

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E METEOROLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

JOÃO PAULO DELAPASSE SIMIONI

**MÉTODOS DE CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE PARA
DELINEAMENTO DE BANHADOS**

PORTO ALEGRE

2021

JOÃO PAULO DELAPASSE SIMIONI

**MÉTODOS DE CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE PARA
DELINEAMENTO DE BANHADOS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto como requisito parcial para a obtenção do título de Doutor em Sensoriamento Remoto e Geoprocessamento.

Orientador: Prof. Dr. Laurindo Antonio Guasselli

PORTO ALEGRE

2021

JOÃO PAULO DELAPASSE SIMIONI

**MÉTODOS DE CLASSIFICAÇÃO DE IMAGENS DE SATÉLITE PARA
DELINEAMENTO DE BANHADOS**

Tese de doutorado apresentada ao Programa
de Pós-Graduação em Sensoriamento Remoto
como requisito parcial para a obtenção do título
de Doutor em Sensoriamento Remoto e
Geoprocessamento.

Aprovado em:

BANCA EXAMINADORA

Prof. Dra. Tatiana Mora Kuplich
Instituto Nacional de Pesquisas Espaciais

Prof. Dr. Gabriel de Oliveira
Universidade de Toronto

Prof. Dr. Thiago Sanna Freire Silva
Universidade de Stirling

Prof. Dr. Laurindo Antonio Guasselli (Orientador)
Universidade Federal do Rio Grande do Sul

CIP - Catalogação na Publicação

Simioni, João Paulo Delapasse
Métodos de classificação de imagens de satélite
para delineamento de Banhados / João Paulo Delapasse
Simioni. -- 2021.
145 f.
Orientador: Laurindo Antonio Guasselli.

Tese (Doutorado) -- Universidade Federal do Rio
Grande do Sul, Centro Estadual de Pesquisas em
Sensoriamento Remoto e Meteorologia, Programa de
Pós-Graduação em Sensoriamento Remoto, Porto Alegre,
BR-RS, 2021.

1. Áreas úmidas. 2. Aprendizado de máquina. 3.
Geobia. 4. Delineamento. I. Guasselli, Laurindo
Antonio, orient. II. Titulo.

À Paola Stuker,
minha companheira de vida.

AGRADECIMENTOS

À Deus, ser superior de luz, que me fortalece e ilumina minha trajetória.

À Universidade Federal do Rio Grande do Sul pela acolhida e ensino de qualidade que me proporcionou.

À CAPES pela concessão da bolsa de pesquisa.

Ao Centro de Pesquisas em Sensoriamento Remoto e Meteorologia pelo espaço disponibilizado e pelas experiências oferecidas.

Às gestoras da APA do Banhado Grande, em reconhecimento à luta diária pela conservação dos Banhados, mesmo diante das dificuldades financeiras e pressão dos agricultores do entorno.

Ao meu orientador Prof. Laurindo Antonio Guasselli, por apresentar-me ao instigante tema das Áreas Úmidas. Seu comprometimento, sua ética e suas contribuições foram indubitavelmente inestimáveis para minha formação profissional.

À Ricardo Aranha Ramos pelo gentil empréstimo de fotografias aéreas.

Aos colegas do Laboratório de Geoprocessamento e análise Ambiental (LAGAM) pelas conversas, cafés, momentos de descontração e pelos churrascos semestrais.

Aos amigos Gabriel de Oliveira, Luis Fernando Ruiz, Guilherme de Oliveira, Douglas Facco e Victor Fernandez, pelas valorosas e construtivas contribuições nos artigos desta tese.

Aos profissionais do MARH (Meio Ambiente e Recursos Hídricos) da STE Engenharia, em especial aos colegas do NIG (Núcleo de Inteligência Geográfica) pela troca diária de experiências.

Aos meus avós paternos e maternos por todo o apoio despendido e pelas tantas palavras calorosas, as quais motivam-me diariamente.

Aos meus pais Sérgio e Silvana e minha irmã Ana Clara, que mesmo diante das dificuldades e da distância foram o suporte essencial para o desenvolvimento desta tese.

À minha companheira de vida, Paola, com quem aprendo todos os dias o verdadeiro significado do amor. O destino permitiu que defendêssemos nossas teses de doutoramento com 2 dias de diferença, evidenciando que até na ciências estamos conectados. Sua trajetória de vida, sua lealdade e seu companheirismo, durante todos os momentos, foram as forças motrizes que conduziram-me até aqui.

Banhado é o lugar onde o bom campeiro
Sujeita o cavalo e evita cruzar,
Onde a rês se atola, a pampa verdeja,
E a flor do aguapé insiste em brotar.

Banhado é o pago imerso em silêncios
Que escodem funduras sem fim nem começo,
Mas é onde à noite, lua e estrelas,
Se olham no espelho do céu pelo avesso.

[...]

O Banhado Grande do Gravataí
E o Santa Catarina, vão chegando ao fim...
O São Donato e o Upamaroti...
E até o santuário do velho Taim.

Como explicar as novas gerações
As tristes razões desse nosso legado,
Se não mais guardamos nos corações
As lições de vida que vêm dos Banhados.

As Lições dos Banhados
Silvio Genro

RESUMO

As Áreas Úmidas (AUs) são ecossistemas de importância global, que apresentam altos níveis de diversidade ecológica e produtividade primária e secundária. Os Banhados são um tipo de AU, característicos nos estados do Sul do Brasil, no Uruguai e na Argentina. O delineamento e classificação desses ecossistemas é uma tarefa árdua, dada as características estruturais hidrológicas, de solos, de cobertura vegetal e espectrais. No estado Rio Grande do Sul os Banhados são considerados Áreas de Preservação Permanente, porém, não há um inventário e tampouco um delineamento desses ambientes. Deste modo, o objetivo desta tese é comparar diferentes métodos baseados em sensoriamento remoto ativo e passivo e aprendizado de máquina (AP) para o delineamento de Banhados. Para isto, utilizamos três abordagens: i) aplicação de índices espectrais de sensoriamento remoto e árvore de decisão; ii) integração de imagens SAR de dupla e quádrupla polarização em bandas C e L e árvore de decisão; e, iii) análise multisensor (ativo e passivo), Geobia e diferentes classificadores. Nossos resultados mostram que os índices espectrais de sensoriamento remoto apresentaram acurárias entre 77,9% e 95,9%; a aplicação de imagens SAR resultou em acurárias entre 56,1% e 72,9%, ambos pelo algoritmo Árvore de Decisão. Para a abordagem multisensor utilizando Geobia e diferentes classificadores, as acurárias variaram entre 95,5% e 98,5%, sendo que, o k-NN foi o algoritmo que apresentou maior acurácia entre os modelos avaliados, demonstrando o potencial da análise multisensor (ativo e passivo) e do aprendizado de máquina para o delineamento e classificação de Banhados. Adotamos como estudo de caso um Banhado localizado no Sul do Brasil, porém recomendamos que devido as semelhanças hidrológicas, estruturais e espectrais desses ambientes, essas metodologias possam ser aplicadas em outras áreas de Banhados (marshes).

Palavras-chave: Áreas Úmidas; GEOBIA; aprendizado de máquina; Delineamento.

ABSTRACT

Wetlands are ecosystems of global importance, with high levels of ecological diversity and primary and secondary productivity. Marshes are a type of wetland characteristic of the southern Brazil, Uruguay and Argentina. The delineation and classification of these ecosystems is an arduous task, given the hydrological structure, soil, vegetation and spectral characteristics. In the Rio Grande do Sul state, marshes are considered Permanent Preservation Areas, however, there is no inventory and no delineation of these environments. Thus, the aim of this thesis is to compare different active and passive remote sensing based methods and machine learning for the delineation of marshes. For this, we use three approaches: i) application of spectral indices of remote sensing and decision tree; ii) integration of dual and quad-poll SAR images in C and L-bands and decision tree, and iii) multisensor analysis (active and passive), Geobia and different classification methods. Our results show that the spectral indexes of remote sensing presented accuracy between 77.9% and 95.9%; the application of SAR images resulted in accuracy between 56.1% and 72.9%, both using the Decision Tree algorithm. For the multisensor approach using Geobia and different classifiers, the accuracy varied between 95.5% to 98.5%, k-NN was the algorithm that showed greater accuracy among the models evaluated, demonstrating the potential of the multisensor analysis (active and passive) and machine learning for marshes delineation and classification. Our study was carried out in a marsh located in the southern Brazil, however due to the hydrological, structural and spectral similarities of these environments, the methodologies can be applied in other marshes areas.

Keywords: Wetlands; GEOBIA; Machine learning; Delineation.

LISTA DE ILUSTRAÇÕES

Figura 1 - Localização do Banhado Grande, APABG e bacia do rio Gravataí – RS..	22
Figura 2 - Precipitação mensal média, entre 2000-2016, APABG.....	25
Figura 3 - Avanço da linha de fogo, em 16/04/2020, na área do Banhado Grande ..	26
Figura 4. Variação temporal da área queimada pelo do fogo no Banhado Grande. .	27
Figura 5 – Unidades Hidrogeomorfológicas definidas por Brinson (1993).	37
Figura 6 - Sistema de classificação de Áreas Úmidas da África do Sul	38
Figura 7 - Abordagem Hierárquica para Delimitação de Áreas Úmidas (PEEW)	39
Figura 8 - Proposta de classificação das Áreas Úmidas brasileiras	41
Figura 9 - Uso e cobertura da Terra nos rios Uruguai, Jacuí e Ibicuí - RS	44
Figura 11 - Variação e características da vegetação e do nível da água em Banhados	46
Figura 12 - Principais elementos do Sensoriamento remoto	49
Figura 13 - Ilustração de um sensor passivo.....	50
Figura 14 - Ilustração de um sensor ativo	51
Figura 15 - Representação da penetração das bandas SAR em dossel florestal.	53
Figura 16 - Comparação entre as bandas L e C, dos satélites Alos Palsar 1 e Sentinel 1 A, em área de Banhado.....	55
Figura 17 - Comportamento espectral de classes de vegetação, a partir de imagem Sentinel 2A, em área de Banhado.....	60
Figura 18 - Comportamento espectral de tipos de áreas úmidas, banda do infravermelho próximo, imagem Sentinel 2A	61
Figura 19 - Análise bibliométrica, países que mais publicaram sobre sensoriamento remoto e Áreas Úmidas, entre 1971 e 2021.....	62
Figura 20 - Análise bibliométrica, principais autores de artigos científicos envolvendo sensoriamento remoto e Áreas Úmidas, entre 1971 e 2021.	63
Figura 21 - Análise bibliométrica, principais palavras-chave nos artigos envolvendo sensoriamento remoto e Áreas Úmidas, entre 1971 e 2021.	64
Figura 22 - Análise bibliométrica, países que mais publicaram sobre sensoriamento remoto e Banhados, entre 1971 e 2021	65
Figura 23 - Análise bibliométrica, principais palavras-chave nos artigos envolvendo sensoriamento remoto e Banhados, entre 1971 e 2021.....	66

Figura 24 - Modelo básico de uma Árvore de Decisão.....	69
Figura 25 - Exemplo de funcionamento de um tipo de Rede Neural Artificial	70
Figura 26 - Ilustração do funcionamento do modelo Randon Forest.....	72
Figura 27 - Ilustração do classificador k vizinho mais próximo.....	74

LISTA DE QUADROS E TABELAS

Quadro 1 - Espécies de vegetação dominantes do Banhado Grande.....	24
Quadro 2 - Comparação entre sensores ativos e passivos.....	51
Tabela 1 - Bandas espectrais do satélite Sentinel 2A	56
Tabela 2 - Imagens SAR utilizadas no estudo.....	76
Tabela 3 - Imagens ópticas utilizadas no estudo.....	76

LISTA DE ABREVIATURAS E SIGLAS

AD	Árvore de Decisão
Alos	<i>Advanced Land Observing Satellite</i>
AP	Aprendizado de máquina
APA	Área de Proteção Ambiental
APABG	Área de Proteção Ambiental do Banhado Grande
APUs	Áreas potencialmente úmidas
AUs	Áreas Úmidas
BG	Banhado Grande
CEPSRM	Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia
CWI	<i>Canadian Wetland Inventory</i>
ESA	European Space Agency
ETM+	<i>Enhanced Thematic Mapper Plus</i>
EW	<i>Extra Wide Swath</i>
GEOBIA	<i>Geographic Object-Based Image Analysis</i>
HGM	Unidades hidrogeomorfológicas
IAF	Índice de Área Foliar
INAU	Instituto Nacional de Ciência e Tecnologia em Áreas Úmidas
IUCN	<i>International Union for Conservation of Nature</i>
IW	<i>Interferometric Wide Swath</i>
JAXA	<i>Japan Aerospace Exploration Agency</i>
k-NN	k-vizinho mais próximo
LAGAM	Laboratório de Geoprocessamento e Análise Ambiental
MDE	Modelo Digital de Elevação
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>

MSI	<i>MultiSpectral Instrument</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NIR	Infravermelho próximo
OLI	<i>Operational Land Imager</i>
PEEW	<i>Potential, existing and efficient wetlands</i>
PPGSR	Programa de Pós-Graduação em Sensoriamento Remoto
REM	Radiação Eletromagnética
RF	<i>Random Forest</i>
RNA	Redes Neurais Artificiais
RS	Rio Grande do Sul
S2	Sentinel 2
SAR	<i>Synthetic-aperture radar</i>
SGB	Sistema Banhado Grande
SM	<i>Strip Map</i>
SNUC	Sistema Nacional de Unidades de Conservação
SR	Sensoriamento Remoto
SVM	<i>Support Vector Machine</i>
TM	<i>Thematic Mapper</i>
TWI	<i>Topographic Wetness Index</i>
UC	Unidade de conservação
UFRGS	Universidade Federal do Rio Grande do Sul
USGS	<i>United States Geological Survey</i>
WV	<i>Wave</i>
ZTAT	Zona de Transição Aquático/Terrestre

SUMÁRIO

1	INTRODUÇÃO.....	16
2	HIPÓTESE.....	19
3	OBJETIVOS.....	20
3.1	Objetivo Geral	20
3.2	Objetivos Específicos.....	20
4	ÁREA DE ESTUDO	20
4.1	O Banhado Grande	21
4.2	Um incêndio devastador.....	25
5	ESTRUTURA DA TESE	28
6	DESENVOLVIMENTO.....	30
6.1	Referencial Teórico	30
6.1.1	Áreas Úmidas	30
6.1.2	Sensoriamento remoto	49
6.1.3	Sensoriamento Remoto em Áreas Úmidas.....	57
6.1.4	Aprendizado de Máquina.....	67
6.2	Procedimentos Metodológicos	75
6.2.1	Levantamento e Pesquisa bibliográfica	75
6.2.2	Aquisição das imagens de satélite.....	76
6.2.3	Processamento das imagens.....	77
6.2.4	Obtenção das amostras.....	77
7	RESULTADOS	79
8	CONCLUSÕES e CONSIDERAÇÕES FINAIS	129
	FINANCIAMENTO.....	131
	REFERENCIAS.....	132

1 INTRODUÇÃO

As Áreas Úmidas (AUs) são ecossistemas de importância global, que apresentam altos níveis de diversidade ecológica e produtividade primária e secundária (ENVIRONMENTAL PROTECTION AGENCY, 2001; LI et al., 2021). O conceito de AUs é bastante amplo, e engloba desde ambientes marinhos e costeiros até os continentais e artificiais. Hu; Niu; Chen (2017) propõem classificar as AUs em: mangues, campos inundáveis, veredas, planícies de inundação, igapós (florestas inundadas) e pântanos

Além de serem ecossistemas responsáveis pela manutenção da biota, atuam diretamente na regulação climática, controle de cheias, retenção de carbono, entre outros (MITSCH; GOSSELINK, 1993). Entretanto, estas áreas vem historicamente sofrendo uma série de impactos negativos, como a drenagem para o manejo agrícola, despejo de resíduos urbanos e industriais, poluição por agroquímicos provenientes das atividades agrícolas e extração de turfas para o setor energético (CUNHA; PIEDADE; JUNK, 2015).

A degradação das AUs significa também a perda dos serviços ecossistêmicos desses ambientes (LIN et al., 2021), insubstituíveis para garantir o bem-estar humano a longo prazo (como, por exemplo, a recarga de aquíferos, o controle de inundações, o armazenamento de carbono, a purificação de água, entre outros). Portanto, proteger e resguardar esses ecossistemas é proteger serviços ecossistêmicos imprescindíveis para a manutenção da biota e do bem-estar humano.

Diante da necessidade de conservação das AUs, o delineamento e o monitoramento destes ecossistemas assumem importância ímpar, dadas as rápidas transformações a que estes ambientes estão acometidos, principalmente com a sua conversão em áreas urbanas, rurais e industriais (HENDERSON; LEWIS, 2008). A magnitude dessa tarefa, aliada à difícil acessibilidade às Áreas Úmidas, volta os esforços dos pesquisadores para ferramentas capazes de obter dados remotamente, em curtos períodos de tempo e de baixo custo.

