEIDA FILHO, 1996).

A partir dos objetos gerados após a segmentação, os atributos das bandas ópticas e polarizações foram extraídos. A extração dos atributos consiste em calcular estatísticas básicas das bandas das imagens para os objetos, como média e desvio padrão (LALIBERTE; RANGO, 2011). Esse processo resulta em um conjunto de dados de atributos que serão utilizados na etapa de classificação das tipologias de vegetação em AUs (MOFFETTI; GORELICK, 2013; DRONOVA, 2015). Deste modo, os atributos foram gerados calculando as Médias (M) e Desvios Padrão (DP) das bandas ópticas e polarizações SAR para os objetos, Tabela 1.

Tabela 1– Atributos das bandas ópticas e SAR para os objetos. Abreviações: RE reflectância na Borda Vermelha (*Red Edge*); NIR reflectância no Infravermelho Próximo (*Near-infrared*); e SWIR reflectância no Infravermelho de Ondas Curtas (*Short Wave Infrared*).

Sensor	Bandas espectrais e polarizações	Atributos Médias (M)	Atributos D. Padrão (DP)	Resolução Espacial		
Sentinel-2A (óptico)	B2 azul	B2M	B2DP	10 m		
	B3 verde	B3M	B3DP			
	B4 vermelho	B4M	B4DP			
	B5 RE	B5M	B5DP			
	Sentinel-2A (óptico)	B6 RE	B6M	B6DP	20 m	
		B7 RE	B7M	B7DP		
		B8 NIR	B8M	B8DP		
		B8a RE	B8aM	B8aDP		
Sentinel-2A (óptico)	B11 SWIR	B11M	B11DP	20 m		
	B12 SWIR	B12M	B12DP			
	Sentinel-1 (SAR)	VV	VVM		VVDP	10 m
		VH	VHM		VHDP	

Fonte: Os autores (2022).

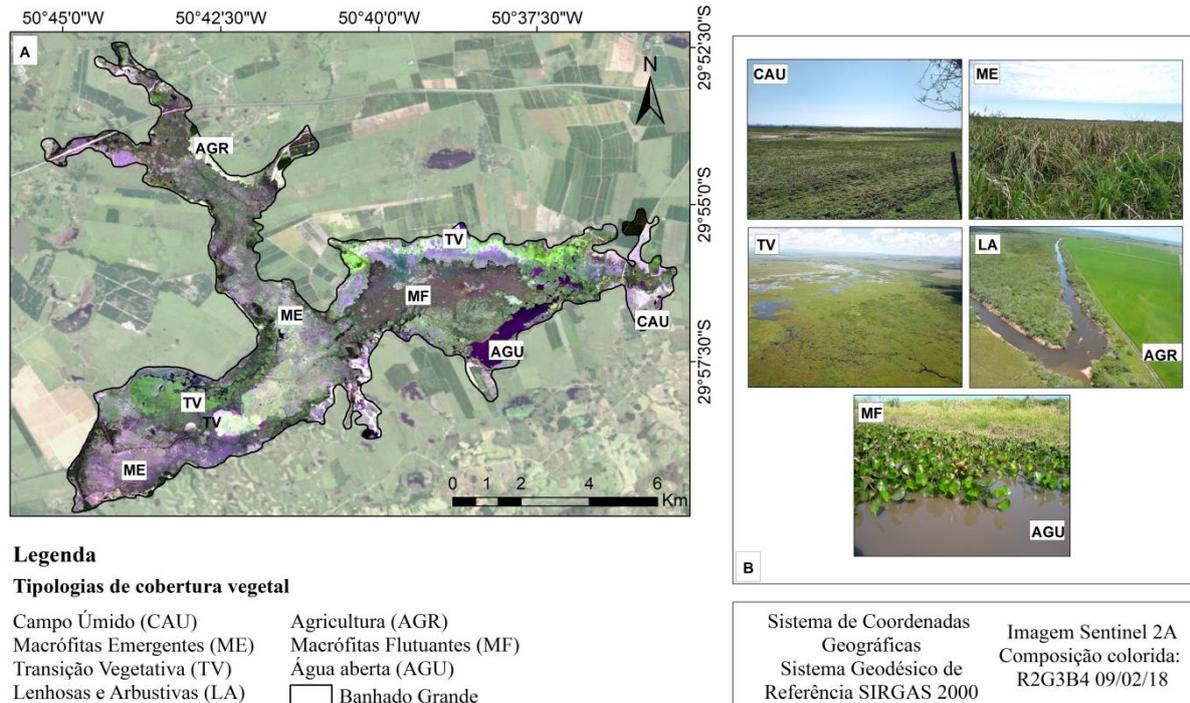
3.3 Processo de classificação e avaliação de acurácia

A determinação das classes de vegetação foi baseada na metodologia de Maltchik et al. (2004). As tipologias correspondem a características de cobertura vegetal semelhante e padrão de espécies. Foram realizadas expedições no rio Gravataí e no BG, no ano de 2018, para identificar e caracterizar as espécies de macrófitas e obter fotografias georreferenciadas. A ferramenta Google Earth e fotografias aéreas fornecidas pela Fundação Municipal do Meio Ambiente de Gravataí auxiliaram no reconhecimento de padrões das espécies vegetais.

Foram definidas as seguintes classes de mapeamento: Macrófitas Flutuantes (MF), Macrófitas Emergentes (ME), Lenhosas e Arbustivas (LA), Campo Úmido (CAU), Transição Vegetativa (TV), Agricultura (AGR) e Água Aberta (AGU). ME compreende espécies fixas no solo, um estrato denso com alturas entre 1,50 m e 1,70 m. Há o predomínio de *Scirpus giganteus*, de forma monoespecífica, mas ocorrem

estandes difusos com outras espécies. MF é composta por Ciperáceas que formam extensas coberturas verdes e homogêneas; TV representa um conjunto de espécies emergentes, flutuantes e arbustivas de pequeno porte, que consistem em formações vegetais diversificadas devido às peculiaridades do terreno e diferenças de saturação na área de transição entre o ambiente terrestre e aquático; CAU está situada normalmente nas bordas dos banhados, é composta por estratos arbustivos e herbáceos, de pequeno porte, e normalmente encontra-se alagada em grande parte do ano; as formações LA encontram-se nas bordas do banhado; na classe AGR predominam o cultivo de arroz irrigado e soja, em áreas adjacentes ao BG. Na Figura 3 são apresentadas a distribuição e representação das tipologias de cobertura vegetal.