Neste contexto, dados provenientes do sensoriamento remoto (SR) apresentam alto potencial para o delineamento, classificação e monitoramento de diferentes tipos de AUs. As melhores resoluções radiométricas, espectrais e temporais dos satélites

Landsat TM (*Thematic Mapper*) e OLI (*Operational Land Imager*), e recentemente, dos satélites Sentinel 2 (S2) A e B MSI (*MultiSpectral Instrument*) possibilitam estudos mais precisos no seu delineamento e classificação.

De forma geral, trabalhos envolvendo delineamento e classificação de AUs utilizavam apenas sensores na faixa óptica do espectro eletromagnético (GUO *et al.*, 2017). Entretanto, nas últimas décadas, a disponibilidade de imagens SAR (Radar de Abertura Sintética) dos satélites RADARSAT 1 e 2, Alos (*Advanced Land Observing Satellite*) Palsar 1 e 2 e Sentinel 1 (S1) A e B tem fornecido dados capazes de complementar ou auxiliar a teledetecção tradicional de AUs (GUO *et al.*, 2017).

A manipulação de grande volume de dados de SR tornou-se possível com a inserção de métodos capazes de encontrar padrões relevantes num contexto de apoio a tomada de decisão. Aprendizado de máquina (AP) é um método de análise de dados que automatiza a construção de modelos analíticos. É um ramo da inteligência artificial baseado na ideia de que os sistemas podem aprender com os dados, identificar padrões e tomar decisões com o mínimo de intervenção humana. O ML permite classificar grandes conjuntos de dados, identificar padrões e estabelecer relações na solução de problemas por meio da análise de dados (HAND, 2007). O ML é um conjunto de métodos e algoritmos, em que se destacam as Redes Neurais Artificiais (RNA), k-vizinho mais próximo (k-NN), Árvore de Decisão (AD) e *Random Forest* (RF) (BEHRENS; SCHOLTEN, 2007).

A integração do SR e ML têm sido amplamente aplicada para delinear e classificar diferentes tipos de AUs (BAKER *et al.*, 2006; MILLARD; RICHARDSON, 2013; VAN BEIJMA; COMBER; LAMB, 2014). Augusteijn; Warrender (1998) aplicaram imagens ópticas, de radar e DM para classificar e delinear florestas inundadas; Bao; Ren (2011) classificaram AUs a partir de RNA; Li *et al.* (2015) delinearam AUs com imagens de altíssima resolução espacial e técnicas de ML; Jahncke *et al.* (2018) delinearam AUs, integrando dados ópticos e de radar.

No Estado do Rio Grande do Sul (RS) ocorrem diferentes tipos de Áreas Úmidas, como: Banhados, planícies inundáveis, campos úmidos, lagos, lagoas, deltas e estuários. Banhado é uma nomenclatura utilizada no sul do Brasil para representar um tipo de AU, e corresponde à “*marsh*” em inglês. O termo Banhado provém da influência dos países vizinhos Uruguai e Argentina, que popularmente denominam

essas áreas de *bañados* (BURGER, 2000). Nesta tese, o termo Banhado foi adotado pelos seguintes motivos: i) inexistência de uma tradução específica para a palavra *marsh*; ii) utilização do termo na legislação estadual do Rio Grande do Sul; e iii) identificação cultural dos povos da América do Sul com os Banhados, palavra presente em músicas, poemas e versos. Portanto, sempre que empregado nesta tese, o termo Banhado será equivalente a *marsh* em inglês.

Na América do Sul, os ecossistemas de Banhados são encontrados, principalmente, na Região Sul do Brasil, na Argentina e no Uruguai. São caracterizados pela presença de: i) depósitos paludais e turfas; ii) solos hidromórficos; e iii) macrófitas aquáticas. São regulados pelos pulsos de inundação, permanecendo constante ou temporariamente inundados, com a presença de vegetação adaptada às flutuações do nível da água e uma biota característica (SIMIONI; GUASSELLI, 2017).

Dada a importância das áreas de Banhados, estuários e lagunas, o Código Estadual do Meio Ambiente do Rio Grande do Sul (SEMAI-RS) considera estas áreas como de especial proteção (RIO GRANDE DO SUL, 2020). Entretanto, apesar da declarada importância dos Banhados, o Estado do RS não possui uma definição conceitual adequada e tampouco um inventário preciso da localização e extensão dos Banhados e demais tipologias das suas AUs.

2 HIPÓTESE

É consenso que um dos grandes desafios da comunidade científica voltada à AUs se relaciona ao tema delineamento e classificação destes ambientes (BOURGEAU-CHAVEZ et al., 2009; JI et al., 2011; GONG, 2014; LAROCQUE et al., 2014, 2020; ZHU; WEN, 2020). A delimitação de AUs utilizando imagem de satélite não é fácil. Ademais, essa dificuldade acontece mesmo *in loco*, pois, as oscilações do nível da água (CAZALS et al., 2016b; LI et al., 2015), a semelhança espectral da vegetação (RAPINEL et al., 2019) e a presença de solos hidromórficos (KANDUS; MINOTTI; MALVÁREZ, 2008) impõe dúvidas aos cientistas instigados no tema, quanto a delimitação destes ecossistemas (CAZALS et al., 2016b; RAPINEL et al., 2019).

Acreditamos, no entanto, que a utilização de índices espectrais, obtidos em imagens de sensores com diferentes resoluções espectrais, espaciais e temporais auxiliados por técnicas de aprendizado de máquina, possam oferecer alto potencial no delineamento e classificação de Banhados.

Com isto, nossa primeira tarefa foi definir conceitualmente Banhado, para então definir seus limites. O ano de 2017 marcou o início da trajetória desta tese, com a publicação de um artigo no Boletim Geográfico do Rio Grande do Sul, onde propusemos uma definição para Banhados, de modo que abranja de fato todas as características e particularidades desses ambientes (SIMIONI; GUASSELLI, 2017).

Então, a hipótese formulada nessa Tese é de que é possível delinear e classificar com alta acurácia ecossistemas de Banhados a partir da integração de dados de sensoriamento remoto ativo e passivo, índices espectrais e aprendizado de máquina.

3 OBJETIVOS

3.1 Objetivo Geral

O objetivo geral da tese é comparar métodos baseados em sensoriamento remoto ativo e passivo e aprendizado de máquina para delinear áreas de Banhados.

3.2 Objetivos Específicos

- i) Aplicar índices espectrais derivados de imagens do Satélite Sentinel 2A para delinear Banhados;
- ii) Avaliar o potencial de imagens SAR bandas L totalmente polarimétrico (*full-pol*) e C de polarização dupla (*dual-pol*) para delinear Banhados;
- iii) Integrar métodos de aprendizado de máquina e análise multisensor (ativo e passivo) para delinear Banhados;

4 ÁREA DE ESTUDO

Os Banhados do Sul do Brasil têm dinâmicas muito semelhantes, relacionadas as características morfológicas, da vegetação, dos solos e da precipitação. A área de estudo desta tese foi o Banhado Grande (BG), localizado na Região Metropolitana de Porto Alegre - RS.

A definição pela área do BG deu-se pelos seguintes motivos:

- i) Importância ambiental e localização geográfica na região metropolitana de Porto Alegre;
- ii) Histórico de impactos no BG, que se iniciaram na década de 1940 com a drenagem para inserção agrícola, e a retificação de um trecho do rio Gravataí, na década de 1970, que transformou o canal meandrino em retilíneo;
- iii) Desenvolvimento de outros estudos, já que o Laboratório de Geoprocessamento e Análise Ambiental (LAGAM) do CEPSRM/UFRGS desenvolve desde 2012 diversas pesquisas na área;
- iv) Proximidade com os gestores da Área de Proteção Ambiental do Banhado Grande (APABG), entre outros.

4.1 O Banhado Grande

O Banhado Grande é uma Área Úmida de aproximadamente 5.981 ha, localizada na região metropolitana de Porto Alegre. O BG é um dos principais formadores do rio Gravataí (Figura 01). Dada a sua importância ambiental, o Governo do Estado do Rio Grande do Sul instituiu em 1996 a APABG, com o objetivo de controlar o uso do solo frente às transformações ocorridas, principalmente, após a década de 1940, quando muitas AUs foram drenadas para o cultivo agrícola, incentivadas pelo Programa Pró-várzea do Governo Federal (BRENNER, 2016).

A APABG é uma unidade de conservação (UC) estadual instituída pelo Decreto nº 38.971/1998 (RIO GRANDE DO SUL, 1998), com área de 136.935 ha, abrangendo os municípios de Glorinha, Gravataí, Viamão e Santo Antônio da Patrulha. O Sistema Nacional de Unidades de Conservação (SNUC) (BRASIL, 2000) define áreas de APA como

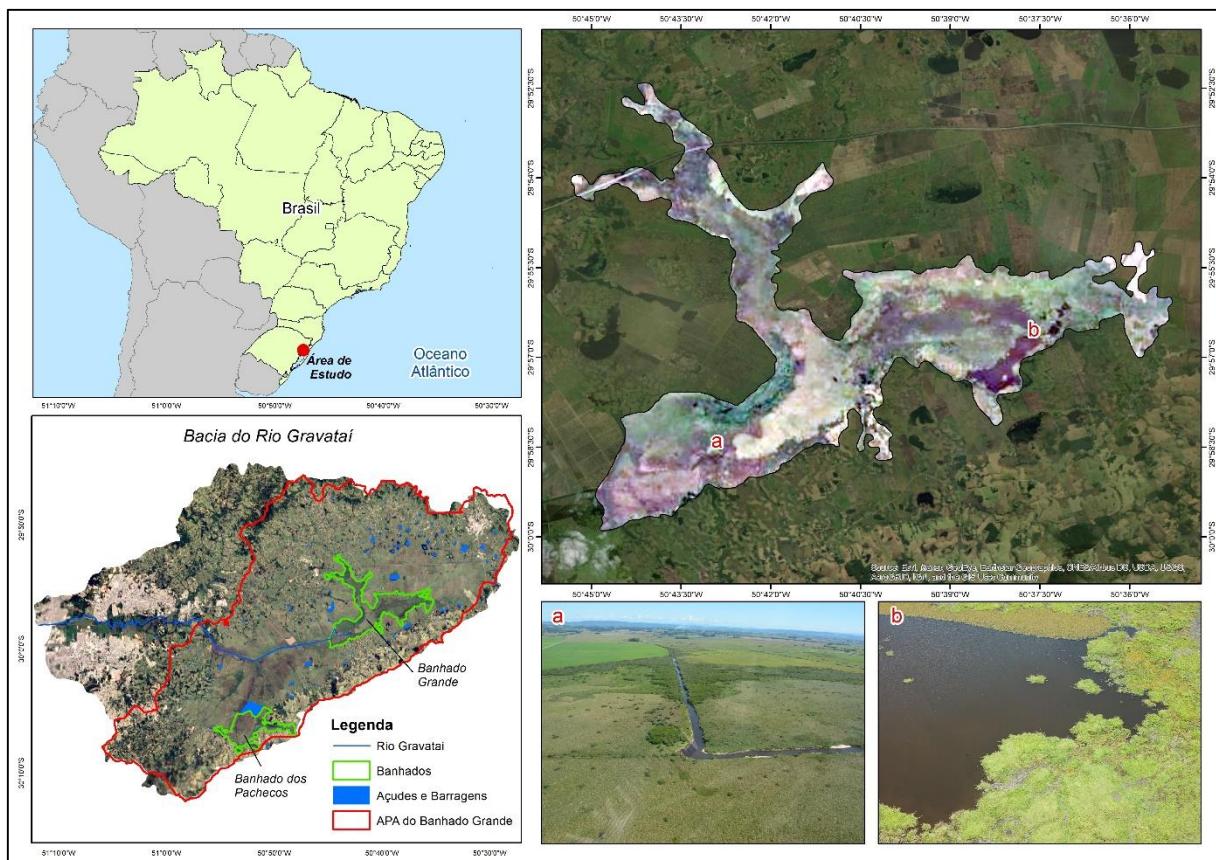
áreas em geral extensas, com um certo grau de ocupação humana, dotadas de atributos abióticos, bióticos, estéticos ou culturais especialmente importantes para a qualidade de vida e o bem-estar das populações humanas, e tem como objetivos básicos proteger a diversidade biológica, disciplinar o processo de ocupação e assegurar a sustentabilidade do uso dos recursos naturais (BRASIL, 2000).

Somente após vinte anos de existência, o Governo do Estado do RS autorizou a elaboração do Plano de Manejo da APABG, que ainda está em andamento. Por ser uma área de APA, as atividades agrícolas são permitidas na APABG. Então, os avanços das fronteiras agrícolas e a drenagem do Banhado Grande têm trazido profundos impactos neste importante ecossistema úmido. Como exemplo, podemos citar o acelerado processo erosivo associado principalmente ao manejo do cultivo do arroz irrigado (ETCHELAR, 2017; SIMIONI; GUASSELLI, 2018).

A APABG está inserida em quatro compartimentos geológicos: depósitos de planícies lagunares, depósitos aluviais, depósitos de planície de inundação e depósitos paludais (VILLWOCK; TOMAZELLI, 1995). Os depósitos paludais ocorrem sob o Banhados Grande, dos Pachecos e Chico-Lomã.

Em grandes pulsos de inundação a área entre os Banhados se conecta com a planície de inundação do rio Gravataí (RUBBO, 2004), numa área associada a cota altimétrica de 11 m (SIMIONI; GUASSELLI; ETCHELAR, 2017). Esta conectividade é extremamente importante para a resiliência desses ambientes, e é responsável por diversas interações entre os compartimentos geológicos da APABG, como a troca de nutrientes, sedimentos e organismos (SIMIONI; GUASSELLI; ETCHELAR, 2017).

Figura 1 - Localização do Banhado Grande, APABG e bacia do rio Gravataí – RS



Fonte: O autor

O BG está inserido num complexo de AUs, denominado Sistema Banhado Grande (SBG), composto por áreas de Banhados, planícies de inundação, campos inundáveis e arrozais (MELLO, 1998; MENEGHETTI, 1998; ACCORDI; HARTZ, 2006). A cobertura vegetal predominante no BG é a comunidade de macrófitas aquáticas, que possuem um padrão heterogêneo de distribuição, influenciado pela dinâmica de inundações e pela hidrodinâmica, formando assim uma estrutura em “mosaicos” (LEITE; GUASSELLI, 2013).

Ao classificar a vegetação do BG utilizando análise geográfica baseada em objetos (GEOBIA), Ruiz et al. (2021) definiram 06 (seis) classes de vegetação, são elas: plantas flutuantes, plantas emergentes, vegetação de transição, campos úmidos, árvores e arbustos e lavouras de arroz (Tabela 01). A maior parte do BG é composta por vegetação de transição (~25%), seguida de plantas emergentes (~23%) e plantas flutuantes (~21%) (RUIZ et al., 2021).

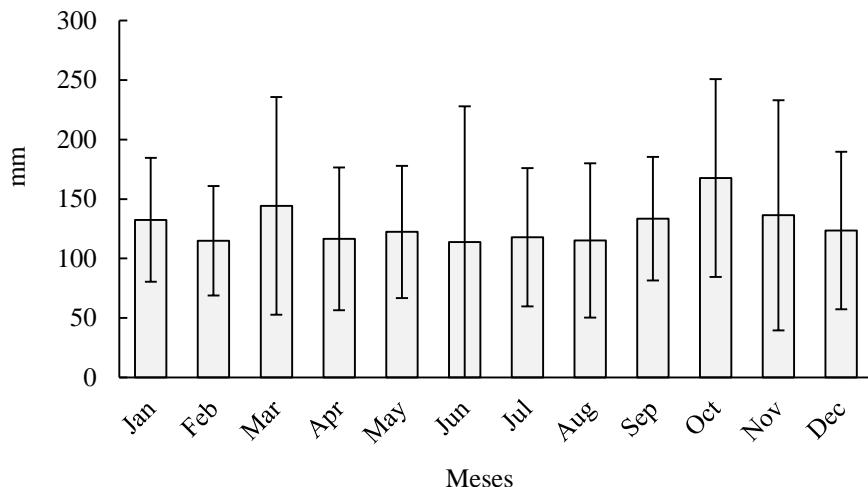
Quadro 1 - Espécies de vegetação dominantes do Banhado Grande

Foto	Classes	Espécies dominantes
	Vegetação de transição	Macrófitas diversas, gramíneas e arbustos
	Plantas emergentes	<i>Cyperus byssaceus, Cyperus giganteus, Senecio bonariensis, Eryngium pandanifolium,</i>
	Campos úmidos	<i>Saccharum angustifolium, Andropogon bicornis, Sida rhombifolia, Mimosa bimucronata, Coleataenia prionitis and gramíneas</i>
	Lavouras de arroz	<i>Oryza sativa</i>
	Plantas flutuantes	<i>Eichhornia crassipes, Eichhornia azurea, Salvinia auriculata Hydrocleys nymphoides, Cabomba caroliniana, Pontederia cordata, Nymphoides indica, Hygrophila costata, Polygonum punctatum, Myriophyllum aquaticum, Ludwigia longifolia.</i>
	Árvores e arbustos	<i>Cephaelanthus glaberatus, Mimosa bimucronata, Erythrina crista-galli, Phyllanthus sellowianus</i>

Fonte: Adaptado de Ruiz *et al.* (2021); Fotos: Ramos (2019)

O regime de inundações é regulado pelos pulsos de inundação. As maiores precipitações da bacia do Gravataí se concentram na região dos patamares da Serra Geral, na porção centro norte da bacia, principalmente nas nascentes do arroio Demétrio, um importante afluente do rio Gravataí (ETCHELAR, 2017). A precipitação anual média varia entre 1.700 e 1.800 mm, sendo outubro o mês de maior precipitação média (167 mm) e fevereiro o mês de menor precipitação (114 mm) (Figura 2) (SIMIONI; GUASSELLI; ETCHELAR, 2017).

Figura 2 - Precipitação mensal média, entre 2000-2016, APABG.



Fonte: Agência Nacional das Águas. Organizado pelo Autor.

A temperatura média anual varia entre 17°C e 20°C. No mês mais quente (janeiro) a temperatura média oscila entre 23°C e 26°, enquanto que, no mês mais frio (julho) oscila entre 11°C e 14°C (COMITÊ GRAVATAHY, 2013).

4.2 Um incêndio devastador

Historicamente, o fogo é utilizado para o manejo da vegetação em todo o mundo (MYERS; GLOBAL, 2006). Quando provocado de forma prescrita e controlada, o fogo remove resíduos e diminui espécies lenhosas ou invasoras, permitindo a regeneração de espécies nativas (KOTZE, 2013). No entanto, em países da América do Sul, principalmente Brasil e Argentina, o fogo tem sido usado para substituição da vegetação natural por pastagens, lavouras e inserção da pecuária (FERREIRA; LETÍCIA; RABELO, 2018; UNL, 2020).

No ano de 2020, a área do BG sofreu um incêndio devastador (Figura 3), com impactos incalculáveis para a fauna e flora local (AMARAL, 2020). Também ocorreram incêndios subterrâneos, queimando depósitos de turfa. Incêndios subterrâneos em turfa ocorrem em épocas de estiagem, geralmente após incêndios superficiais e são devastadores para o ecossistema com severos impactos nos solos de Áreas Úmidas (COTA; BAPTISTA, 2015), e tornam seu combate ainda mais difícil (AMARAL, 2020).

Figura 3 - Avanço da linha de fogo, em 16/04/2020, na área do Banhado Grande

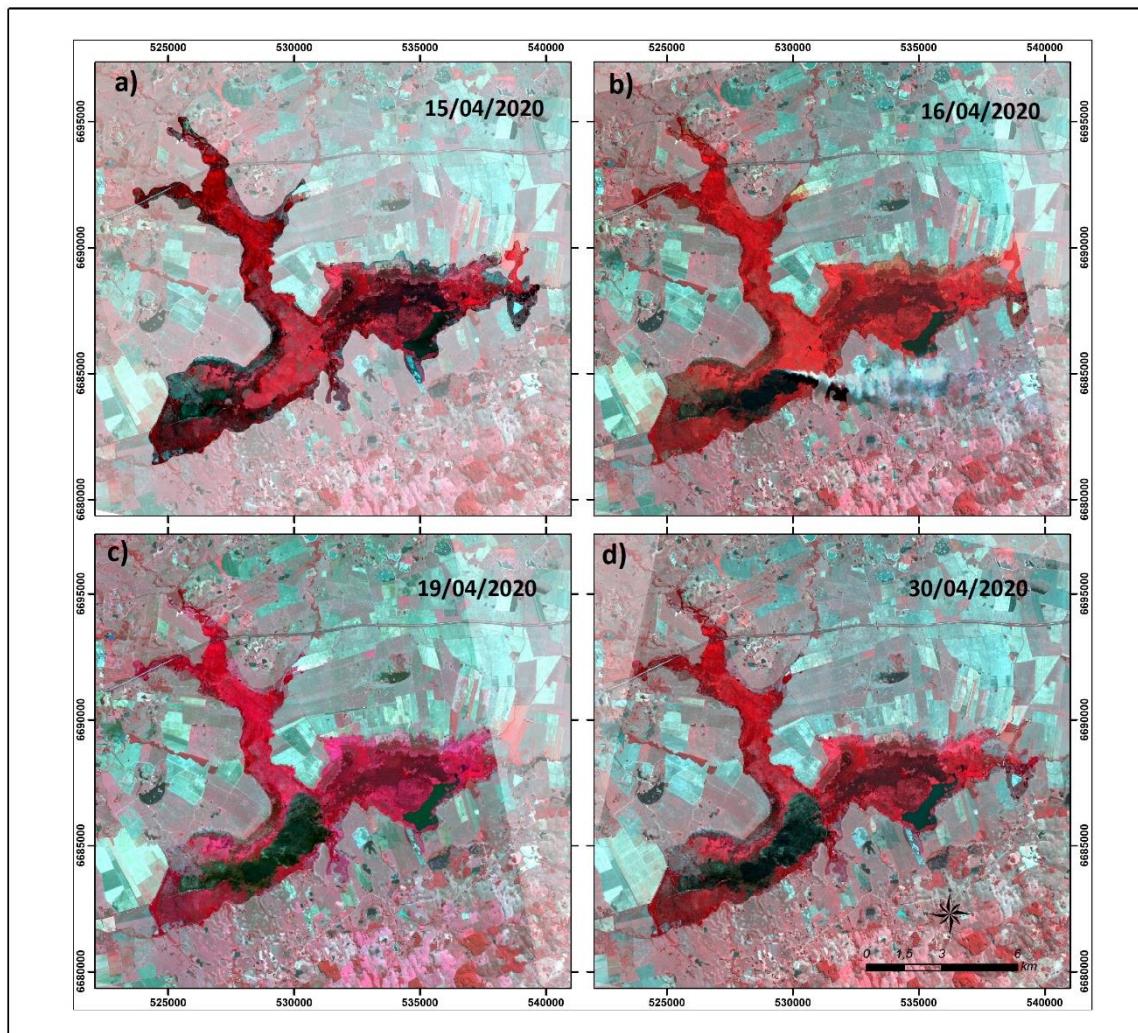


Fonte: Acervo APA do Banhado Grande. Foto: Cecília S. Nin (2020)

O fogo devastou 702 ha da área do BG (aproximadamente 12% da área total), sendo que, as áreas com a presença de vegetação emergente foram as mais devastadas, devido, principalmente a altura das plantas (geralmente variando entre 1 a 2 m) acima no nível da água.

As imagens Planet Scope, Figura 4a, mostram que no dia 15/04/2020 o fogo ainda não havia atingido as plantas emergentes, permanecendo concentrado em uma área próxima ao rio Gravataí. Às 13h do dia 16/04/2020, a imagem Planet Scope captou o avanço do fogo sobre as plantas emergentes, Figura 4b, mostrando que o fogo havia consumido mais de 60% da área com ocorrência de plantas emergentes.

Figura 4. Variação temporal da área queimada pelo fogo no Banhado Grande.



Fonte: Imagem Planet Scope, bandas RBG 432. Elaborado pelo autor.

A imagem do dia 19/04/2020 (Figura 4c), mostra que o fogo em superfície havia sido controlado na área de vegetação emergente, com a atuação dos bombeiros e voluntários e também a presença de um corpo hídrico que impediu o avanço do fogo para os braços leste e sudoeste do BG. No entanto, apesar do fogo superficial ter sido controlado, continuou o chamado incêndio subterrâneo, com a queima da turfa, que perdurou até o final do mês de abril, quando o fogo foi totalmente controlado (Figura 4d).

5 ESTRUTURA DA TESE

Esta tese “Métodos baseados em sensoriamento remoto para delineamento de Banhados” foi estruturada na forma de artigos científicos, estando organizada conforme normas do PPGSR.

O Capítulo 6 apresenta o Desenvolvimento da Tese. Está divido em Referencial Teórico (Capítulo 6.1) onde são discutidos os principais conceitos, bases e métodos envolvidos na temática de AUs e abordados na Tese; Procedimentos metodológicos (Capítulo 6.2) e Resultados (Capítulo 6.3) onde são apresentados artigos científicos, publicados em reconhecidas revistas internacionais, seguindo a Resolução Nº 115/2014 da Câmara de Pós-Graduação da Universidade Federal do Rio Grande do Sul.

Optou-se por apresentar como resultados os seguintes artigos:

- i) SIMIONI, J.P.D.; GUASSELLI, L.A.; RUIZ, L.F.C.; NASCIMENTO, V.F.; OLIVEIRA, G. Small inner marsh area delimitation using remote sensing spectral indexes and decision tree method in southern Brazil”. **Revista de Teledetección**, v.52, p.55-66, 2018. (SJR 2019 0,49).
- ii) SIMIONI, J.P.D.; GUASSELLI, L.A.; OLIVEIRA, G.G.; RUIZ, L.F.C.; OLIVEIRA, G. 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 (Springer)**, v. 22, p. 5603-5620, 2019 (JCR 2019 2.191).;
- iii) SIMIONI, J.P.D.; GUASSELLI, L.A.; RUIZ, L.F.C.; NASCIMENTO, V.F.; OLIVEIRA, G. A comparison of data mining techniques and multi-sensor analysis for inland marshes delineation. **Wetlands Ecology and Management (Springer)**, v.28, p. 577-594, 2020. (JCR 2019 1.221).

No decorrer do período da tese também foram publicados:

SIMIONI, J. P. D.; GUASSELLI, L. A. Simulation of changes in land-use/land cover on wetlands through CA-Markov model. **Revista Brasileira de Geografia Física**, v.11, p. 1, 2018.

SIMIONI, J.P.D.; GUASSELLI, L.A.; SILVA, T.S. Shifting habitat mosaic: identification and mapping. **Revista Ambiente e Água**, v.14, p.1-13, 2019.

GUASSELLI, L.A.; SIMIONI, J.P.D.; LAURENT, F. Mapeamento e classificação de áreas úmidas usando topographic wetness index (TWI) a partir de Modelos Digitais de Elevação, na bacia hidrográfica do rio Gravataí - Rio Grande do Sul, Brasil. **Revista Brasileira de Geomorfologia**, v.21, p.639-659, 2020.

SIMIONI, J.P.D.; GUASSELLI, L.A.; OLIVEIRA, G.; MATAVELI, G.A.V.; SANTOS, T.V. A Remote Sensing-Based Method to Assess Water Level Fluctuations in Wetlands in Southern Brazil. **GeoHazards**, v.1, p.3-30, 2020.

RUIZ, L.F.C.; SIMIONI, J.P.D.; BELLOLI, T.F.; BARROS FERNANDES, P.C.; GUASSELLI, L.A. Object-based classification of vegetation species in a subtropical wetland using Sentinel-1 and Sentinel-2A images. **Science of Remote Sensing**, v. 3, p. 100017, 2021.

E, estão em avaliação:

SIMIONI, J.P.D.; GUASSELLI, L.A.; BELLOLI, T.F.; RAMOS, R.A. A remote sensing-based method to assess subtropical wetland fire resilience. **Journal of Land Use Sciense** (em avaliação).

SIMIONI, J.P.D.; GUASSELLI, L.A.; FACCO, D. S. OLIVEIRA, G. de. Dual-season comparison of OBIA and pixel-based approaches for subtropical coastal wetland classification. **Estuarine, Coastal and Shelf Science** (em avaliação).

SIMIONI, J.P.D.; GUASSELLI, L.A.; FACCO, D. S. OLIVEIRA, G. de.; MATAVELI, G. A. V.; GUERRERO, J.V.R. Application of data mining techniques based on geomorphometric and hydrologic indices for mapping wetlands in the Gravataí River Basin, Southern Brazil. **Journal of South American Earth Sciences** (em avaliação).

O Capítulo 7 apresenta as Conclusões e Considerações finais.

6 DESENVOLVIMENTO

6.1 Referencial Teórico

No referencial teórico apresentamos e discutimos os principais conceitos, bases e métodos envolvidos na temática de AUs e abordados na Tese.

Na primeira parte do Referencial Teórico tratamos das principais definições acerca de AUs e suas tipologias, além do paradigma clássico das AUs sobre serem ou não ecossistemas de transição aquático/terrestre. Discutimos os principais sistemas de classificações, e trazemos um panorama sobre as AUs do Rio Grande do Sul, com ênfase nas áreas de Banhados.

Na sequência abordamos os sensores ativos e passivos e a contribuição de artigos que envolvem aplicações, vantagens e desvantagens acerca do delineamento e classificação de AUs. Além disso, realizamos uma análise bibliométrica de estudos que envolvem sensoriamento remoto e AUs, de modo a demonstrar os principais países, autores e palavras-chave envolvidos na temática. Por fim, discutimos os conceitos de aprendizado de máquina e de algoritmos de aprendizado de máquina utilizados no delineamento de Banhados empregados nesta tese.

6.1.1 Áreas Úmidas

6.1.1.1 Definições nacionais e internacionais

Durante séculos, a humanidade tratou as Áreas Úmidas como ambientes indesejáveis, insalubres e improdutivos, associados a vetores e que impediam o desenvolvimento agrícola (HOOK, 1993). Áreas Úmidas em todo o mundo foram drenadas e convertidas em terras agrícolas, áreas urbanas e industriais. Matthews (1993) relembra que o desaparecimento das Áreas Úmidas passou então a trazer consequências danosas para a sociedade, como a perda de reservas de água subterrânea, maior recorrência de inundações, aumento da erosão em ambientes costeiros, maior acúmulo de poluentes e outros distúrbios e desaparecimento de plantas, animais e aves.

A partir da segunda metade do século XX, quando os efeitos adversos da destruição das Áreas Úmidas torna-se evidente, principalmente face ao desaparecimento de aves aquáticas, é que a União Internacional para a Conservação da Natureza e dos Recursos Naturais (IUCN) organiza em 02 de fevereiro de 1971 na

cidade de Ramsar no Irã, a “Convenção sobre Zonas Úmidas de Importância Internacional, especialmente como Habitat para Aves Aquáticas”. Posteriormente denominada de Convenção de Ramsar, quando representantes de 18 nações assinaram o texto de um tratado notável, de interesse global.

A Convenção de Ramsar foi então o primeiro dos instrumentos modernos que buscaram conservar os recursos naturais em escala global, em especial os habitats de aves aquáticas (MATTHEWS, 1993). Na convenção foi proposta uma definição para Áreas Úmidas, que ainda é a mais aceita pela comunidade científica. Segundo a Ramsar (1971)

Áreas Úmidas são áreas de pântanos, brejos, turfeiras ou de água rasa, sejam naturais ou artificiais, permanentes ou temporárias, doce, salobra ou salinas, incluindo áreas de águas marinhas nas quais a profundidade na maré baixa não excede seis metros (RAMSAR, 1971).

No entanto, por ser uma das primeiras definições de AUs, este conceito é bastante amplo, considerando AUs, áreas com profundidade de até 6 (seis) metros. Isto pode gerar uma confusão conceitual, pois, a definição pode abranger habitats exclusivamente marinhos (GUASSELLI, 2005) e ao mesmo tempo ignorar habitats que estão a mais de 6 m de profundidade, como o caso de alguns recifes de corais (SIMAN; MAGALHAES JÚNIOR, 2018).

O fato da definição de AUs, segundo a Convenção de Ramsar ser demasiada abrangente faz com que características e particularidades de diferentes tipos de AUs não sejam levadas em consideração. Porém, como menciona Cowardin et al. (1979) é praticamente impossível propor uma definição de Áreas Úmidas que conte cole todos esses ecossistemas, dada a grande diversidade e as diferentes tipologias. Os autores salientam que a única característica comum entre a maioria das AUs é a presença de solo ou substrato periodicamente ou permanentemente saturado ou coberto por água.

Assim como Cowardin et al. (1979), Brinson (1993) também afirma que não há consenso sobre uma definição universal de AUs. O termo é usualmente empregado para denominar sistemas em condições de inundação, ou com solos saturados com água por períodos prolongados (BRINSON, 1993).

É justamente a partir da necessidade de abranger as características e peculiaridades das AUs que Cowardin et al. (1979) propõem uma definição geral, objetivando a classificação desses ecossistemas, tratando as AUs como

áreas de transição entre os sistemas terrestres e aquáticos, onde o lençol freático é geralmente na superfície ou perto dela ou a terra é coberta por águas rasas. Para fins de classificação, as AUs devem ter um ou mais dos seguintes três atributos: (1) pelo menos periodicamente, a terra suporta predominantemente plantas aquáticas; (2) o substrato é composto por solo hidromórfico; (3) o substrato é não-solo e é saturado com água ou coberto por águas rasas em algum momento do ano (COWARDIN *et al.*, 1979).

Destaca-se que Cowardin et al. (1979) vão além da definição proposta pela Covenção Ramsar, ao adicionar características das AUs em sua definição como, por exemplo, a presença de plantas aquáticas, solos hidromórficos e aspectos hidrológicos. Além disto, Cowardin et al. (1979) introduzem o termo “áreas de transição aquático/terrestre”, tratando essas áreas como ambientes ecótonos, ou seja, nem somente terrestre, tampouco somente aquático.