Figura 3 – A) Distribuição das tipologias de cobertura vegetal; B) Representação das tipologias de vegetação.



Fonte: Os autores (2022).

As amostras de referência, usadas para a etapa de avaliação de acurácia, compreendem 132 pontos gerados aleatoriamente. A quantidade de amostras está relacionada à dificuldade de obtenção de dados *in situ*, e à impossibilidade de acesso no interior do BG. As classes foram atribuídas aos pontos a partir de visitas de campo, de uma coleção de fotos georreferenciadas e de imagens orbitais disponíveis no Google Earth. As amostras de treinamento, utilizadas para treinar o RF, foram obtidas de forma sistemática, a partir de 658 pontos com espaçamento regular de 300 m entre as amostras.

O RF divide as amostras em subconjuntos e gera uma Árvore de Decisão (AD) para cada subconjunto. Para cada novo subconjunto, um terço das amostras é excluído aleatoriamente, e denominadas como *out-of-bag* (BREIMAN, 2001). As amostras restantes (*in-the-bag*) são usadas para construir a AD e as amostras *out-of-bag* para avaliar o desempenho do modelo e selecionar o subconjunto de treinamento com a maior acurácia. Após o treinamento, a classificação de um novo exemplo é obtida pela votação de cada AD e a amostra é classificada na classe mais votada.

AD é um modelo binário, construído dividindo o conjunto de dados de entrada em nós cada vez mais homogêneos, escolhendo o valor do atributo que minimiza a heterogeneidade (impureza) do nó. Assim, o crescimento da AD é realizado selecionando vetores de atributos que diminuem a impureza de cada nó da árvore. O RF estima as importâncias dos atributos computando o decréscimo médio da impureza dos nós (BREIMAN, 2001; COSTA et al., 2016; TIAN et al., 2016).

O número de árvores e a sua profundidade máxima são parâmetros ajustáveis. Para ambos os parâmetros foram avaliados valores entre 5 e 50, variando 5. Foi utilizado como critério de divisão dos nós da árvore o índice Gini de impureza (MENZE et al. 2009; MURERIWA et al. 2016), Eq. (1):

$$\Delta I = G(\tau) - plG(\tau l) - prG(\tau r) \quad (1)$$

Em que ΔI quantifica o decréscimo do índice Gini, após a divisão (*impureza Gini*); $G(\tau)$ é o valor do índice Gini para o nó, antes da divisão; pl é a probabilidade das predições das classes para o nó esquerdo (τl); pr é a probabilidade das predições das classes para o nó direito (τr); $G(\tau r)$ é o valor do índice Gini para o nó direito; e $G(\tau l)$ é o valor do índice Gini para o nó esquerdo.

Com as amostras de referência foram calculadas as acurácias da classificação por meio do índice Proporção Correta (PC) (PONTIUS; MILLONES, 2011), Acurácia do Produtor (AP) e Acurácia do Usuário (AU) (CONGALTON, 1991). O cálculo de PC inicia com a geração da matriz de confusão em relação aos dados de referência com a classificação. Posteriormente é estimada a matriz populacional que expressa cada entrada na matriz de confusão como uma probabilidade (ou frequência relativa), que representa a proporção de cada combinação das amostras da classe de referência com a classe mapeada em relação ao total (PONTIUS; MILLONES, 2011). Com a matriz populacional, calcula-se o PC, conforme Eq. (2):

$$PC = \sum_{j=1}^J D_{jj} \quad (2)$$

Em que PC é a proporção correta; J é o número total de classes; j é a coluna estimada da matriz populacional; e D_{jj} é a matriz diagonal da matriz populacional.

Na última etapa, os dados foram avaliados em relação aos parâmetros do classificador e o melhor caso do método, considerando o valor de PC, foi apresentado como resultado. As classificações e as validações foram desenvolvidas em programação Python 3. Com a biblioteca de aprendizado de máquina *Scikit-Learn* foram elaboradas as rotinas das classificações (PEDREGOSA et al., 2011) e com a biblioteca *Numpy* as validações (VAN DER WALT et al., 2011). Os *scripts* integram o *plugin GeoPatterns*, disponível no *software QGIS* (RUIZ, 2019).

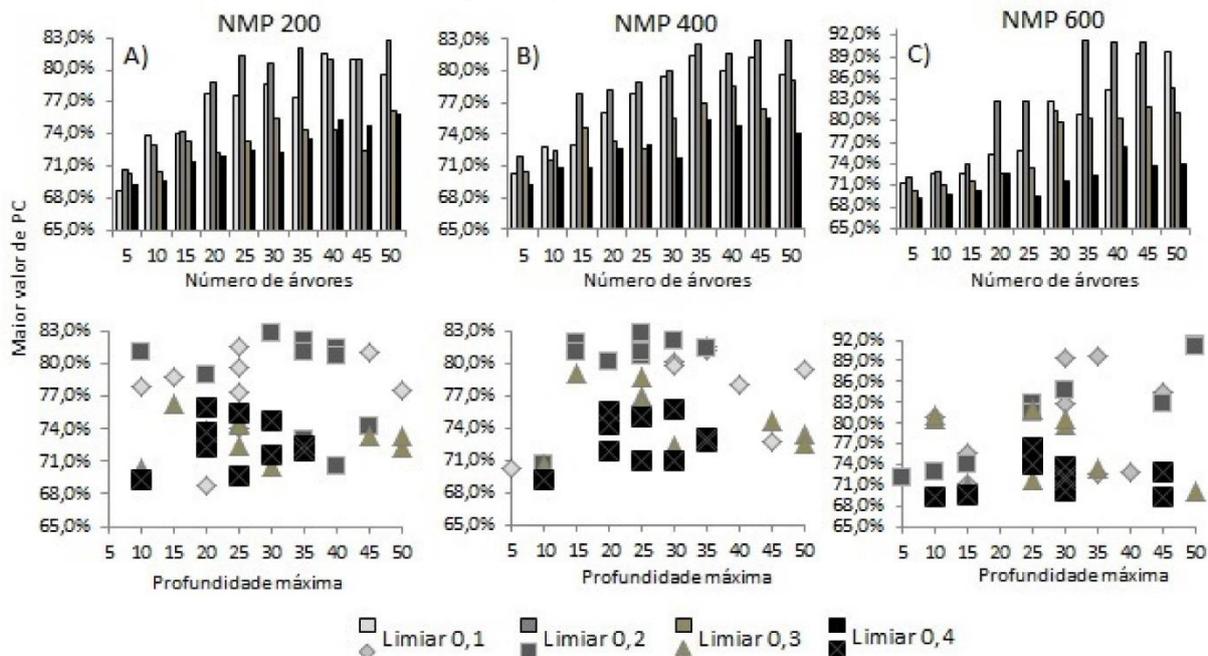
4 RESULTADOS E DISCUSSÕES

As tipologias de vegetação no BG apresentam alta variabilidade espectral. Consequentemente, os objetos gerados com limiares de similaridade mais altos ($>0,4$) agregaram diferentes classes, o que dificultou a discriminação das tipologias e resultou em classificações menos acuradas ($<65\%$). A Figura 4 apresenta para cada NMP os maiores valores de acurácia por número de árvores e limiar de similaridade (gráficos superiores) e a profundidade máxima que os mesmos ocorreram (gráficos inferiores).