A definição proposta por Cowardin et al. (1979) passa então a ser aprimorada com a criação do conceito de pulso de inundação (JUNK; BAYLEY; SPARKS, 1989), relativo a sequência entre períodos de inundação e seca em Áreas Úmidas como a força dominante dos processos ecológicos de alagamento periódico. Junk; Bayley; Sparks (1989) propuseram uma definição para planícies de inundação, considerando esses ambientes como Zonas de Transição Aquático/Terrestre (ZTATs).

Ao abordar os conceitos de zonas de transição ou interface Cowardin et al. (1979) e Junk; Bayley; Sparks (1989) tratam as AUs como ambientes ecótonos, ou seja, ambientes de transição entre duas comunidades ou de tensão entre ambas (CLEMENTS, 1905).

Neiff (2003a), no entanto, contrapõe-se a ideia de que grandes Áreas Úmidas sejam zonas de transição aquático/terrestre. O autor justifica que na década de 1980 as definições de Áreas Úmidas eram voltadas basicamente para extensas planícies de inundação. Neiff (2003b) entende que estes ambientes como macroecossistemas que não têm características de transição entre ecossistemas terrestres e aquáticos. Entretanto, nas AUs pode existir localmente ecótonos e também contínuos,

dependendo dos graus de interações ambientais, especialmente, do regime hidrológico (NEIFF, 2003).

O Canadá é um dos países referência no âmbito das Áreas Úmidas, com inventários ricos em informações e detalhes sobre esses ecossistemas (CANADIAN WETLAND INVENTORY TECHNICAL GROUP, 2016). Criado em 2002, o *Canadian Wetland Inventory* (CWI) apresenta recentemente uma versão implementada no *Google Earth Engine*, com imagens Sentinel 2A e 2B com 10 m de resolução espacial (MAHDIANPARI *et al.*, 2020).

O Grupo Canadense de Estudos de Áreas Úmidas (1997) define Áreas Úmidas como

“áreas saturadas de água por tempo suficiente para promover zonas úmidas ou processos aquáticos, caracterizadas por solos mal drenados, vegetação hidrofítica e vários tipos de atividades biológicas adaptadas a um ecossistema úmido”.

Ou seja, assim como a definição proposta pela Convenção Ramsar, a definição de AUs do Grupo Canadense de Estudos de Áreas Úmidas (1997) não trata esses ecossistemas como zonas de transição aquático/terrestre, mas sim, ambientes caracterizados por solos hidromórficos, vegetação hidrofítica e aspectos hidrológicos.

A questão acerca das definições sobre as Áreas Úmidas serem ou não ambientes de transição aquático/terrestre é discutida também pelo grupo de especialistas em Áreas Úmidas da *California Wetland and Riparian Area Protection Policy* (2009). Esses especialistas demonstram discordância de Neiff (2003) ao entenderem que os termos transição e interface não denotam necessariamente “localização geográfica”, mas sim, são empregados para reforçar que as Áreas Úmidas não são totalmente terrestres nem totalmente aquáticas, ou seja, possuem habitats ou manchas (*patches*) com atributos terrestres e aquáticos.

Kandus *et al.* (2018) consideram que as AUs não são ambientes de transição, pois possuem características funcionais e estruturais próprias, ou seja, com identidade própria, como as turfeiras, por exemplo. Conforme as autoras, a principal característica das AUs é a sua funcionalidade em termos de regime hidrogeomórfico, o que de fato pode demonstrar as características e o comportamento das AUs.

Nosso estudo, corrobora com a ideia de Kandus *et al.* (2018), uma vez que, áreas de Banhados possuem características funcionais próprias, sendo reguladas por pulsos de inundação, contrapondo-se a ideia de um “ambiente transicional”, mas sim, um ambiente ora seco, ora inundado.

Essas peculiaridades funcionais e estruturais que tornam as AUs diferentes entre si, instigaram o grupo de pesquisadores da *California Wetland and Riparian Area Protection Policy* (2009) a criar uma definição própria de AUs. Os pesquisadores entendiam que as definições existentes não contemplavam de fato as AUs da Califórnia, criando assim, um conceito, segundo o qual

uma área é considerada úmida se, em circunstâncias normais, ela (1) for saturada por água subterrânea ou inundada por água superficial rasa por um período suficiente para causar condições anaeróbicas no substrato superior; (2) exibe condições de substrato hídrico indicativas de tal hidrologia; e (3) possui ausência de vegetação ou a vegetação é dominada por hidrófitas (*California Wetland and Riparian Area Protection Policy* 2009).

Além destas, diversas outras definições de Áreas Úmidas foram desenvolvidas, de modo, a preencher lacunas e atender as características e peculiaridades desses ambientes em âmbito regional. Na América do Sul, Neiff; Irondo; Carnan (1994) propuseram a seguinte definição para as grandes Áreas Úmidas

sistemas de extensão sub-regional onde a presença espacial e temporal da água provoca fluxos biogeoquímicos característicos, solos com hidromorfismo acentuado e uma biota cuja estrutura e dinâmica está bem adaptada a uma vasta variabilidade de disponibilidade de água. Podem ser consideradas macrossistemas cuja complexidade cresce com a variabilidade hidrossedimentológica e a extensão geográfica (NEIFF; IRONDO; CARNAN, 1994).

No Brasil, o Instituto Nacional de Ciência e Tecnologia em Áreas Úmidas (INAU) é referência em estudos que envolvem AUs. O grupo composto por pesquisadores de importantes universidades brasileiras e estrangeiras, desenvolve pesquisas nos âmbitos de definição e delineamento das AUs. O INAU, a partir de um importante documento publicado por seus pesquisadores (JUNK *et al.*, 2014) define AUs como sendo:

ecossistemas na interface entre ambientes terrestres e aquáticos, continentais ou costeiros, naturais ou artificiais, permanentemente ou

periodicamente inundados por águas rasas ou com solos encharcados, doces, salobras ou salgadas, com comunidades de plantas e animais adaptadas à sua dinâmica hídrica (JUNK *et al.*, 2014; CUNHA; PIEDADE; JUNK, 2015).

Assim como Junk; Bayley; Sparks (1989), o INAU entende que a maioria das AUs brasileiras são consideradas Áreas Úmidas de pulsos de inundação, e caracterizadas como Zona de Transição Aquático/Terrestre. Os autores salientam que em AUs extensas, como as várzeas e igapós amazônicos ou do Pantanal Mato-grossense, as ZTATs são compostas por muitos habitats diferentes e incluem, além das áreas periodicamente secas e alagadas, também habitats permanentemente aquáticos, como lagoas e canais, e terrestres, tais como paleovárzeas, paleodunas e *inselbergs*, que são de importância fundamental para a manutenção da biodiversidade e da produtividade do sistema (CUNHA; PIEDADE; JUNK, 2015).

6.1.1.2 Sistemas de Classificação de Áreas Úmidas

Uma análise histórica dos sistemas de classificações de Áreas Úmidas revela que as primeiras classificações tinham como objetivo encontrar AUs que pudessem ser drenadas para o uso humano (GERBEAUX; MAX FINLAYSON; VAN DAM, 2018). Tais classificações baseavam-se em informações sobre tipos de solo de acordo com seu potencial agrícola. Por exemplo, as Áreas Úmidas de fácil drenagem, Áreas Úmidas com necessidade de dreno e aterro e Áreas Úmidas não drenáveis, ou seja, impróprias para o cultivo (GERBEAUX; MAX FINLAYSON; VAN DAM, 2018).

Do ponto de vista ambiental, as primeiras classificações foram realizadas para comporem inventários de manejo e conservação. Brinson (2011) reconhece três diferentes abordagens de classificação que em geral são comumente utilizados para AUs: estrutura, funcionamento e utilidade.

A estrutura representa os tipos de Áreas Úmidas, por exemplo, pântanos, florestas inundadas, brejos, planícies de inundação, entre outros. A característica estrutural de cada tipologia de AU é responsável pela conceituação e definição dos diferentes tipos de AUs existentes. O funcionamento evidencia as diferenças entre a forma como as AUs recebem e transportam água, uma vez que, o regime hidrológico é o componente mais crítico do comportamento das AUs. A utilidade diz respeito a

como as AUs são manejadas pela sociedade humana dada sua capacidade de fornecer processos de suporte à vida conhecidos como serviços ecossistêmicos (BRINSON, 2011).

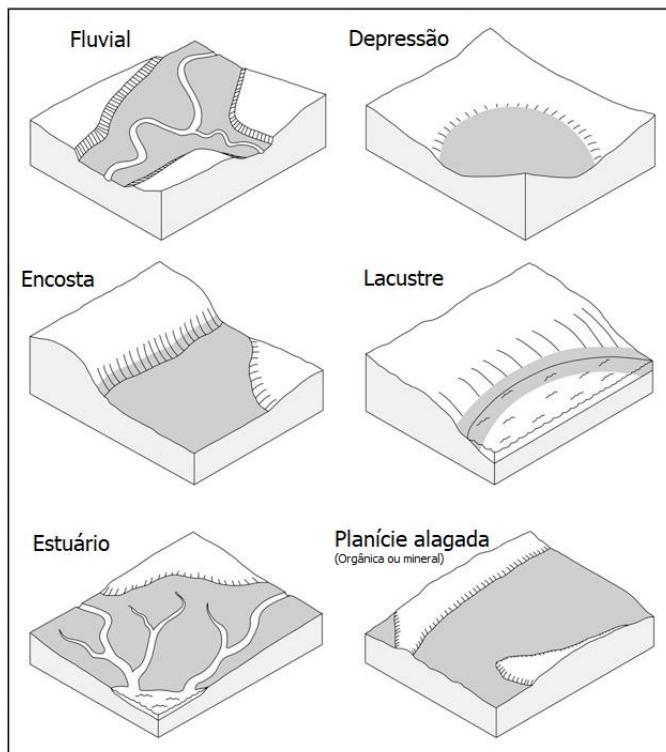
Em relação aos tipos de classificação, Brinson (2011) sugere que a abordagem estrutural é a mais indicada para mapeamentos e inventários. Para avaliação da condição de uma AU, emprega-se a classificação funcional; e, a abordagem de utilidade mostra os serviços ecossistêmicos proveniente das AUs como, por exemplo, as utilizadas como abastecimento (alimentos, água doce, combustível), as reguladoras (clima, enchentes e purificação da água), as culturais (estético, educacional e recreativos) e as de apoio (produção primária, ciclagem de nutrientes).

Diversas pesquisas têm buscado desenvolver métodos para classificar AUs. Com o objetivo de definir limites em ecossistemas naturais dos Estados Unidos, para fins de inventários, gestão e manejo, Cowardin et al. (1979) desenvolveram um dos primeiros métodos de classificação. Levando em consideração os aspectos estruturais, essa classificação aborda as AUs conforme sua hierarquia (sistemas marinhos, estuarinos, fluviais, lacustres e palustres), classes, subclasses e uma série de características relativas ao regime hidrológico, química da água (salinidade, pH) e solos.

Posteriormente, Scott (1980) desenvolveu uma classificação das Áreas Úmidas voltada principalmente para a conservação de aves aquáticas, na Europa Ocidental e noroeste do continente Africano. No início da década de 1990 é publicada a classificação oficial da Ramsar (1990) para AUs. Inicialmente a classificação de Ramsar (1990) abordou as AUs em três tipologias principais: i) marinhas ou costeiras; ii) interiores ou continentais; e iii) artificiais (SCOTT; JONES, 1995). Posteriormente foram incluídos os Sistemas Cársticos.

Brinson (1993) propôs uma classificação de AUs baseada nas unidades hidrogeomorfológicas (HGM's). O autor esclarece que três fatores influenciam diretamente no funcionamento de uma AU: i) geomorfologia; ii) fonte de água dominante e seu transporte (precipitação, fluxo superficial, fluxos subterrâneos, descarga de água subterrânea e ressurgência) e; iii) hidrodinâmica (direção e fluxo e movimento da água dentro da AU) (BRINSON, 1993; GOMES, 2017). As sete classes de AUs definidas por Brinson (1993) são ilustradas na Figura 5.

Figura 5 – Unidades Hidrogeomorfológicas definidas por Brinson (1993).



Fonte: Brinson, 1993

Na abordagem HGM, os Banhados podem ser classificados como:

- i) AUs fluviais: quando são localizados ao longo de rios e canais fluviais, e as fontes de água dominantes provém do extravasamento lateral dos rios durante os pulsos de inundação e de conexões subterrâneas entre o canal do rio e o Banhado, como é o caso do BG.
- ii) AUs de Depressões: quando apresentam uma área com um contorno de elevação fechado que permite o acúmulo de água superficial. Nesses casos, as fontes dominantes de água são precipitação, descarga de água subterrânea e interfluxo de terras altas adjacentes. Esses Banhados são característicos de terras altas.

Devido as diferentes tipologias e às peculiaridades características, diversos países criaram seus próprios sistemas de classificação, de modo a atender as demandas de gestão e conservação das AUs no âmbito nacional.

Uma das classificações mais conhecidas é a *Canadian Wetland Inventory* que divide as AUs em águas rasas (*shallow water*), águas abertas (*open water*), banhados (*marshes*), florestas inundadas (*swamps*), turfeiras (*fen*) e pântanos (*bog*). O CWI é

responsável pela restauração e conservação de aproximadamente 263.000 km² de AUs.

O sistema de classificação de AUs da África do Sul (OLLIS *et al.*, 2013) é referência internacional, dada sua abrangência e complexidade de análise, abordando as AUs em seis diferentes níveis. A estrutura em camadas inicia nos tipos de sistemas (marinho, estuarino, interior) (Nível 1), passando para a configuração regional (Nível 2), Unidades de Paisagem (Nível 3) e o nível 4 refere-se às Unidades Hidrogeomorfológicas. No nível 5 os sistemas internos são diferenciados com base no regime hidrológico. No nível 6, 'descritores' são incorporados ao sistema de classificação. Esses descritores permitem distinguir entre ecossistemas aquáticos com diferentes características estruturais, químicas e/ou biológicas, Figura 6.

Figura 6 - Sistema de classificação de Áreas Úmidas da África do Sul



Fonte: Ollis *et al.*, 2013

A França utiliza para delinear e classificar suas AUs uma abordagem Hierárquica para Delimitação de Áreas Úmidas (PEEW), proposta por Durandu et al. (2000), e aprimorada por Merot et al. (2006). A abordagem PEEW hierarquia as AUs em três níveis: i) áreas potencialmente úmidas (APUs); ii) áreas úmidas efetivas; e iii) áreas úmidas eficazes.

Áreas potencialmente úmidas são todos ambientes que possuem características de AU, como hidromorfismo, hidrologia, vegetação e geologia. Para identificar as APUs os pesquisadores do MEDDE (2014) dividiram a França em Hidro-Ecorregiões, com características hidrológicas e pedológicas semelhantes. Muitas áreas identificadas como APU podem ter sido perdidas, através do desenvolvimento antrópico (drenagem, avanço agrícola, aterros, desmatamentos, entre outros) (MEROT et al., 2006).

As AUs efetivas são áreas mapeadas como potencialmente úmidas e que de fato são áreas úmidas (banhados, florestas inundadas, pântanos, planícies de inundação, turfeiras, veredas, mangues, entre outros), com baixo ou nenhum grau de intervenção antrópica. Essas áreas foram identificadas através de mapas de uso e cobertura do solo e trabalhos de campo.

A Área Úmida eficaz corresponde às funções, bens e serviços ecossistêmicos desempenhados pela Área Úmida (desnitrificação, valor patrimonial, regulação climática, controle de cheias, fixação de carbono, refúgio de aves migratórias, manutenção de espécies ameaçadas, valores econômicos, como pesca, ecoturismo, lazer e extrativismo sustentável, entre outros), Figura 7.

Figura 7 - Abordagem Hierárquica para Delimitação de Áreas Úmidas (PEEW)



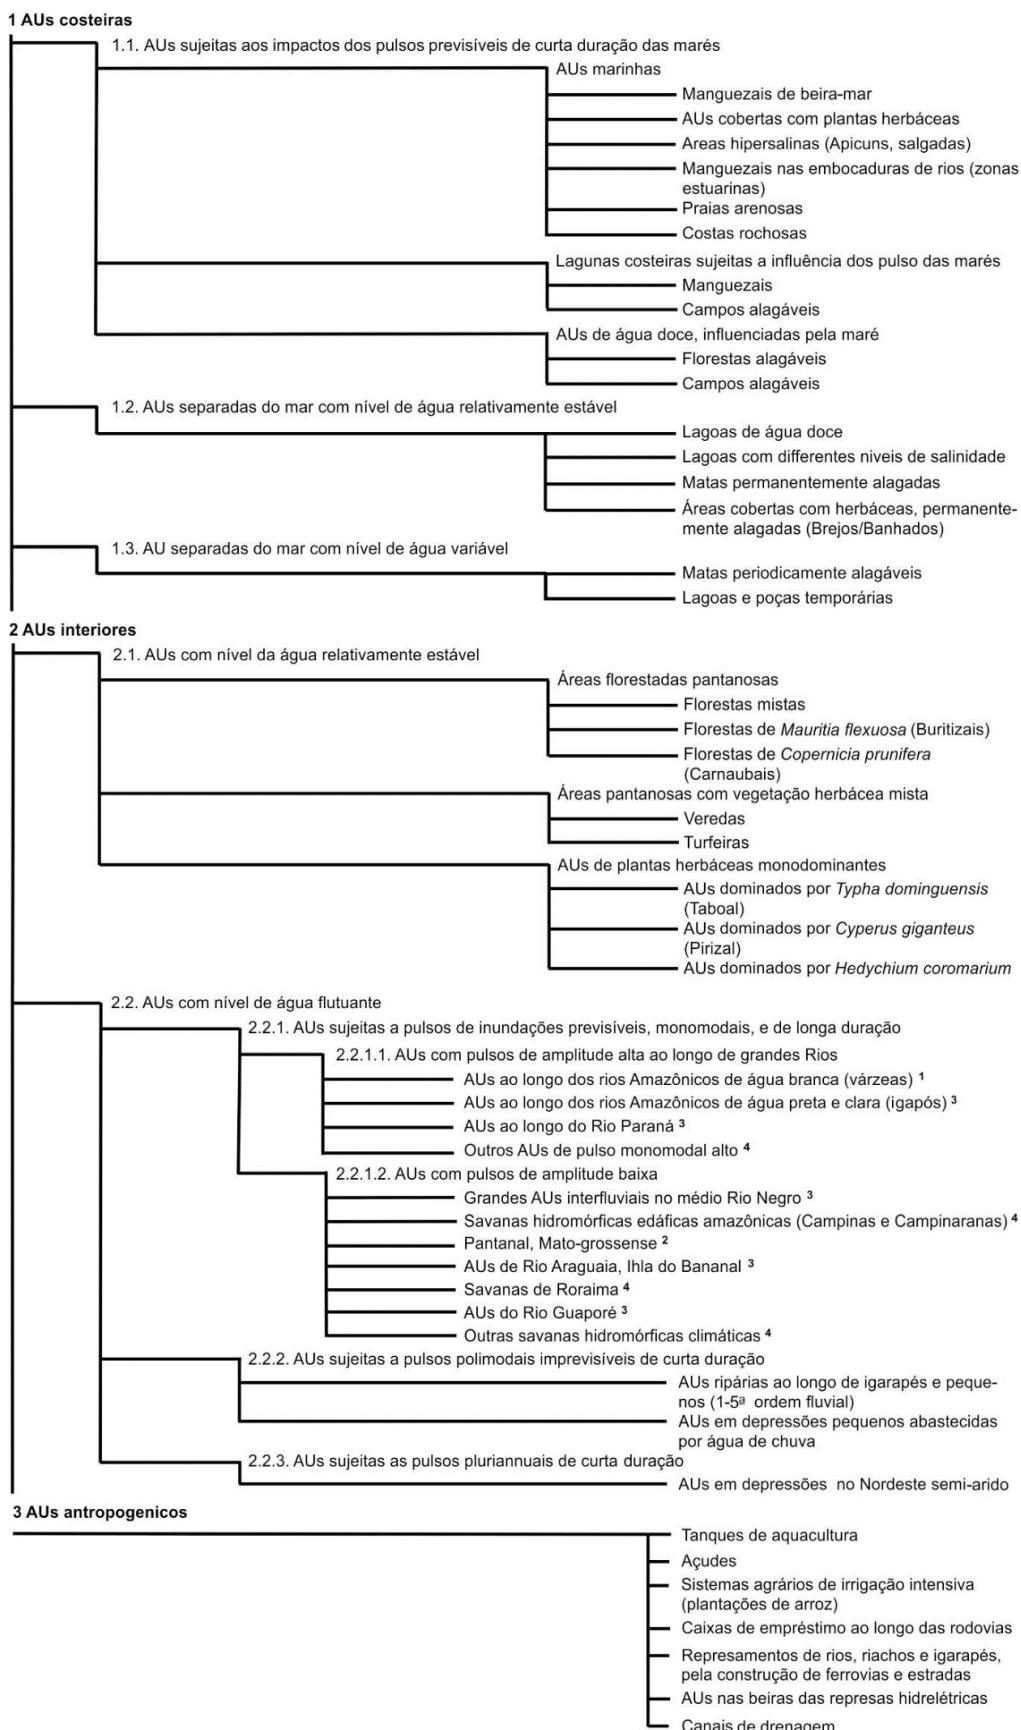
Fonte: Durandu et al. (2000) e Merot et al. (2006)

Na América do Sul, diversos países possuem sistemas de classificações e mapeamento das AUs. Na Colômbia, por exemplo, o relatório Colômbia Anfíbia (INSTITUTO HUMBOLDT, 2015), define um sistema de classificação de AUs baseando-se em critérios geomorfológicos, hidrológicos, solos e vegetação. As AUs foram definidas em 5 unidades: AUs de Montanha, AUs da costa caribenha, AUs da costa do Pacífico, AUs da Orinoquia e AUs da Amazônia.

Canevari et al. (1999) realizaram a classificação e inventário das AUs Argentinas, e posteriormente, Kandus; Minotti; Malvárez (2008) mapearam as AUs a partir da classificação de solos. Ginzburg et al. (2005) propuseram uma classificação para as AUs do Chaco, baseando-se principalmente em dados hidrológicos.

No Brasil há um grande esforço de pesquisadores para classificação e mapeamento de AUs, com destaque para o INAU. Neste sentido, Cunha; Piedade; Junk (2015a) propuseram uma classificação das AUs brasileiras baseadas em níveis hierárquicos até o nível de macrohabitats (Figura 8).

Figura 8 - Proposta de classificação das Áreas Úmidas brasileiras



Fonte: Cunha; Piedade; Junk (2015a)

A classificação de Cunha; Piedade; Junk (2015) aborda as Áreas Úmidas brasileiras de forma hierárquica, iniciando a divisão entre ecossistemas costeiros, ecossistemas interiores e Áreas Úmidas antropogênicas. Tal classificação é um significativo avanço para o delineamento e inventário das Áreas Úmidas brasileiras, pois, atende a critérios de grandes áreas úmidas até pequenas áreas, como AUs dominadas por *Cyperus giganteus*, por exemplo.

Gomes (2017) e Siman; Magalhaes Júnior (2018) propuseram uma classificação das AUs para o estado de Minas Gerais. Os autores realizaram uma ampla sistematização dos sistemas de classificação existentes e propuseram uma classificação com base em padrões HGMs. A proposta de classificação baseia-se em 4 níveis: i) Sistema de Interior; ii) Bioma (Cerrado, Mata Atlântica e Caatinga); iii) característica geomorfológica da paisagem; e iv) Classes HGM (AUs de Planícies Inundáveis, AUs Planas e Elevadas, AUs Deprimidas, AUs de Cabeceira de Drenagem, AUs de Fundos de Vale) (GOMES; MAGALHAES JR, 2020). As AUs foram então classificadas em: Brejos e Pântanos, lagoas difusas, lagoas transicionais, veredas e campus de murundus.

Maltchik et al. (2004) propuseram uma classificação para as AUs do Estado do Rio Grande do Sul, a partir de critérios estabelecidos por Cowardin et al. (1979). Classificaram as AUs conforme o sistema, subsistema, tipo, classe e subclasse. Conforme os autores, das 146 Áreas Úmidas estudadas, 95,9% estão no sistema palustre e 4,1% artificial. Dentre o subsistema palustre, 62,8% foram consideradas palustre, 28,6% como lacustre e 8,6% planícies de inundação. O trabalho de Maltchik et al. (2004) é importante, pois, foi a primeira classificação de Áreas Úmidas no Rio Grande do sul.

Guasselli; Simioni; Laurent (2020) compararam diferentes Modelos Digitais de Elevação (MDEs) para delinear áreas de captação e identificar padrões de drenagem e de escoamento. Aplicaram o *Topographic Wetness Index* (TWI) para mapear e classificar Áreas Úmidas. De forma particular, em áreas de topografia plana, essas informações de relevo são difíceis de obter, mas muito úteis para identificar as AUs. Além disso, áreas de depressões no MDE podem ser zonas úmidas características da paisagem.

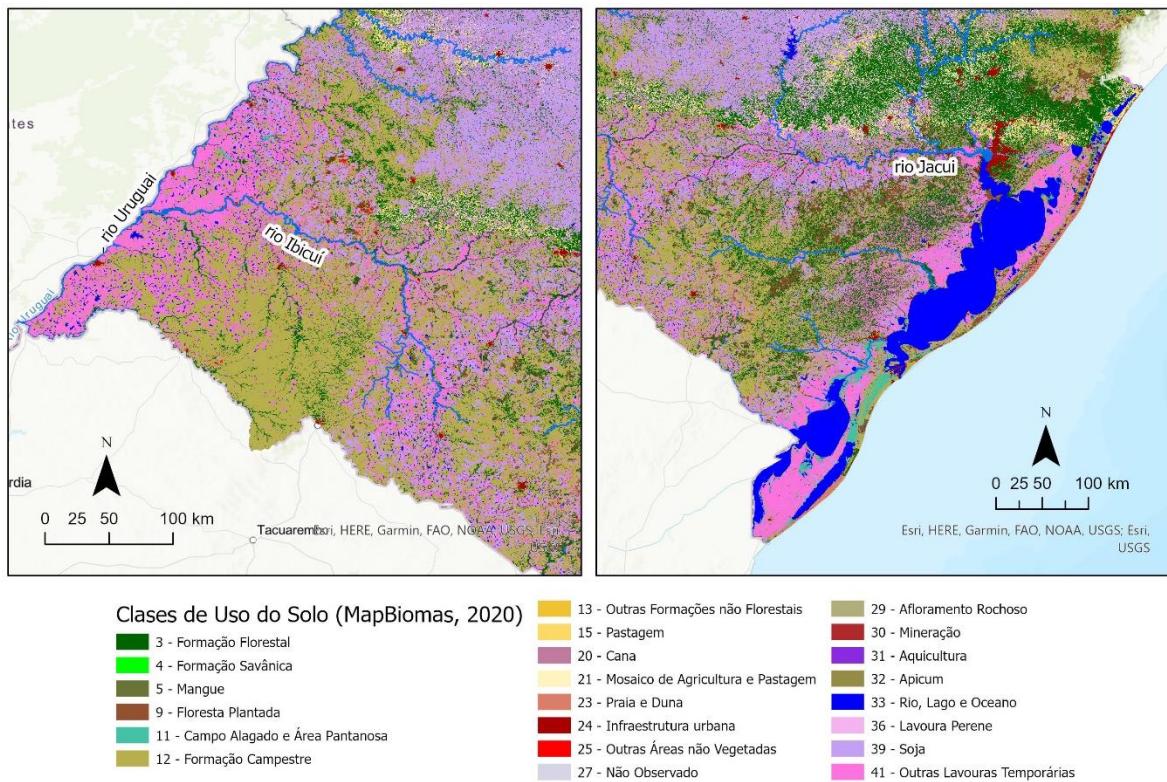
Ruiz et al. (2021) avaliaram o desempenho dos métodos de ML: RF e k-NN na classificação baseada em objetos de espécies de vegetação no BG, integrando imagens S1 e S2A.

6.1.1.3 Áreas Úmidas do Rio Grande do Sul

No Rio Grande do Sul ocorrem diferentes tipos de Áreas Úmidas. As várzeas dos rios Uruguai, Jacuí e Ibicuí, as lagoas Mirim e Mangueira, a Laguna dos Patos, estuários e marismas, os Banhados do Canal de São Gonçalo, da bacia do rio Gravataí, do Taim, de São Donato, e da Lagoa do Peixe são exemplos da riqueza de tipologias de Áreas Úmidas no estado.

Muitas dessas áreas foram historicamente convertidas, principalmente em terras agrícolas (BURGER, 2000), como é o caso das planícies do rio Uruguai e do rio Jacuí (SOUZA *et al.*, 2020), por exemplo, conforme ilustra a Figura 9. Apesar de lavouras de arroz serem consideradas Áreas Úmidas artificiais, e que permitem a colonização de espécies (ROLON, 2013), o serviço ecossistêmico dessas áreas está longe de equiparar-se aos serviços promovidos pelas AUs palustres. Nas lavouras de arroz ocorre o manejo do solo, o uso de maquinários e agrotóxicos, a previsibilidade de inundação, o controle artificial da profundidade e a monocultura, fatos que impedem que as lavouras de arroz possam ser comparadas às áreas naturais (ROLON, 2013).

Figura 9 - Uso e cobertura da Terra nos rios Uruguai, Jacuí e Ibicuí - RS



Fonte: Mapbiomas, 2019. Adaptado pelo autor.

Banhado é um tipo de AU que se localiza nas planícies inundáveis dos rios e em pequenas áreas de depressões na Serra Geral. Estes ambientes são caracterizados pela presença de solos hidromórficos e vegetação aquática adaptada aos pulsos de inundação (VISSER; SASSER, 1999).

Neiff et al. (2002) definem Banhados como

Áreas Úmidas com pouca inclinação, densamente vegetadas com plantas (geófitas) que se decompõem lentamente, originando a formação de solos com um horizonte orgânico superficial. A água tem uma condição ácida permanente, cor marrom e é pobre em matéria inorgânica suspensa (NEIFF et al., 2002; NEIFF; CARIGNAN, 1997).

O Grupo Canadense de Estudos de Áreas Úmidas (1997) define os Banhados como sendo “uma zona úmida mineral dominada por graminóides, arbustos ou plantas emergentes com menos de 75% de água aberta. A área pode ser inundada ou apresentar águas superficiais periódicas ou persistentes”.

Neiff et al. (2002) e o Grupo Canadense de Estudos de Áreas Úmidas (1997) abordam os Banhados do ponto de vista da presença de vegetação e das características hidrológicas. Irgang; Pedralli; Waechter (1984) e posteriormente

Irgang; Gastal Jr (1996) abordaram a definição de Banhados do ponto de vista da comunidade vegetal nestes ecossistemas. Conforme os autores, os Banhados são “um conjunto complexo de comunidades vegetais aquáticas, com baixo número de espécies, e grande número de indivíduos, formando comunidades puras de grande distribuição geográfica” (IRGANG; GASTAL Jr, 1996).

A definição de Banhados partindo apenas da presença de comunidade de plantas, pode mascarar ou superestimar áreas de Banhados. Isso porque a ocorrência de Banhados é definida também pela presença de substrato com solos hidromórficos e a presença de turfa. Essa preocupação sobre a definição de Banhados de Irgang; Gastal Jr (1996) é também abordada em Mello (1998). Apesar da autora basear-se no conceito de Banhado proposto pelos autores, ela vai além, trazendo critérios até então não abordados. Conforme Mello (1998), os Banhados

são ecossistemas complexos, de grande diversidade genética e ambiental, que ocorrem em todos os continentes, sendo classificados segundo critérios geológicos, morfológicos, hidrológicos ou botânicos. A sua difícil delimitação, devido à grande elasticidade do ecossistema, gera problemas para o seu manejo. Entretanto, são ambientes muito sensíveis, sujeitos ao desaparecimento, quando submetidos a alterações nas condições hidrológicas (MELLO, 1998)

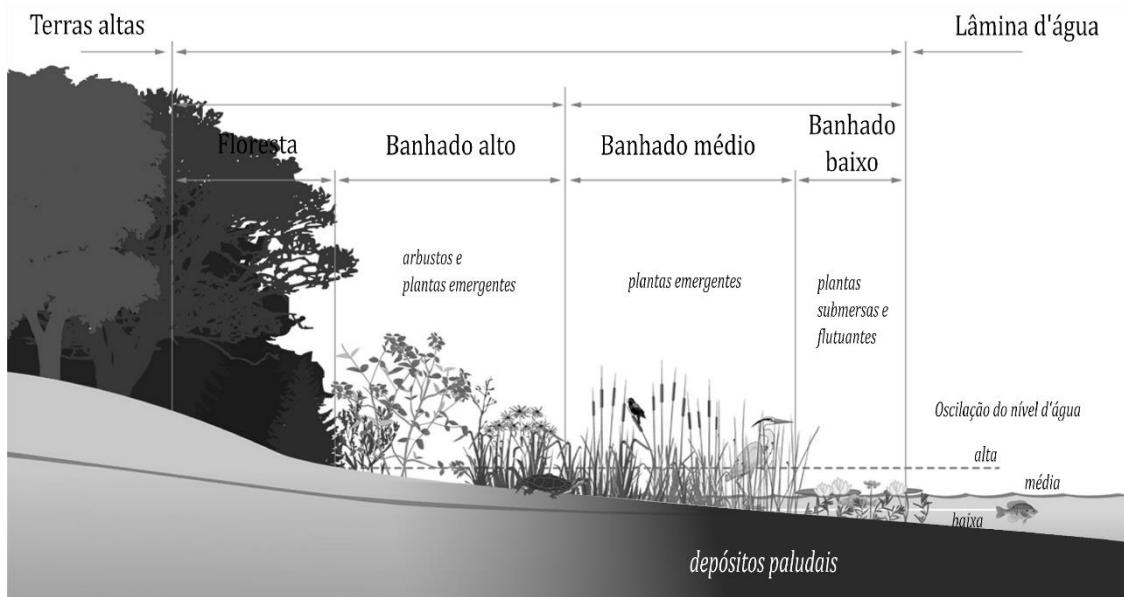
Nessa definição, os Banhados são divididos em três compartimentos, conforme a vegetação e a oscilação do nível da água, Figura 11. O primeiro é o banhado baixo, formado predominantemente por vegetação macrofítica submersa e flutuante. Mesmo em períodos de seca, esta área tende a permanecer inundada, pois, os Banhados têm como característica funcionar como esponjas, absorvendo a água nos períodos de inundação e liberando aos poucos nos períodos de seca. Prevalecem as seguintes espécies: *Eichhornia crassipes*, *Eichhornea azurea*, *Salvinia auriculata*, *Hydrochleis nymphoides*, *Leersia sp.*, *Cabomba australis*, *Leersia sp.*, *Pontederia lanceolata*, *Nymphoides sp.*, *Hygrophila sp.*, *Polygonum spp.* e *Myriophyllum brasiliensis*.