Para os três valores avaliados de MNP (200, 400 e 600 pixels) foram obtidas altas acurácias ($>80\%$) com o limiar de similaridade = 0,2, seguidas do limiar 0,1. O melhor caso da segmentação foi obtido com limiar de similaridade = 0,2 e NMP = 600 pixels (Figura 4C). Pode ser observado que a menor acurácia foi obtida para os parâmetros Número de Árvores e Profundidade Máxima = 5, retornando valor de PC = 72,1%. Ao aumentar os valores dos parâmetros Número de Árvores e Profundidade máxima no limiar 0,2 verificou-se maior acurácia para Número de Árvores = 35 e Profundidade Máxima = 50, com PC = 91,3%.

O segundo melhor caso da segmentação foi obtido com NMP = 400 (Figura 4B). A menor acurácia foi obtida para os parâmetros Número de Árvores e Profundidade Máxima = 10, retornando valor de PC = 71,5%. A maior acurácia ocorreu para Número de Árvore = 45 e Profundidade Máxima = 25, com PC = 82,96%. No NMP 200 (Figura 4A) o menor valor de PC = 70,6%, para os parâmetros Número de Árvore = 5 e Profundidade Máxima = 40. A maior acurácia ocorreu com PC = 82,81% para Número de Árvore e Profundidade Máxima = 50 e 30, respectivamente.

Figura 4 – Valores de PC para os parâmetros do RF e limiares de similaridade.



Fonte: Os autores (2022).

A seleção do melhor limiar evita a subsegmentação ou a supersegmentação. As maiores acurácias na classificação das tipologias de cobertura vegetal ocorreram em segmentações com limiares de similaridades mais baixos (0,1 e 0,2). O oposto ocorreu para os parâmetros do RF, pois sua complexidade é ampliada com o aumento dos valores dos parâmetros Número de Árvores e Profundidade Máxima, e pode ser uma das razões das menores acurácias resultarem dos menores valores dos mesmos nos limiares mencionados.

Foi observada uma tendência de aumento nos valores das menores e maiores acurácias com o aumento dos parâmetros NMP. A melhor acurácia foi alcançada com NMP = 600 pixels, mas devido aos valores das acurácias máximas serem muito próximos nos NMPs avaliados, inferimos que objetos com tamanhos menores que 600 pixels possibilitam a discriminação das classes de vegetação.

Para construir uma AD são selecionados os atributos que minimizam as impurezas dos nós, ou seja, intervalos de valores específicos do conjunto de atributos que melhor discriminam as classes. A partir do melhor caso, que obteve maior acurácia, foram avaliadas as importâncias dos atributos para a classificação. As maiores importâncias entre as bandas ópticas foram obtidas para as médias das bandas azul, verde, vermelho, borda vermelha e as duas bandas do infravermelho de ondas longas (B2M, B3M, B4M, B5M, B11M e B12M), com 3,3%, 4,3%, 5,3%, 6,6%, 6,3% e 6,2%, respectivamente.

Considerando apenas as polarizações, as médias das bandas SAR obtiveram as maiores importâncias para VHM (9,7%) e para VVM (8,9%). Aplicando a classificação baseada em objetos apenas com os atributos ópticos mais importantes (B2M, B3M, B4M, B5M, B11M, B12M), obteve-se acurácia = 86,2%. Quando inseridos os atributos SAR mais importantes, VVM e VHM, a acurácia aumentou = 91,3%.

Dentre os atributos ópticos com importâncias relevantes, destacaram-se as bandas de reflectância vermelho (B4M), borda vermelha (B5M) e infravermelho médio (B11M, B12M). Amani et al. (2017) verificaram maiores diferenças na reflectância das bandas 4 (vermelha) e 8A (borda vermelha) em banhados com imagens Sentinel-2A, e salientam que estas bandas são as mais indicadas para mapear diferentes AUs. Segundo Amani et al. (2018) as bandas no infravermelho de ondas longas são sensíveis à umidade na vegetação e nos solos, e contribuem na discriminação de classes de vegetação em AUs.

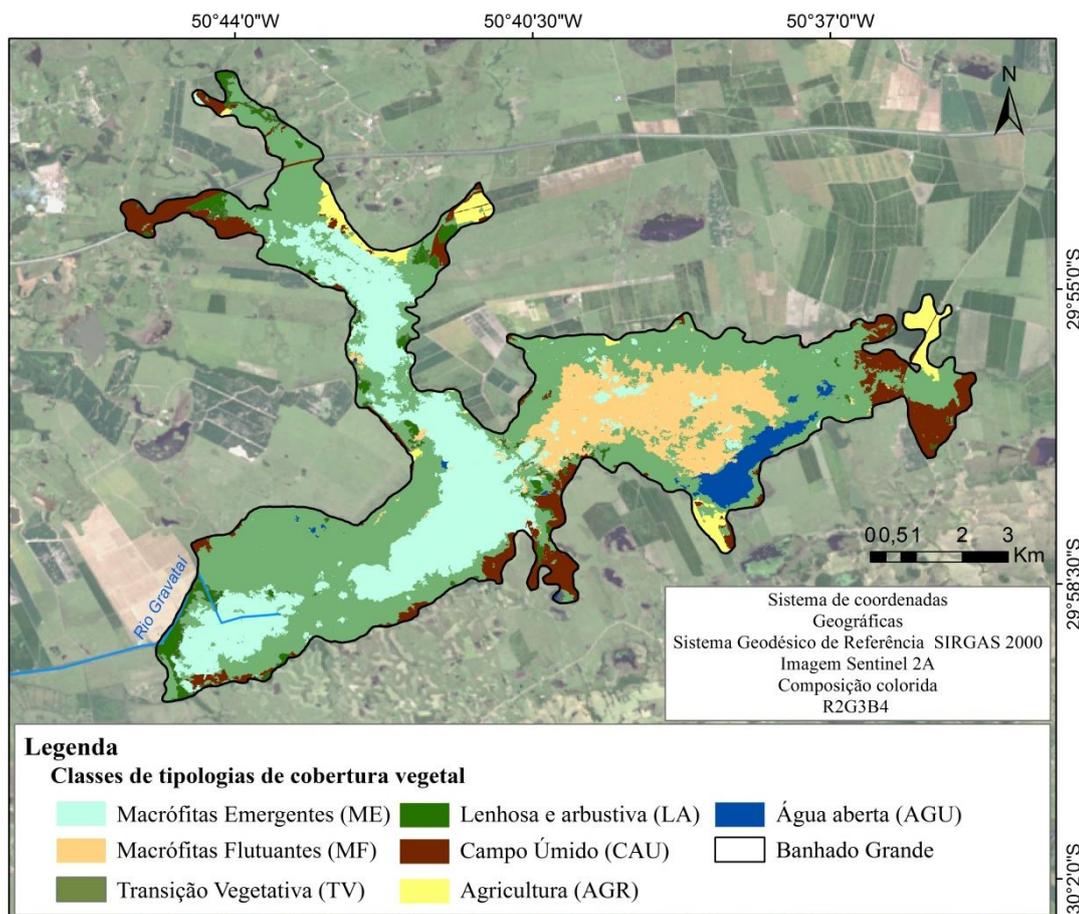
A maior importância observada para distinguir tipologias vegetais ocorreu para a polarização cruzada Sentinel-1 VH (9,7%), frente à polarização VV (8,9%). De forma semelhante, Simioni et al. (2020) observaram que as polarizações VH (22%) e VV + VH (20%) foram as mais importantes para delinear AUs e classes de cobertura vegetal utilizando Sentinel-1. Kaplan e Avdan (2018) encontraram forte correlação entre a polarização cruzada (VH) e correlação fraca entre a polarização VV para diferenciar tipologias de AUs com diferentes padrões de vegetação.

A resolução espectral influenciou na classificação, mas a resolução espacial não se mostrou relevante. As maiores importâncias ocorreram tanto em bandas com 10 m quanto com 20 m. As bandas ópticas apresentaram, no total, as maiores importâncias na classificação, mesmo com diferentes resoluções espaciais.

Na Figura 5 é apresentada a classificação das tipologias de cobertura vegetal no BG. Pode ser observado que na área central do BG encontram-se as classes ME e MF. Nas áreas de borda do BG, ocorrem as classes CAU e AGR, principalmente nos limites norte e leste. A segmentação retornou 23.250 objetos, com área média de 2578 m² e mediana de 201 m², redução de cerca de 99% no campo de análise, se comparado com o número de pixels da imagem (1617 x 1383 pixels). A combinação de OBIA e RF possibilitou discriminar objetos isolados como, por exemplo, a ocorrência da classe ME na classe MF e TV. Esta heterogeneidade de tipologias vegetais é característica de AUs palustres, devido às peculiaridades do terreno e a diferenças de saturação, e foi bem identificada pelo classificador.

A matriz de confusão da classificação (Tabela 2) apresenta as amostras de referência e a área de ocupação de cada classe.

Figura 5 – Classificação baseada em objetos no BG.



Fonte: Os autores (2022).

A classe CAU apresentou maior confusão com a classe TV, resultando em uma AP = 76%. Em CAU ocorrem diferentes espécies de vegetação e variações no teor de umidade, causando confusão com as demais classes. A classe AGR apresentou maior confusão com CAU, com AP = 38%. No mês de fevereiro as áreas de arroz estão em estágio de maturação, mas plantios tardios, com áreas ainda inundadas pela irrigação, assemelham-se à classe CAU.

Tabela 2 – Matriz de confusão: Acurácia do Produtor (AP); Acurácia do Usuário (AU).

Classes	AGR	CAU	ME	TV	LA	AGU	MF	AU (%)	Área (ha)	Área (%)
AGR	3	0	0	0	0	0	0	100	131,20	2,2
CAU	3	16	0	2	0	0	0	76	795,63	13,3
ME	1	0	29	2	1	0	2	83	1507,84	25,3
TV	1	4	3	43	2	0	1	80	2425,27	40,7
LA	0	0	0	0	5	0	1	83	230,90	3,8
AGU	0	0	0	0	0	2	0	100	166,44	2,8
MF	0	1	0	1	0	0	8	80	692,90	11,6
AP (%)	38	76	91	90	63	100	67	Total	5.950,18	100

Fonte: Os autores (2022).

A maior acurácia entre as classes ocorreu na classe ME, com AP = 91% e confusão apenas com a classe TV. Como ME é a segunda classe mais representativa em área no BG (25,3%), foi obtido maior quantidade de amostras de treinamento, obtendo maior acerto. Isso também foi observado com a classe TV, das 48 amostras de referência, 90% foram classificadas corretamente. TV se localiza nas bordas do BG, com composição de diferentes tipos e portes de vegetação, sendo a classe predominante em área (40,7%). AGU, com 2 amostras de referência, resultou em AP = 100%. MF ocorre no interior do BG, composta por vegetação flutuante de difícil classificação, com AP = 67%. A soma da área total das classes resultou na área total do ecossistema, cerca de 5.950 ha.

5 CONCLUSÕES

A partir da integração entre imagens ópticas e SAR dos sensores Sentinel-1 e 2A, aliada ao uso de OBIA e RF, foi possível classificar com precisão as classes de tipologias de cobertura vegetal em uma AU palustre no sul do Brasil. As maiores acurácias na classificação das tipologias de cobertura vegetal do BG ocorreram em segmentações com limiares de similaridades mais baixos e com os parâmetros de árvores mais altos e, portanto, mais complexos no RF. Foram obtidas altas acurácias (>80%) para os três valores avaliados de NMP (200, 400 e 600 pixels), mas a melhor acurácia foi obtida para objetos com o NMP mais elevado.