O segundo compartimento é o chamado Banhado médio ou intermediário. Este ambiente é caracterizado pela oscilação entre períodos de seca e inundação. Há a predominância de uma vegetação composta por plantas emergentes como: *Scirpus sp.*, *Cyperus sp.*, *Zizaniopsis sp.* e *Eryngium pandanifolium*.

O terceiro compartimento é denominado Banhado alto. Este ambiente é marcado pela presença de solo encharcado, a completamente inundado em períodos de pulsos

de inundação. As principais comunidades de vegetação encontradas neste compartimento são: *Erianthus sp.*, *Andropogon bicornis*, *Sida sp.*, *Mimosa bimucronata*, *Panicum prionitis* e *Poaceae*.

Figura 10 - Variação e características da vegetação e do nível da água em Banhados



Fonte: www.miseagrant.umich.edu/lessons/lessons/all-lessons/

Na legislação vigente do Estado do Rio Grande do Sul, os Banhados são definidos como ambientes com presença de

“solos naturalmente alagados ou saturados de água por período não inferior a 150 dias no ano, excluídas as situações efêmeras, as quais se caracterizam pelo alagamento ou saturação do solo por água apenas durante ou imediatamente após os períodos de precipitação” (RIO GRANDE DO SUL, 2000).

Além da presença de solos encharcados, a legislação prevê também que para o ambiente ser classificado como Banhado possua a ocorrência simultânea de no mínimo uma das seguintes espécies de flora: Junco (*Schoenoplectus spp.*, *Juncus spp.*); Aguapé (*Eichhornia spp.*); Erva-de-Santa-Luzia ou marrequinha (*Pistia stratiotes*); Marrequinha-do-Banhado (*Salvinia sp.*); Gravatá ou caraguatá-de-Banhados (*Eryngium pandanifolium*); Tiririca ou palha-cortadeira (*Cyperus giganteus*); Papiro (*Cyperus papyrus*); Pinheirinho-da-água (*Myriophyllum brasiliensis*);

Soldanela-da-água (*Nymphoides indica*); Taboa (*Typha domingensis*); Chapeu-de-couro (*Sagi Maria montevidensis*); e Rainha-das-lagoas (*Pontederia lanceolata*).

E também, que ocorra de forma regular de uma ou mais das espécies da fauna relacionadas: Jacaré-de-papo-amarelo (*Caiman latarostris*); Tachã (*Chauna torquata*); Garça-branca-grande (*Ardea alba*); Frango-d'água (*Gallinula spp.*); Caramujo ou aruá-do-Banhado (*Pomacea canaliculata*); Gavião-caramujeiro (*Rosthramus sociabilis*); Jaçanã (*Jacana jacana*); Marreca-pé-vermelho (*Amazoneta brasiliensis*); Cardeal-do-Banhado (*Amblyramphus holosericeus*); João-grande (*Ciconia maguari*); Nútria ou Ratão-do-Banhado (*Myocastor coypus*); ou Capivara (*Hydrochoerus hydrocoerus*).

Ao definir o termo Banhado, o Rio Grande Do Sul (2015) generaliza o termo, ao propor “condições para a ocorrência de Banhados”. A grande incógnita a respeito desta classificação diz respeito a “solos naturalmente alagados ou saturados de água por período não inferior a 150 dias no ano, excluídas as situações efêmeras”. Ou seja, a definição acaba por estimar a quantidade de dias em que estas áreas precisam permanecer inundadas para caracterizarem-se como Banhados, bem como, o tipo de ocorrência vegetal e animal, o que dificultaria o delineamento e classificação, por sensoriamento remoto, por exemplo.

No primeiro trimestre de 2021, Schulz et al. (2021) publicaram o livro “Guia para identificação de Banhados na bacia hidrográfica do rio dos Sinos”. Tal publicação parece sanar os problemas acerca da identificação geral destes ecossistemas, partindo de um longo estudo na bacia do rio dos Sinos. Apresenta uma definição de Banhados, e seus principais aspectos (solo, vegetação e hidrologia) e uma metodologia para levantamento da vegetação nesses ambientes.

No entanto, na definição de Banhados (pág. 10 do livro) os autores utilizam a definição geral de AUs proposta por Junk et al. (2014)¹, o que ao nosso ver incorpora um erro conceitual, em que

áreas úmidas (banhados no Rio Grande do Sul) são ecossistemas na interface entre ambientes terrestres e aquáticos, continentais ou costeiros, naturais ou artificiais, permanente ou periodicamente inundados ou com solos encharcados. As águas podem ser doces, salobras ou salgadas, com comunidades de plantas e animais adaptados à sua dinâmica hídrica (JUNK, et al., 2014 apud SCHULZ et al., 2021).

¹ O ano da citação de (JUNK, W. J. et al., 2014) está errado no livro de SCHULZ et al. (2021). Os autores citam 2013, mas o correto é 2014.

A definição proposta por Junk et al. (2014), pode ser aplicada para uma definição geral de AUs, sem diferenciar suas tipologias, ou seja, várzeas, pântanos, lavouras de arroz, campos úmidos, veredas, entre outros. Sua aplicação para definir Banhados, conforme verificada em Schulz et al. (2021), é demasiada abrangente e ignora características importantes dos Banhados, como hidrologia e a presença de turfas, por exemplo.

Se considerarmos a definição de Banhados de Schulz et al. (2021) para delimitar esses ecossistemas, equivocadamente áreas de campos úmidos, lavouras de arroz, planícies de inundação, marismas, estuários, entre outras, poderão ser incluídas como Banhados. Tal fato, põe em risco a integridade desses ecossistemas à luz dos amparos legais, uma vez que, tal definição está mais próxima de um conceito geral de AUs, podendo tornar a lei passível de questionamentos e diferentes interpretações, ignorando características peculiares desses ecossistemas.

É necessária a conceituação de Banhados, diferenciando-os de outras AUs que ocorrem no Rio Grande do Sul como, por exemplo, campos úmidos, lavouras de arroz, planícies de inundação, lagos, estuários, entre outras. De modo que estas áreas possam ser delineadas e inventariadas, com vistas ao seu reconhecimento, gestão e preservação legal.

Neste contexto, Simioni; Guasselli (2017) propuseram uma definição de Banhados que engloba as características mais importantes desses ecossistemas. Cowardin et al. (1979) descrevem que para a identificação e delineamento de Áreas Úmidas é preciso levar em consideração três critérios importantes: 1) água superficial; 2) vegetação adaptada as oscilações do nível da água (alternância entre períodos de excesso e déficit hídrico); e, 3) presença de solos hídricos ou solos com sinais de hidromorfismo.

Baseando-se nos critérios definidos por Cowardin et al. (1979), Simioni; Guasselli (2017) definiram Banhados como sendo:

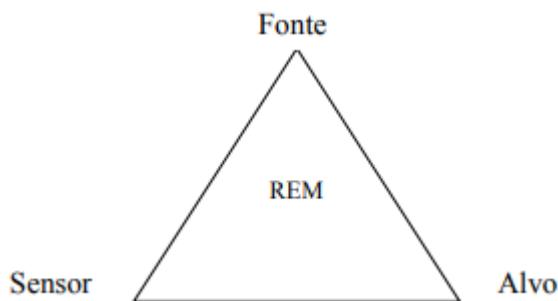
"um tipo de Área Úmida que apresenta alta complexidade e grande diversidade de gradientes ambientais. Estes ecossistemas são caracterizados pela presença de: i) depósitos palúdicos e turfas; ii) solos hidromórficos; e iii) presença de macrófitas aquáticas. São regulados pelos pulsos de inundação, permanecendo constante ou temporariamente inundados, com a presença de vegetação adaptada às flutuações do nível da água e uma biota característica" (SIMIONI; GUASSELLI, 2017).

Deste modo, ao longo da Tese, o termo Banhado será utilizado, seguindo a definição de Simioni; Guasselli (2017), visto que, esta definição utiliza a geologia, pedologia, vegetação e hidrodinâmica para identificar as áreas de Banhados.

6.1.2 Sensoriamento remoto

O SR é um conjunto de técnicas destinado à obtenção de informação sobre objetos, sem que haja contato físico com eles (NOVO; PONZONI, 2001). O SR é baseado em quatro elementos básicos, Figura 12.

Figura 11 - Principais elementos do Sensoriamento remoto



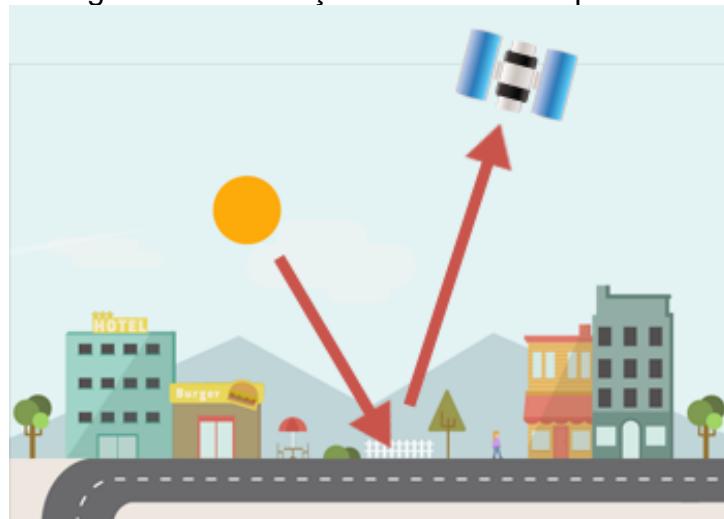
Fonte: Novo; Ponzoni (2001).

No centro do triângulo, a Radiação Eletromagnética (REM), elemento de ligação entre todos os demais elementos. Nos vértices, a fonte de REM, que para o SR óptico é o Sol, e para o SR ativo e termal o alvo é a Terra; o sensor, instrumento capaz de coletar e registrar a REM refletida ou emitida pelo objeto, que também é denominado alvo, e que representa o elemento do qual se pretende extrair informação (NOVO; PONZONI, 2001).

Os sensores remotos são dispositivos que detectam a energia eletromagnética de um alvo em determinados comprimentos de onda, transformando-a em sinal elétrico que, posteriormente é registrado e convertido em informações que descrevem as feições do objeto que compõe a superfície terrestre (DI MAIO *et al.*, 2008). Os sistemas imageadores fornecem como produto uma imagem, seja a partir do sensoriamento remoto óptico, SAR, scanner ou até mesmo com uma câmera fotográfica. Os não imageadores (conhecidos como radiômetro ou espetroradiômetro) apresentam os resultados em formas de dígitos ou tabelas (DI MAIO *et al.*, 2008).

Os sensores imageadores passivos (ópticos), detectam a radiação solar refletida a partir da Terra e podem conter bandas espectrais simultaneamente. Destacam-se os satélites Landsat TM e OLI e Sentinel 2A e 2B MSI, Figura 13.

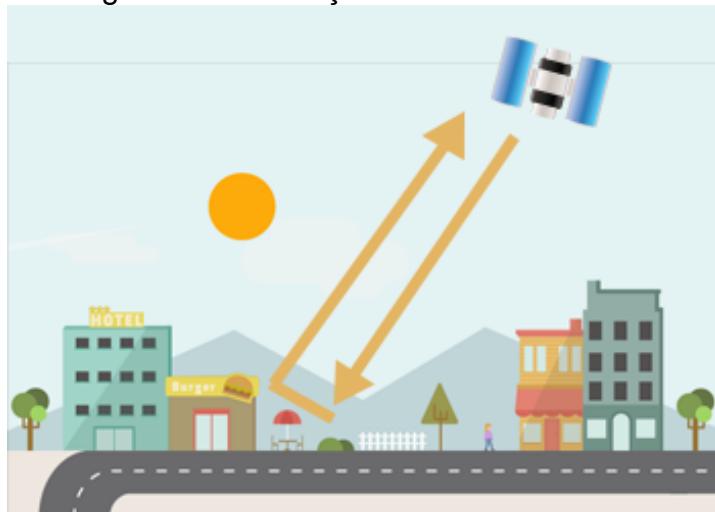
Figura 12 - Ilustração de um sensor passivo



Fonte: www.gisgeography.com

Os sensores ativos (SAR e scanners), Figura 14, utilizam sua própria fonte de energia para obter imagens, e podem operar durante o dia ou a noite. A operação de um SAR consiste na emissão e recebimento de pulsos, na faixa das micro-ondas, através de uma antena. Os pulsos são emitidos e espalhados em várias direções, sendo que, uma parcela dos pulsos volta ao sensor, o que é denominado de retroespalhamento (PONZONI; SHIMABUKURO; KUPLICH, 2015).

Figura 13 - Ilustração de um sensor ativo



Fonte: www.gisgeography.com

As imagens SAR operam na faixa de micro-ondas do espectro eletromagnético e apresentam algumas vantagens em relação aos dados ópticos. O retroespalhamento do SAR é sensível as propriedades dielétricas (umidade do solo e vegetação) e aos atributos geométricos da superfície (rugosidade). Os sistemas SAR podem obter dados durante o dia e também a noite, inclusive em áreas com grande quantidade de nuvens (FURTADO; SILVA; NOVO, 2016).

O Quadro 2 compara os sensores ativos e passivos.

Quadro 2 - Comparaçao entre sensores ativos e passivos.

Características	Sensor	
	Ativo	Passivo
Obtenção de imagem durante o dia ou a noite	X	
Obtenção de imagens em qualquer condição climática	X	
Obtenção de imagens em diferentes bandas espectrais		X
Ruídos na imagem	X	
Penetração na vegetação e solo e não apenas no topo do dossel	X	

Fonte: Elaborado pelo autor.

Alguns autores compararam dados de SR óptico e SAR para mapeamento e classificação de AUs. Augsteijn; Warrender (1998) avaliaram dados ópticos e SAR para mapear AUs. Os dados ópticos apresentaram acurácia de 82,6%, e as imagens SAR acurácia de 80,4%. Mas, a integração entre dados SAR e ópticos apresentou a maior acurácia, 87,3%, para a classificar AUs.

Evan et al. (2014) aplicaram imagens de dupla polarização Alos Palsar I banda L e RADARSAT-2 banda C para mapear habitats das sub-regiões hidrologicamente variantes do Pantanal. As autoras identificaram 10 classes de habitats com precisão superior a 80%, salientando que a combinação das diferentes bandas foi fundamental para obtenção destas acurárias.

Corcoran et al. (2012), não encontraram variação significativa a partir da integração entre imagens SAR, ópticas e MDE na classificação de AUs. A integração entre os três métodos apresentou acurácia de 75%, enquanto a integração de dados ópticos e MDE, apresentou acurácia de 72%. Este fato, pode estar relacionado às diferentes bandas SAR utilizadas, bem como a resolução espacial dos dados ópticos.

Em trabalho semelhante, Robertson et al. (2015) verificaram que a integração entre dados ópticos e MDE apresentou a mesma acurácia para classificação de Banhados que a integração de dados ópticos, MDE e SAR, bandas HH e HV, 83%. De modo geral, a hipótese de que a classificação com dados ópticos e SAR (bandas HH e HV) apresentaria uma melhor acurácia, em comparação com imagens ópticas, não se confirmou.

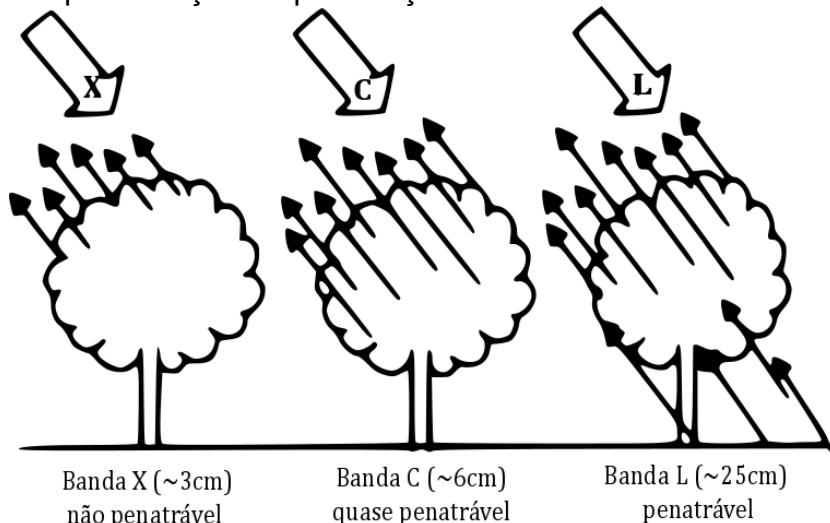
6.1.2.1 Alos Palsar I

O Palsar é um dos três instrumentos do Satélite Avançado de Observação da Terra (ALOS), desenvolvido para contribuir com os campos de mapeamento, observação regional precisa da cobertura da Terra, monitoramento de desastres e levantamento de recursos naturais. O Alos é uma missão da Agência de Exploração Aeroespacial do Japão (JAXA), lançado em 2006, operou até 2011, quando foi substituído pelo Alos Palsar II. O Palsar opera na Banda L, capaz de obter imagens diurnas ou noturnas e em quaisquer condições atmosféricas. A banda L possui maior penetração no dossel vegetal, se comparado as bandas X e C, Figura 15.