As imagens ópticas e SAR forneceram variáveis importantes para a classificação da vegetação na área úmida. Os atributos ópticos mais relevantes no modelo de classificação (> 6%), foram obtidos para as médias das bandas Borda Vermelha (banda 5) e Infravermelho Médio (bandas 11 e 12). As imagens SAR apresentaram as maiores relevâncias na classificação, sendo que as polarizações VH e VV obtiveram juntas 18,6% de relevância.

A integração de imagens ópticas e SAR produziu uma acurácia de classificação maior em comparação com a classificação apenas da imagem óptica. O uso sinérgico dos atributos extraídos dos dados ópticos e SAR melhorou a acurácia geral para 91,3%, um aumento de 5,1% em comparação ao uso apenas de dados do sensor óptico, o que demonstra que as imagens Sentinel-1 são uma fonte de dados relevante para distinguir tipologias de vegetação em AUs palustres. De todas as classes, a classe ME, com monodominância da espécie *Scirpus giganteus* apresentou maior acurácia de classificação (91%).

A abordagem de integração de dados testada neste estudo, aliada a classificação OBIA e RF possibilitou identificar e delimitar tanto a extensão e distribuição das tipologias vegetais quanto a área total do ecossistema de banhado. A classificação acurada das tipologias de cobertura vegetal do BG garante melhor compreensão desta área úmida e, conseqüentemente, uma gestão mais adequada para a conservação de seus recursos e biodiversidade.

Os resultados alcançados demonstram que esta abordagem metodológica pode ser estendida à aplicação de dados Sentinel no mapeamento da vegetação de AUs palustres subtropicais, potencialmente aquelas com uma maior diversidade de tipologias de cobertura vegetal.

Agradecimentos

Os autores agradecem à Fundação Municipal do Ambiente de Gravataí pela assistência nas visitas de campo e pelas fotografias aéreas concedidas. Este trabalho foi financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) processo número 88887.488339/2020-00. Os autores agradecem aos revisores desconhecidos que analisaram cuidadosamente o trabalho e cujas sugestões foram úteis para melhorar o manuscrito.

Contribuição dos Autores

Os autores LAG e LFCR idealizaram o projeto. O autor LFCR realizou a Análise formal e metodologia e os autores TFB e JPDS a investigação e validação. A administração, supervisão e revisão foram realizadas em conjunto pelos autores LAG e TK. A redação e edição foram realizadas em conjunto entre os autores TFB e LAG. A visualização do texto, dados e figuras foi executada pela autora TFB.

Conflitos de Interesse

Os autores declaram que não há conflitos de interesse

Referências

- ACCORDI, I. A.; HARTZ, S. M.; OHLWEILER, A. O sistema Banhado Grande como uma área úmida de importância internacional. In: SIMPÓSIO DE ÁREAS PROTEGIDAS, 2003, Pelotas. **Anais...** Pelotas, p. 56-63.
- ADAM, E.; MUTANGA, O.; RUGEGE, D. (2009). Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: a review. **Wetlands Ecology and Management**, v.18, n. 3, p. 281–296. DOI. 10.1007/s11273-009-9169-z
- AMANI, M.; SALEHI, B.; GRANGER, J. Spectral analysis of wetlands in newfoundland using sentinel-2A and landsat 8 imagery. In: IMAGING & GEOSPATIAL TECHNOLOGY FÓRUM. **Proceedings...** Baltimore, Maryland, USA, Proceedings of the IGTF, 2017, p. 1-9.
- AMANI, M.; SALEHI, B.; MAHDAVI, S.; BRISCO, B. Spectral Analysis of Wetlands Using Multi-Source Optical Satellite Imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 144, p. 119–136, 2018. DOI. 10.1016/j.isprsjprs.2018.07.005.
- ASSELEN, V.; VERBURG, H. P.; VERMAAT, E. J.; JANSE, H. J. Drivers of wetland conversion: a global meta-analysis. **PloS one**, v. 8, n. 11, p. e81292, 2013. DOI. 10.1371/journal.pone.0081292
- BARBIER, E. B.; Hacker, S. D.; Kennedy, C.; Koch, E. W.; Stier, A. C. Silliman, B. R. The value of estuarine and coastal ecosystem services. **Ecological monographs**, v.81, n. 2, p. 169-193, 2011. DOI. 10.1890/10-1510.1
- BELLOLI, T. F. **Impactos ambientais decorrentes da produção orizícola, Área de Proteção Ambiental do Banhado Grande - RS**. 2016. 80p. Monografia de Conclusão de Curso. Curso de Bacharelado em Geografia – Instituto de Geociências, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.
- BELLOLI, T. F. Impactos ambientais em áreas úmidas. In: GUASSELLI, L. A. **Áreas úmidas: questões ambientais**. 1ª Ed. Porto Alegre: Imprensa Livre, 2018, p. 89-111.
- BERGER, M.; MORENO, J.; JOHANNESSEN, J. A.; LEVELT, P. F.; HANSSSEN, R. F. ESA's sentinel missions in support of Earth system science. **Remote Sensing of Environment**, v. 120, p. 84-90, 2012. DOI. 10.1016/j.rse.2011.07.023
- BERHANE, T.M.; LANE, C.R.; WU, Q.; AUTREY, B.C.; ANENKHONOV, O.A.; CHEPINOGA, V.V.; LIU, H. Decision-Tree, Rule-Based, and Random Forest Classification of High-Resolution Multispectral Imagery for Wetland Mapping and Inventory. **Remote Sensing**, v. 10, n. 4, p. 1-26, 2018. DOI. 10.3390/rs10040580.

- BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5-32. 2001. DOI. 10.1023/A:1010933404324.
- BRISCO, B.; KAPFER, M.; HIROSE, T.; TEDFORD, B.; LIU, J. Evaluation of C-Band Polarization Diversity and Polarimetry for Wetland Mapping. **Canadian Journal of Remote Sensing**, v. 37, p. 82–92, 2011. DOI. 10.5589/m11-017
- CARLEE, A.P.; DEBEIR, O.; WOLFF, E. Assessment of Very High Spatial Resolution Satellite Image Segmentations, **Photogrammetric Engineering & Remote Sensing**, v.71, n.11, pp. 1285-1294, 2005. DOI. 10.14358/PERS.71.11.1285
- CROMMELINCK, S.; BENNETT, R.; GERKE, M.; NEX, F.; YANG, M.Y.; VOSSSELMAN, G. Review of Automatic Feature Extraction from High-Resolution Optical Sensor Data for UAV-Based Cadastral Mapping. **Remote Sensing**, v. 8, n. 8, p.689, 22 ago. 2016. DOI.10.3390/rs8080689
- COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). **Calendário de plantio e colheita 2019**, p.75, 2019. Disponível em: <<https://www.conab.gov.br/institucional/publicacoes/outras-publicacoes/item/7694-calendario-agricola-plantio-e-colheita>>. Acesso em 20 ago. 2021.
- 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. DOI. 10.1016/0034-4257(91)90048-B.
- COUTINHO, A. C. **Segmentação e classificação de imagens Landsat-TM para o mapeamento dos usos da terra na região de Campinas, SP**. 1997. 150 p. Dissertação. Mestrado em Ciências – Instituto de Biociências, Universidade de São Paulo, São Paulo, 1997.
- COMPANHIA DE PESQUISA DE RECURSOS MINERAIS (CPRM). **Litoestratigrafia**. Estado do Rio Grande do Sul. Escala 1:1.000.000. Disponível em: <<https://geoportal.cprm.gov.br/geosgb/>>. Acesso em: 19 dez. 2020.
- DENNISON, W. C; ORTH, R. J.; MOORE, K. A.; STEVENSON, J.C.; CARTER, V.; KOLLAR, S.; BERGDROM, P. W.; BATIUK, R. A. Assessing water quality with submerged aquatic vegetation. **Bioscience**, v. 43, p.86–94. DOI. 10.2307/1311969. 1993.
- DRIVER, J. L.; NEL, K.; SNADDON, K.; MURRAY, D. J. ROUX, L.; HILL, E. R. SWARTZ, J.; MANUEL, N. F. **Implementation Manual for Freshwater Ecosystem Priority Areas**. South Africa: National Freshwater Ecosystem Priority Areas project (NFEPA), 2011. 119 p. WRC Report No. 1801/1/11, ISBN 978-1-4312-0147-1
- DRONOVA, I .; GONG, P .; CLINTON, N.E; WANG, L .; FU, W .; QI, S .; LIU, Y. Landscape analysis of wetland plant functional types: The effects of image segmentation scale, vegetation classes and classification methods. **Remote Sensing Environment**, v. 127, p. 357–369, 2012. DOI. 10.1016/j.rse.2012.09.018
- DRONOVA, I. Object-based image analysis in wetland research: A review. **Remote Sensing**, v. 7, n. 5, p. 6380-6413, 2015. DOI. 10.3390/rs70506380
- ETCHELAR, C. B.; SIMIONI, J. P. D. Classificação das Áreas Úmidas em unidades de paisagem. In: LAURINDO ANTONIO GUASSELLI. **Áreas úmidas: questões ambientais**. 1ª Ed. Porto Alegre: Imprensa Livre, 2018, p. 139-161.
- FRANKLIN, S. E.; AHMED, O. S. Object-Based Wetland Characterization Using Radarsat-2 Quad-Polarimetric SAR Data, Landsat-8 OLI Imagery, and Airborne Lidar-Derived Geomorphometric Variables. **Photogrammetric Engineering & Remote Sensing**, v. 83, n. 1, p. 27-36, 2017. DOI. 10.14358/PERS.83.1.27.
- FRANTZ, D.; CARRARO, C.; VERDUM, R.; GARCIA, M. 1990. Caracterização de ambientes paludais da planície costeira do Rio Grande do Sul em imagens orbitais TM/Landsat 5. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 6, 1990, Manaus. **Anais...** São José dos Campos, INPE, p. 408-418.
- FU, B .; WANG, Y .; CAMPBELL, A .; LI, Y .; ZHANG, B .; YIN, S .; JIN, X. Comparison of object-based and pixel-based Random Forest algorithm for wetland vegetation mapping using high spatial resolution GF-1 and SAR data. **Ecological Indicators**, v. 73, p. 105-117, 2017. DOI. 10.1016/j.ecolind.2016.09.029
- GALLANT, A. L. The Challenges of Remote Monitoring of Wetlands. **Remote Sensing**, v. 7, p. 10938-10950,