Por ter um maior comprimento de onda, a banda L tem boa capacidade de penetração no dossel vegetal, podendo interagir de maneiras distintas com a superfície retroespalhada: i) atingir pelo menos uma copa de árvore; ii) atingir diretamente o solo por meio dos espaços entre as árvores; e iii) encontrar um tronco

de árvore e gerar um forte retroespalhamento, principalmente se a superfície é relativamente lisa e úmida (VIANA, 2012).

Figura 14 - Representação da penetração das bandas SAR em dossel florestal.



Fonte: Wada; Shibasaki (2009)

O Palsar opera com polarizações HH e VV com uma largura de banda de 28 MHz. O ângulo de visão é variável em 18 passos entre 9,9° e 50,8° fora do nadir (ROSENQVIST *et al.*, 2007). Possui três modos de imageamento: i) fino; ii) ScanSAR; e iii) polarimétrico. O modo fino adquire dados em uma única polarização (HH) ou em duas polarizações (HH e HV) numa faixa de imageamento de 40 a 70 km. O modo ScanSAR adquire imagens na polarização HH e a sua faixa de imageamento pode atingir 350 km. O modo polarimétrico adquire imagens em quatro polarizações (HH, HV, VH e VV), e sua faixa de imageamento é a mais restrita de todos, varia entre 20 e 65 km, com resolução espacial de 12,5 m (SANTOS, 2010). A cobertura do Brasil inteiro no modo polarimétrico ocorre apenas uma vez por ano.

Diversos autores aplicaram dados do Alos Palsar I para mapear AUs. Evans *et al.* (2010) realizaram um mapeamento sazonal dos padrões de inundação, a partir de dados Alos Palsar I. Sartori *et al.* (2011) classificaram macrófitas aquáticas, a partir de dados Alos Palsar I, com acurácia de 87%. Clewley *et al.* (2015), aplicaram dados Alos Palsar para mapear AUs, com acurácia de 95% na discriminação das classes Área Úmida e área não-úmida, e após esta discriminação, classificaram tipos de AUs, com acurácia de 85%.

6.1.2.2 Sentinel 1

Os satélites Sentinel 1 A e B foram lançados pela Agência Espacial Europeia (ESA) em 2014 e 2016, respectivamente, constituindo a primeira série de satélites operacionais que respondem às necessidades de observação da Terra da iniciativa da União Europeia - Monitoramento Global do Ambiente e Segurança (TORRES *et al.*, 2012). Projetado para atender principalmente aplicações de média a alta resolução através de um modo principal de operação que apresenta uma ampla faixa (250 km) e alta resolução geométrica (5m × 20m) e radiométrica, e tem quatro modos operacionais:

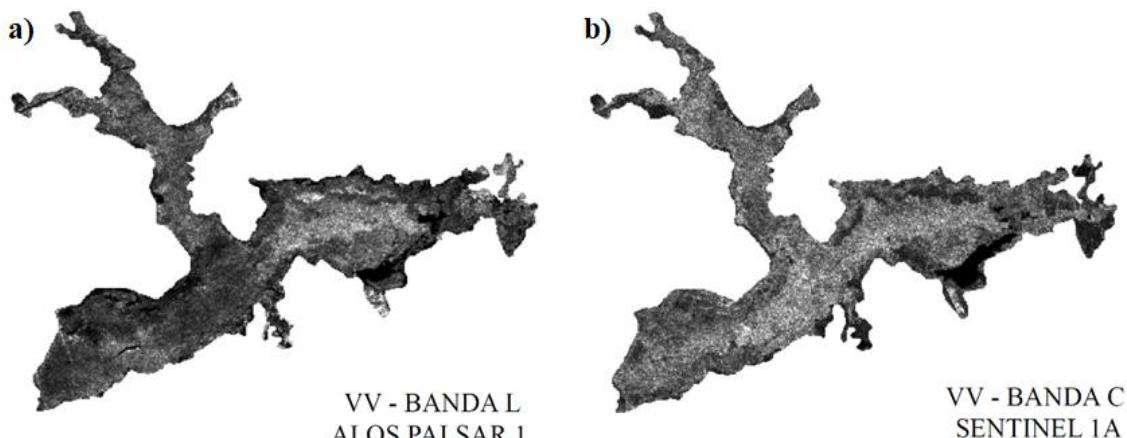
1. *Strip Map* (SM): tem resolução espacial de 5 m e faixa de imageamento de 80 km. É utilizado principalmente para monitorar pequenas ilhas, e gerenciamento de emergência para eventos extraordinários. Tem polarização simples (HH ou VV) ou dupla (HH + HV ou VV + VH) e as imagens podem ser adquiridas mediante solicitação;
2. *Interferometric Wide Swath* (IW) tem resolução espacial de 5 x 20 m e faixa de imageamento de 250 km. É o principal modo operacional sobre a Terra, com polarização simples (HH ou VV) ou dupla (HH + HV ou VV + VH);
3. *Extra Wide Swath* (EW) tem resolução espacial de 25 x 100 m e faixa de imageamento de 400 km. É utilizado para monitorar áreas costeiras e tráfego marítimo e potenciais riscos ambientais, como derramamentos de óleo ou mudanças no gelo marinho;
4. *Wave* (WV) tem resolução de 5 x 20 m e baixa taxa de dados. Este é o principal modo operacional em mar aberto, com polarização simples (HH ou VV).

Ao contrário do Alos Palsar 1 que pode ser totalmente polarimétrico (HH, HV, VV e VH), as imagens disponíveis gratuitamente do S1 A e B são de polarização dupla VV e VH. Em algumas áreas é possível a obtenção de imagens HH+HV. Outra diferença é a faixa de operação, os satélites Sentinel operam na banda C, que não chega a penetrar no dossel florestal, por exemplo.

A Figura 16 ilustra uma imagem de banhado na polarização VV, bandas L e C. A banda L (Figura 16a) apresenta tons mais escuros na área central da BG, área coberta por vegetação, onde a banda L consegue penetrar no dossel chegando até o

solo saturado por água. A banda L é mais indicada para mapear a extensão das AUs, pois, apresenta sensibilidade a umidade e a inundação do solo, e a banda C (Figura 16b) apresenta melhor capacidade de classificação da vegetação, que neste caso apresenta tons claros.

Figura 15 - Comparação entre as bandas L e C, dos satélites Alos Palsar 1 e Sentinel 1 A, em área de Banhado.



Fonte: Elaborado pelo autor.

Uma das principais vantagens dos satélites Sentinel é a resolução temporal de 6 dias. As imagens Alos Palsar I não são obtidas desde 2011. O satélite foi substituído pelo Alos Palsar II, também de banda L, porém com aquisição de imagens apenas mediante compra.

Por ser lançado recentemente (2014 e 2016), ainda existem poucos trabalhos aplicando imagens Sentinel 1 em AUs. Destacam-se os trabalhos de Muro et al. (2016), que desenvolveram um modelo automatizado para avaliar as mudanças em AUs em curtos períodos de tempo, o que é possibilitado devido a resolução temporal do Sentinel 1.

Cazals et al. (2016) mapearam e caracterizaram a dinâmica hidrológica de uma AU, a partir de imagens Sentinel 1A. Os resultados demonstram grande potencial das imagens SAR (banda C), para monitorar inundações sazonais com alta frequência temporal. Pham-Duc et al. (2017) desenvolveram uma metodologia para detectar e monitorar água superficial com dados do satélite Sentinel-1. Destacam o potencial das imagens Sentinel-1 para o monitoramento de águas superficiais, especialmente

regiões tropicais, onde há grande cobertura de nuvens durante as estações chuvosas. Graosque; Guasselli (2020) mapearam áreas de inundação com Análise de Componentes Principais e imagens Sentinel-1B, sensor C-SAR, polarização VH do tipo Interferométrico.

6.1.2.3 Sentinel 2

O S2 é uma missão de imageamento multiespectral da ESA a partir do programa Copernicus (DRUSCH *et al.*, 2012). A constelação S2 é composta por dois satélites: Sentinel A e B, que juntos tem um tempo de revisita de até 5 dias. O S2A foi lançado em 2015 e o S2B em 2017, com câmera de alta resolução multiespectral de 13 bandas, incluindo três bandas no “*red edge*”, que proporciona informação chave sobre o estado da vegetação (GOMES, 2017).

O S2A MSI tem quatro bandas de 10 m, seis bandas de 20 m e três de 60 m de resolução espacial (Tabela 1), cobrindo uma faixa de 290 km.

Tabela 1 - Bandas espectrais do satélite Sentinel 2A

Resolução (m)	Banda	Nome	Comprimento de onda central (nm)
10	B02	Azul	490
	B03	Verde	560
	B04	Vermelho	665
	B08	Infravermelho próximo	842
20	B05	Red edge 1	705
	B06	Red edge 2	740
	B07	Red edge 3	783
	B8A	Red edge 4	865
	B11	SWIR 1	1610
	B12	SWIR 2	2190
60	B01	Aerossol	443
	B09	Vapor d'água	94
	B10	Cirrus	1375

Fonte: Elaborado pelo autor.

A resolução radiométrica do instrumento MSI é de 12 *bits*, permitindo que a imagem seja adquirida num intervalo de 0 a 4.095 valores potenciais de intensidade de luz. A altitude orbital média das constelações S2 é de 786 km (GOMES, 2017).

Em relação aos estudos envolvendo a aplicação do S2A para mapeamento e classificação de AUs, destacam-se Kaplan; Avdan (2017) que avaliaram três métodos de classificação (*pixel a pixel*, baseada em objetos e baseada em índices espectrais) com imagens S2A. A classificação baseada em objetos apresentou a melhor acurácia para o mapeamento de AUs, chegando a 99%.

Amani et al. (2017) aplicaram imagens S2 para classificar diferentes tipos de AUs, a partir do *Random Forest*. Obtiveram acurácia do usuário de apenas 41% para as áreas de Banhados, e de apenas 10% para áreas de florestas inundadas, evidenciando a dificuldade no delineamento e classificação destes ecossistemas.

Rapinel et al. (2019) utilizaram série temporal de imagens S2A para mapear comunidades de plantas em áreas inundáveis. Avaliaram os classificadores Máquina de Vetor de Suporte e *Random Forest*, com acuráncias de 78% e 71%, respectivamente. Também verificaram que a acurácia é menor quando em uma única imagem (67%) ou em banda única (70%), se comparada a análise temporal.

6.1.3 Sensoriamento Remoto em Áreas Úmidas

Nas últimas cinco décadas, o sensoriamento remoto tornou-se o principal aliado dos cientistas no delineamento e classificação de Áreas Úmidas. Atualmente, existem diversos satélites ópticos que fornecem imagens de média a alta resolução espacial. Esses dados podem ser utilizados de forma eficaz para obter informações detalhadas das áreas úmidas (AMANI et al., 2017).

O sensoriamento remoto pode oferecer informações valiosas em escalas mais amplas de análise, quer seja a partir de um contexto regional, nacional ou até mesmo global, permitindo a análise integrada desses ecossistemas. Informações temporais sobre o uso e cobertura da terra no entorno de AUs são importantes, pois permitem compreender as pressões a que estes ambientes são acometidos, bem como

monitorar os avanços das fronteiras agrícolas sobre estes ambientes, com vistas na sua conservação (OZESMI; BAUER, 2002).

O SR apresenta-se assim como uma importante ferramenta capaz de complementar aos trabalhos de campo acerca do monitoramento e gestão das AUs, tornando-se uma alternativa barata, dada a disponibilidade de imagens ópticas e SAR e de softwares livres. O SR por satélite pode ser especialmente apropriado para inventários e monitoramento de AUs em países em desenvolvimento como, por exemplo, no Brasil, onde os financiamentos para pesquisas científicas são limitados e há pouca informação disponível sobre Áreas Úmidas e suas mudanças ao longo do tempo (OZESMI; BAUER, 2002).

A primeira vista o delineamento e classificação de AUs com sensoriamento remoto parece uma tarefa simples. No entanto, diversos são os desafios dos pesquisadores no mapeamento e delineamento destes ambientes. Diferentemente de áreas de florestas, águas abertas, campo, lavouras ou pastagens, que possuem padrões e formas semelhantes, as Áreas Úmidas compartilham a presença característica de água, que pode estar na superfície ou na zona de enraizamento das plantas, podendo gerar uma mistura espectral capaz de confundir o classificador (OZESMI; BAUER, 2002; GALLANT, 2015; MLECZKO; MRÓZ, 2018).

A água pode estar presente o tempo todo, sazonalmente, ou apenas em alguns anos, mas é residente o suficiente para influenciar o desenvolvimento e condição do solo e sustentar a vegetação adaptada às condições úmidas. Ademais, as Áreas Úmidas podem suportar espécies herbáceas submersas, flutuantes e emergentes, bem como arbustos hidrofíticos e espécies de árvores, sendo que, as comunidades de Áreas Úmidas podem ser dominadas por uma única ou poucas espécies ou ser uma mistura heterogênea de várias espécies e formas de vida (MOFFETT; GORELICK, 2013; GALLANT, 2015).

Amani et al. (2017) destacam que muitas características e propriedades das Áreas Úmidas podem ser estudadas a partir da medição da resposta espectral desses ecossistemas em diferentes regiões do espectro eletromagnético, como o visível e o infravermelho (próximo, ondas curtas e térmico) (DRONOVA, 2015; AMANI et al., 2017; GUO et al., 2017).

Dados provenientes de sensores hiperespectrais podem oferecer dados valiosos sobre as Áreas Úmidas, dada a quantidade de bandas espectrais. No entanto, esses sensores são, em geral, caros e de difícil processamento (GUO *et al.*, 2017). Em contrapartida, os sensores multiespectrais são atualmente os mais utilizados para o mapeamento de Áreas Úmidas (AMANI *et al.*, 2017).

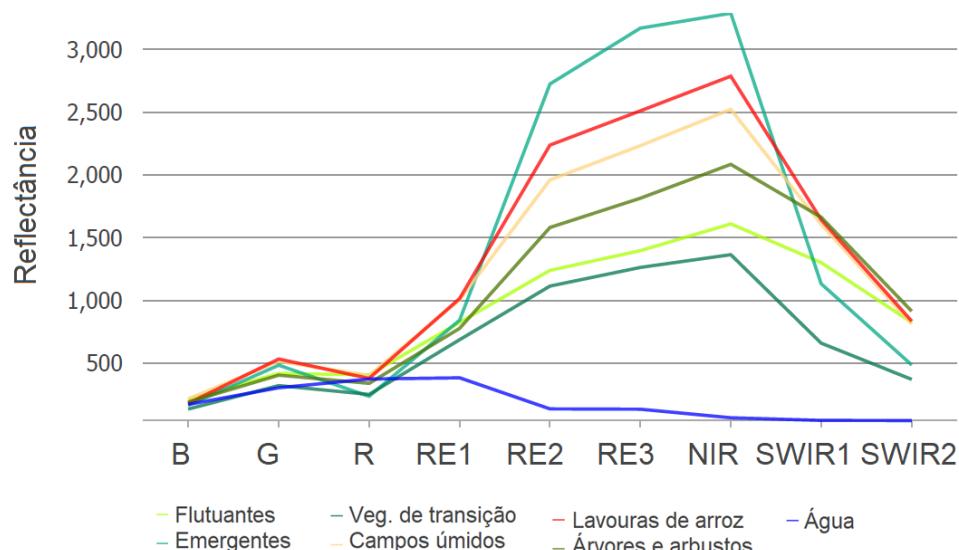
Atualmente existem diferentes tipos de satélites multiespectrais com diferentes resoluções espaciais, temporais e radiométricas disponíveis. O *Moderate Resolution Imaging Spectroradiometer* (MODIS) captura dados em 36 bandas espectrais variando em comprimento de onda de 0,4 μm a 14,4 μm e resoluções espaciais variáveis (2 bandas com 250 m, 5 bandas com 500 e 29 bandas com 1 km). Juntos, os instrumentos representam a imagem de toda a Terra a cada 1 a 2 dias, sendo recomendados para mapeamentos de Áreas Úmidas em escala regional.

Os satélites do Programa Landsat são os mais utilizados no monitoramento e mapeamento de Áreas Úmidas (AMANI *et al.*, 2017). Os satélites Landsat 7 *Enhanced Thematic Mapper Plus* (ETM+) e Landsat 8 OLI ainda estão ativos coletando dados. Está previsto para o mês de setembro de 2021 o lançamento do Landsat 9, como continuidade do Landsat 8 OLI. A resolução espacial dos satélites Landsat é 30 m e a resolução temporal de 16 dias.