2015. DOI. 10.3390/rs70810938.

- GRENIER, M.; LABRECQUE, S.; GARNEAU, M.; TREMBLAY, A. Object-based classification of a SPOT-4 image for mapping wetlands in the context of greenhouse gases emissions: The case of the Eastmain region, Québec, Canada. **Canadian Journal of Remote Sensing**, v. 34, p. 398-413. 2008. DOI. 10.5589/m08-049
- GUMBRICHT, T.; ROMAN-CUESTA, R. M.; VERCHOT, L.; HEROLD, M.; WITTMANN, F.; HOUSEHOLDER, E.; MURDIYARSO, D. An expert system model for mapping tropical wetlands and peatlands reveals South America as the largest contributor. **Global change biology**, v. 23, n. 9, p. 3581-3599, 2017. DOI. 10.1111/gcb.13689
- INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Supplement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories: Wetlands**. IPCC, Switzerland., 354p. Supplement report.
- IRGANG, B. E.; GASTAL JR, G.; DE SENNA, C. V. **Macrófitas aquáticas da planície costeira do RS**. Porto Alegre: CPG Botânica/UFRGS, 1996.
- JANOUSEK, C.N.; FOLGER, C.L. Does National Wetland Inventory class consistently identify vegetation and edaphic differences in Oregon tidal wetlands. **Wetlands Ecology and Management**, v. 26, p. 315–329, 2018. DOI. 10.1007/s11273-017-9575-6.
- JUNK, W. J.; BAYLEY, P. B.; SPARKS, R. E. The flood pulse concept in river-floodplain systems. **Canadian special publication of fisheries and aquatic sciences**, v. 106, n. 1, p. 110-127, 1989.
- KANDUS, P.; MINOTTI, P.G.; MORANDEIRA, N.S.; GRINSON, R.; GONZÁLEZ TRILLA, G.; GONZÁLEZ, E.B.; GAYOL, M. P. Remote sensing of wetlands in South America: status and challenges. **International Journal of Remote Sensing**, v. 39, p. 993–1016, 2018. DOI. 10.1080/01431161.2017.1395971.
- KAPLAN, G.; AVDAN, U. Monthly analysis of wetlands dynamics using remote sensing data. **ISPRS International Journal of Geo-Information**, v. 7, n. 10. p. 411, 2018. DOI. 10.3390/ijgi7100411
- LALIBERTE, A. S.; RANGO, A. Image Processing and Classification Procedures for Analysis of Sub-decimeter Imagery Acquired with an Unmanned Aircraft over Arid Rangelands. **GIScience & Remote Sensing**, v. 48, n. 1, p. 4-23, 15 jan. 2011. DOI.10.2747/1548-1603.48.1.4.
- LEITE, M. G.; GUASSELLI, L. A. Dinâmica espaço-temporal das macrófitas aquáticas no Banhado Grande, bacia hidrográfica do Rio Gravataí, RS. **Para Onde!?**, v. 7, n. 1, p. 17-24, 2013.
- LOU, P.; FU, B.; HE, H.; LI, Y.; TANG, T.; LIN, X.; FAN, D.; GAO, E. An Optimized Object-Based Random Forest Algorithm for Marsh Vegetation Mapping Using High-Spatial-Resolution GF-1 and ZY-3 Data. **Remote Sensing**, v.12, n. 8, p. 1270, 2020. DOI. 10.3390/rs12081270.
- MAHDIANPARI, M.; SALEHI, B.; MOHAMMADIMANESH, F.; HOMAYOUNI, S.; GILL, E. The First Wetland Inventory Map of Newfoundland at a Spatial Resolution of 10 m Using Sentinel-1 and Sentinel-2 Data on the Google Earth Engine Cloud Computing Platform. **Remote Sensing**. v. 11, n. 1, 43, 2019. DOI. 10.3390/rs11010043
- MAIN-KNORN, M.; BRINGFRIED, P.; VINCENT, L.; MULLER-WILM, U.; GASCON, F. Sen2Cor for Sentinel-2, Remote Sensing. Image and Signal Processing for Remote Sensing XXIII. In: SPIE Remote Sensing, v. 10427, 2017, Warsaw, Poland, **Proceedings**. DOI.10.1117/12.2278218.
- MALTCHIK, L.; ROLON, A. S.; GUADAGNIN, D. L.; STENERT, C. Wetlands of Rio Grande do Sul, Brazil: a classification with emphasis on plant communities. **Acta Limnologica Brasiliensia**, v. 16, n. 2, p. 137–151, 2004.
- MENZE, B. H., KELM, B. M.; MASUCH, R.; HIMMELREICH, U.; BACHERT, P.; PETRICK, W.; HAMPRECHT, F. A. A Comparison of Random Forest and Its Gini Importance with Standard Chemometric Methods for the Feature Selection and Classification of Spectral Data. **BMC Bioinformatics**, v.10, n.1, 2009. DOI.10.1186/1471-2105-10-213.
- MIDWOOD, J. D.; CHOW-FRASER, P. Mapping Floating and Emergent Aquatic Vegetation in Coastal

- Wetlands of Eastern Georgian Bay, Lake Huron, Canada. **Wetlands**, v.30, p.1141-1152, 2010. DOI.10.1007/s13157-010-0105-z.
- MISHRA, N. B. Wetlands: Remote Sensing. In: Wang, Y. **Wetlands and Habitats**. 2ª Ed. Boca Raton: CRC Press, 2020. p. 566-574. DOI. 10.1201/9780429445507.
- MITSCH, W. J.; GOSSSELINK, J. G. **Wetlands**. 5ª Ed. New Jersey: Wiley, 2015.
- MOFFETT, K. B.; GORELICK, S. M. 2013. Distinguishing wetland vegetation and channel features with object-based image segmentation. **International Journal of Remote Sensing**, v.34, n. 4, p. 1332-1354, 2013 DOI. <https://doi.org/10.1080/01431161.2012.718463>
- MOMSEN, E. GRASS GSoC 2012 Image Segmentation. **Segmentation Methods**. Disponível em:<https://grasswiki.osgeo.org/wiki/GRASS_GSoC_2012_Image_Segmentation>. Acesso em: 25 ago. 2021
- MUI, A.; HE, Y.; WENG, Q. An object-based approach to delineate wetlands across landscapes of varied disturbance with high spatial resolution satellite imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, n. 109, p. 30-46, 2015. DOI. 10.1016/j.isprsjprs.2015.08.005
- MURERIWA, N.; ADAM, E.; SAHU, A.; TEFAMICHAELI, S. Examining the Spectral Separability of *Prosopis Glandulosa* from Co-Existent Species Using Field Spectral Measurement and Guided Regularized Random Forest. **Remote Sensing**, v. 8, n. 4, p.144–160. DOI.10.3390/rs8020144.
- NASCIMENTO, P. S. R.; ALMEIDA FILHO, R. Utilização da técnica de segmentação em imagens TM/Landsat visando otimizar a técnica de interpretação visual. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8, Salvador, Brasil. **Anais...** São José dos Campos: INPE/SELPER, 1996, p. 215-218.
- NIELSEN, S. **Geomorfologia da bacia do rio Gravataí-RS**. In: Bacia do rio Gravataí-RS: informações básicas para a gestão territorial, Porto Alegre: Proteger, p. 1-18, 1994.
- PEDREGOSA, F.; VAROUQUAUX, G.; GRAMFORT, A.; MICHEL, V.; THIRION, B. GRISEL, O.; DUCHESNAY, E. Scikit-learn: Machine learning in Python. **Journal of machine Learning research**, n. 12, p. 2825-2830, 2011.
- PONTIUS, R. G. J.; MILLONES, M. Death to Kappa: Birth of Quantity Disagreement and Allocation Disagreement for Accuracy Assessment. **Inter. Journal of Remote Sensing**, v. 32, p. 4407-4429, 2011. DOI. 10.1080/01431161.2011.552923.
- PRATOLONGO, P.; VICARI, R.; KANDUS, P.; MALVÁREZ, I. A new method for evaluating net aboveground primary production (NAPP) of *Scirpus giganteus* (Kunth). **Wetlands**, v. 25, n. 1, p. 228-232, 2005. DOI. 10.1672/0277-5212(2005)025[0228:ANMFEN]2.0.CO;2
- PU, R.; LANDRY, S.; YU, Q. Object-based urban detailed land cover classification with high spatial resolution IKONOS imagery. **International Journal of Remote Sensing**, v. 32, n. 12, p. 3285-3308, 2011. DOI. 10.1080/01431161003745657
- QIAN, Y.; ZHOU, W.; YAN, J.; LI, W. H.; HAN, L. Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery. **Remote Sensing**, n 7, p.153-168, 2015. DOI. 10.3390/rs70100153.
- RAMSAR. The Ramsar Convention Manual: **A Guide to the Wetland Convention, 6th ed**. Disponível em:<<https://www.ramsar.org/sites/default/files/documents/library/manual6-2013-e.pdf>> Acesso em: 23 abr 2021.
- RAPINEL, S.; FABREA, E.; DUFOURA, S.; ARVORA, D., MONYB, C.; HUBERT-MOYA, L. Mapping potential, existing and efficient wetlands using free remote sensing data. **Journal of Environmental Management**. N. 247, p. 829–839, 2019. DOI. 10.1016/j.jenvman.2019.06.098
- ROSSATO, M. S. **Os climas do Rio Grande do Sul: variabilidade, tendências e tipologias**. 2011. 240p. Tese de Doutorado - Programa de Pós-graduação em Geografia. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.
- RUIZ, L. F. C. **GeoPatterns 1.0**. Zenodo. 2019. DOI.:10.5281/zenodo.3408394.
- SAHA, T.K.; PAL, S. Exploring physical wetland vulnerability of Atrayee river basin in India and Bangladesh

- using logistic regression and fuzzy logic approaches, **Ecological Indicators**, v. 98, p.251-265, 2019. DOI. 10.1016/j.ecolind.2018.11.009.
- SAINTILAN, N. Biogeography of Australian saltmarsh plants. **Austral Ecology**, v. 34, n. 8, p. 929-937, 2009. DOI. 10.1111/j.1442-9993.2009.02001.x
- SIEBEN, E. J. J.; COLLINS, N. B.; MTSHALI, H.; VENTER, C. E. The Vegetation of Inland Wetlands with Salt-Tolerant Vegetation in South Africa: Description, Classification and Explanatory Environmental Factors. **South African Journal of Botany**, n.104, p. 199–207, 2016. DOI. 10.1016/J.SAJB.2015.11.004.
- SILVA, T. S.; COSTA, M. P.; MELACK, J. M.; NOVO, E. M. Remote sensing of aquatic vegetation: theory and applications. **Environmental monitoring and assessment**, v. 140, n. 1-3, p. 131-145, 2008. DOI. 10.1007/s10661-007-9855-3
- SIMIONI, J. P. D.; GUASSELLI, L. A.; ETCHELAR, C. B. 2017. Connectivity among Wetlands of EPA of Banhado Grande, RS. **RBRH**, n. 22, p. 1-11, 2017. DOI. 10.1590/2318-0331.011716096
- SIMIONI, J. P. D.; GUASSELLI, L. A.; NASCIMENTO, V. F.; RUIZ, L. F. C.; BELLOLI, T. F. Integration of multi-sensor analysis and decision tree for evaluation of dual and quad-Pol SAR in L- and C-bands applied for marsh delineation. **Environment, Development and Sustainability**, n. 22, p. 5603–5620, 2020. DOI. 10.1007/s10668-019-00442-0
- TIAN, S.; ZHANG, X.; TIAN, J.; SUN, Q.R. Random forest classification of wetland landcovers from multi-sensor data in the arid region of Xinjiang, China. **Remote Sensing**, v.8, n.11, p. 954, 2016. DOI. 10.3390/rs8110954
- TIMM, B. C.; MCGARIGAL, K. Fine-scale remotely-sensed cover mapping of coastal dune and salt marsh ecosystems at Cape Cod National Seashore using Random Forests. **Remote Sensing of Environment**, v. 127, p. 106-117, 2012. DOI. 10.1016/j.rse.2012.08.033
- TINER, R. W.; LANG, M. W.; KLEMAS, V. V. (Eds.). **Remote sensing of wetlands: applications and advances**. Boca Raton: CRC press, 2015
- VAN DER WALT, S.; COLBERT, S. C.; VAROQUAUX, G. The NumPy array: a structure for efficient numerical computation. **Computing in science & engineering**, v. 13, n. 2, p. 22-30, March-April 2011. DOI. 10.1109/MCSE.2011.37
- WHITESIDE, T. G.; BARTOLO, R. E. Mapping Aquatic Vegetation in a Tropical Wetland Using High Spatial Resolution Multispectral Satellite Imagery. **Remote Sensing**, v.7, n. 9, p. 11664-11694, 2015. DOI. 10.3390/rs70911664
- ZHANG, C.; XIE, Z. Object-based vegetation mapping in the Kissimmee River watershed using HyMap data and machine learning techniques. **Wetlands**, v.33, n. 2, p. 233-244, Apr 2013. DOI. 10.1007/s13157-012-0373-x
- ZHOU, D.; GONG, H.; WANG, Y.; KHAN, S.; ZHAO, K. Driving Forces for the Marsh Wetland Degradation in the Honghe National Nature Reserve in Sanjiang Plain, Northeast China. **Environmental Modeling & Assessment**, v. 14, p. 101–111, 2009. DOI. 10.1007/s10666-007-9135-1
- ZHOU, W.; TROY, A. An object-oriented approach for analysing and characterizing urban landscape at the parcel level. **International Journal of Remote Sensing**, v.11, n.29, p. 3119-3135, 2008. DOI: 10.1080/01431160701469065.
- WANG, X.; GAO, X.; ZHANG, Y.; FEI, X.; CHEN, Z.; WANG, J.; ZHANG, Y.; LU, X.; ZHAO, H. Land-cover classification of coastal wetlands using the RF algorithm for worldview-2 and Landsat 8 images. **Remote Sensing**, v.11, p. 1927, 2019. DOI.10.3390/rs11161927

Biografia do autor principal



Tássia Fraga Belloli nasceu em 1990 na cidade de Gravataí, RS. É geógrafa e mestre em Sensoriamento Remoto e Geoprocessamento pela Universidade Federal do Rio Grande do Sul. Possui experiência em estimativa de biomassa vegetal e carbono orgânico em áreas úmidas, mapeamento, avaliação de impactos ambientais e recuperação ambiental de áreas úmidas. Atualmente é pesquisadora bolsista de doutorado no PPGSR – UFRGS, trabalhando com mapeamento de áreas úmidas no estado do RGS e seus serviços ecossistêmicos. Possui interesse em sensoriamento remoto, ferramentas de geoprocessamento e plataformas de análise geoespacial e nos seus papéis de apoio a tais esforços.



Esta obra está licenciada com uma Licença [Creative Commons Atribuição 4.0 Internacional](https://creativecommons.org/licenses/by/4.0/) – CC BY. Esta licença permite que outros distribuam, remixem, adaptem e criem a partir do seu trabalho, mesmo para fins comerciais, desde que lhe atribuam o devido crédito pela criação original.