No ano de 2015 foi lançado o S2, um satélite do Programa Copernicus da Agência Espacial Europeia. A missão é uma constelação com dois satélites gêmeos, S2A e S2B que adquire imagens ópticas com resolução espacial entre 10 m e 60 m.

A Figura 17 mostra a assinatura espectral de diferentes classes de vegetação e água em Área Úmida, obtidas com imagem S2A. Destaca-se a semelhança espectral das bandas do visível (azul, verde e vermelho) e *Red Edge 1* (borda do vermelho) e a capacidade do infravermelho próximo (NIR) de separar as classes de vegetação e água. A banda do vermelho apresenta menores refletâncias para a vegetação, devido aos pigmentos fotossintetizantes que absorvem energia nessa região espectral. No entanto, a região do infravermelho próximo apresenta altos valores de reflectância devido ao espalhamento múltiplo da radiação nas diferentes camadas das folhas (JENSEN, 2007).

Figura 16 - Comportamento espectral de classes de vegetação, a partir de imagem Sentinel 2A, em área de Banhado.

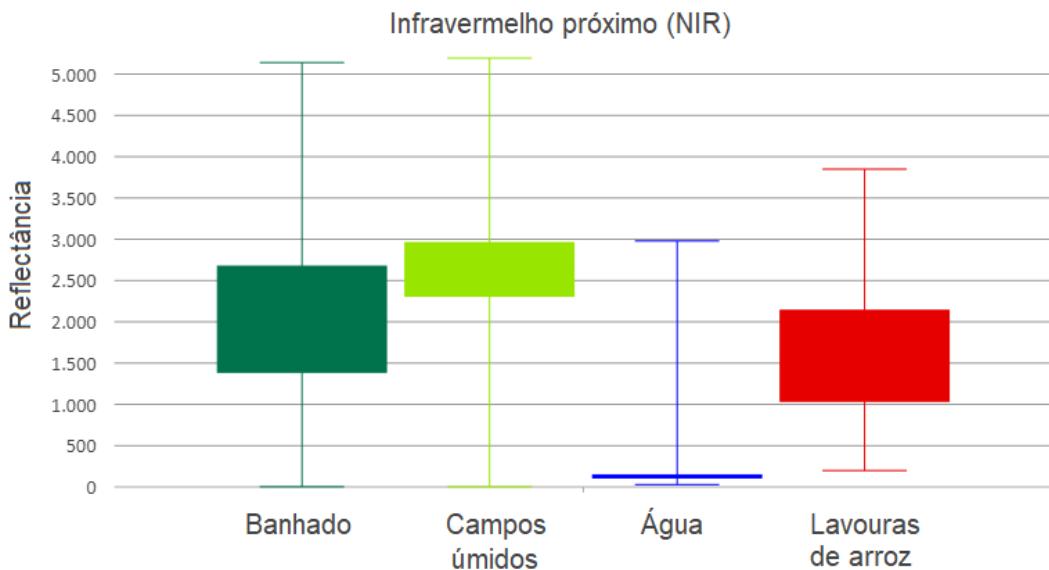


Fonte: Elaborado pelo autor.

A análise do conjunto das classes de vegetação (plantas emergentes, flutuantes e vegetação de transição), apenas na banda do infravermelho próximo, mostra que as áreas de Banhados apresentam sobreposições na reflectância com áreas de campos e lavouras de arroz (OZESMI; BAUER, 2002; AMANI et al., 2017). A Figura 18 mostra que a quantidade de água na planta faz com que os valores de reflectância das lavouras de arroz sejam menores, se comparados aos campos úmidos, por exemplo. As áreas de Banhados apresentam as maiores variações na reflectância, pois possuem plantas com diferentes conteúdos de água na folha.

A vegetação de transição e as plantas flutuantes possuem maior conteúdo de água na superfície refletida, enquanto as plantas emergentes, apesar de terem as raízes submersas, podem ter até 2 m de altura, como a espécie *Scirpus giganteus*, com maior quantidade de energia refletida das folhas verdes ou secas do dossel.

Figura 17 - Comportamento espectral de tipos de áreas úmidas, banda do infravermelho próximo, imagem Sentinel 2A



Fonte: Elaborado pelo autor.

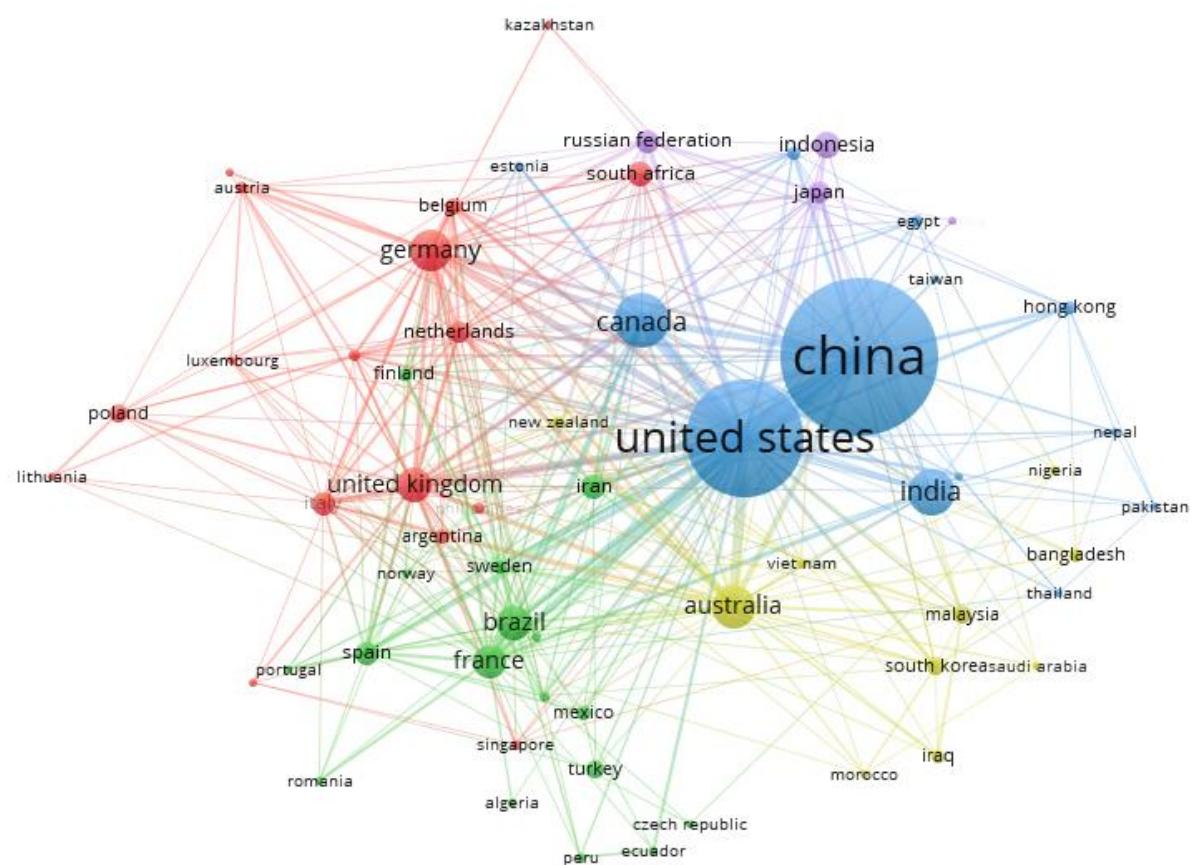
Os sensores SAR vêm ganhando destaque nos estudos de Áreas Úmidas (WHITE *et al.*, 2015). Estes sensores são chamados de sensores ativos, possuem sua própria fonte de radiação eletromagnética, e trabalham em faixas restritas do espectro (FRANKLIN *et al.*, 2018; RAPINEL *et al.*, 2020). O retroespalhamento dos sistemas SAR pode penetrar no dossel da vegetação, em vários graus, para obter imagens das condições do sub-bosque ou até mesmo do solo, dependendo do comprimento de onda estudado (WHITE *et al.*, 2015).

Quanto maior o comprimento de onda, maior será a penetração através do dossel da vegetação. Os sinais de radar da banda P (comprimentos de onda de 30 a 100 cm) penetram em quase todos os dosséis e até mesmo no solo. Os sinais da banda L (15–30 cm) penetram em grande parte dos dosséis; e os sinais da banda C (3,75–7,5 cm) e da banda X (2,4–3,75 cm) só penetram em copas abertas ou copas mais densas durante condições de folhagem (WHITE *et al.*, 2015).

Guo et al. (2017) em vasta pesquisa bibliográfica, no período entre 1964 e 2015, encontraram na *Web of Science* 5.719 artigos científicos envolvendo sensoriamento remoto e Áreas Úmidas. A vegetação foi o tema mais abordado dentre os artigos, seguido das mudanças no uso e cobertura do solo e a classificação de AUs. Nesses artigos a média resolução espacial foi a mais utilizada (GUO *et al.*, 2017).

A análise bibliométrica fornece um panorama acerca da pesquisa envolvendo Áreas Úmidas e sensoriamento remoto. A Figura 19 mostra os países que mais publicam sobre sensoriamento remoto e Áreas Úmidas entre 1971 e 2021. A China é o país com maior número de publicações na base de dados Scopus, com 1.706 artigos científicos, seguido dos Estados Unidos com 1.320 artigos e Canadá com 322 publicações. O Brasil aparece em décimo lugar no número de publicações envolvendo sensoriamento remoto e Áreas Úmidas, com 133 publicações.

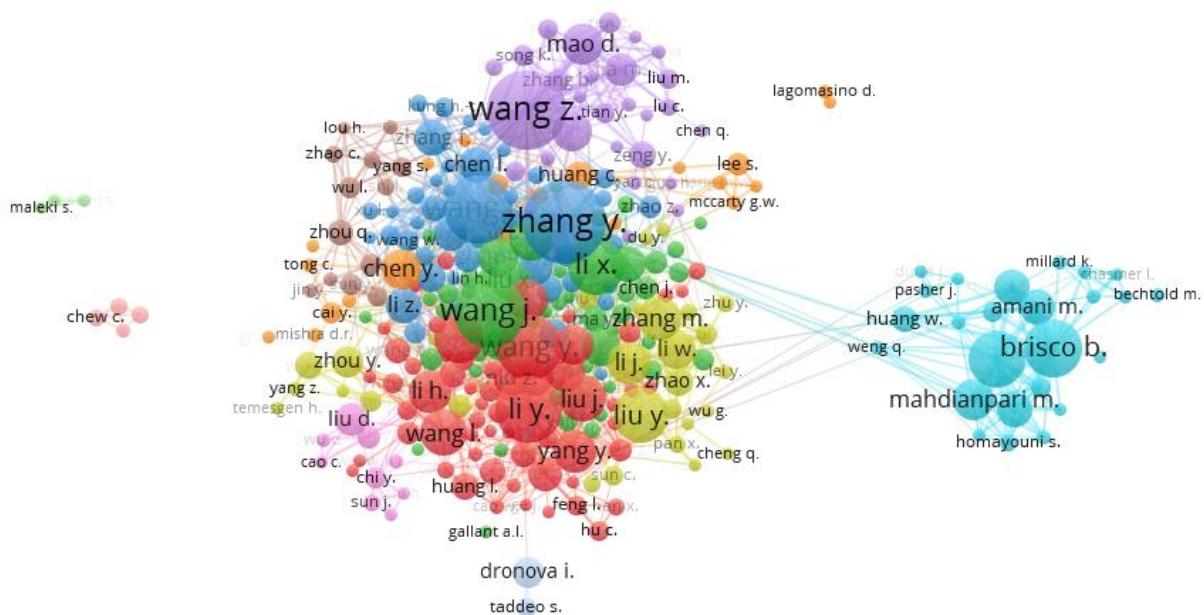
Figura 18 - Análise bibliométrica, países que mais publicaram sobre sensoriamento remoto e Áreas Úmidas, entre 1971 e 2021.



Fonte: Scopus (2021). Elaborado pelo autor.

A análise dos principais autores dos artigos científicos mostra a evidente participação chinesa nas publicações. Em destaque no número de publicações aparecem os pesquisadores chineses Dr. Zongming Wang da Academia Chinesa de Ciências, Dr. Jiang Wang da Universidade de Taizhou e Dr. Yu Zhang, que apesar de chinês, trabalha na Universidade Duke, nos Estados Unidos (Figura 20).

Figura 19 - Análise bibliométrica, principais autores de artigos científicos envolvendo sensoriamento remoto e Áreas Úmidas, entre 1971 e 2021.

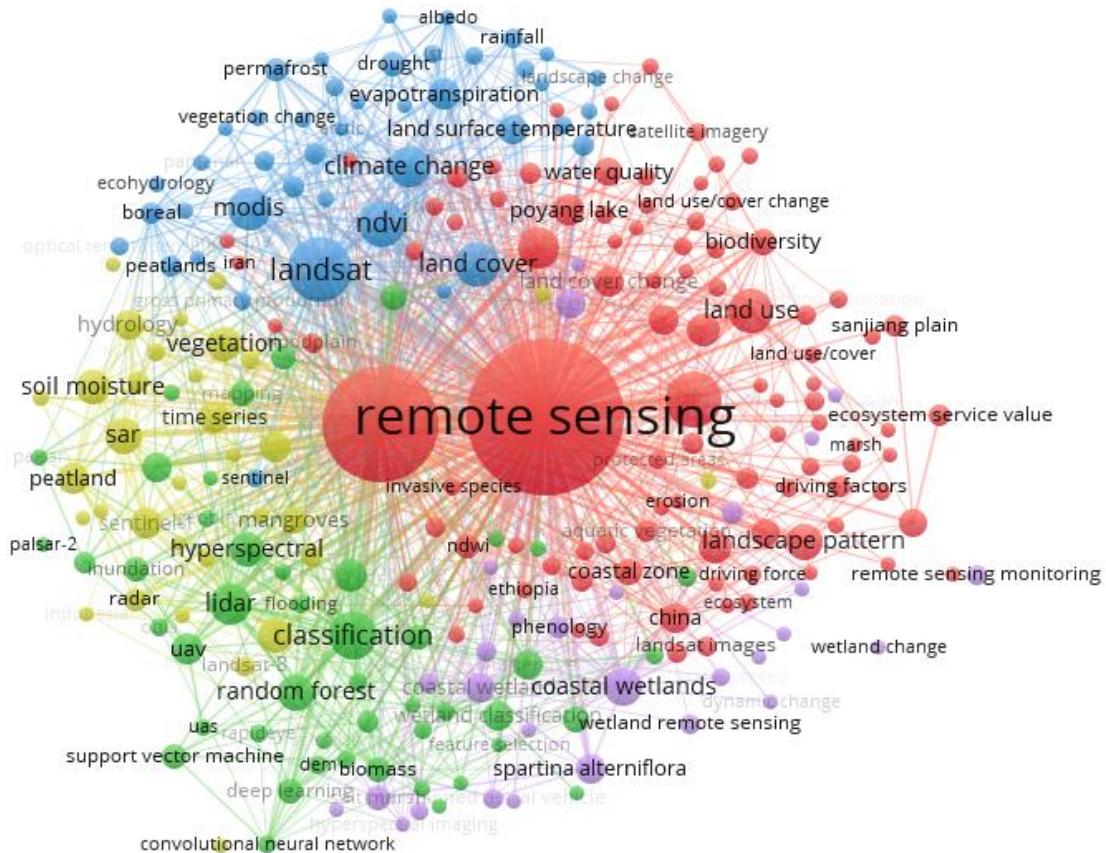


Fonte: Scopus (2021). Elaborado pelo autor.

No *cluster* com o grupo do Dr. Braian Brisco, do Instituto de Recursos Naturais do Canadá, reconhecidos por importantes pesquisas sobre sensoriamento remoto e sistemas SAR. Destacam-se também os grupos da Dra. Iryna Dronova, da Universidade da Califórnia, com importantes manuscritos na área de Geobia e da Dra. Alisa L. Gallant do Serviço Geológico dos Estados Unidos.

Ao mapear os termos mais utilizados nas palavras-chave, destacam-se os termos “sensoriamento remoto” (*remote sensing*) e “Áreas Úmidas” (*wetlands*) (Figura 21). As ligações em cores azuis permitem identificar que as imagens “MODIS” e “Landsat” aparecem em trabalhos juntamente com as palavras “NDVI”, “cobertura da terra” (*land cover*), “evapotranspiração” (*evapotranspiration*), “mudanças climáticas” (*climate change*), entre outros. As ligações em amarelo mostram que as imagens “SAR” são utilizadas juntamente com “umidade do solo” (*soil moisture*), “hidrologia” (*hydrology*), “vegetação” (*vegetation*), “turfeiras” (*peatland*) e “mangues” (*mangroves*), demonstrando o potencial das imagens SAR para Áreas Úmidas.

Figura 20 - Análise bibliométrica, principais palavras-chave nos artigos envolvendo sensoriamento remoto e Áreas Úmidas, entre 1971 e 2021.

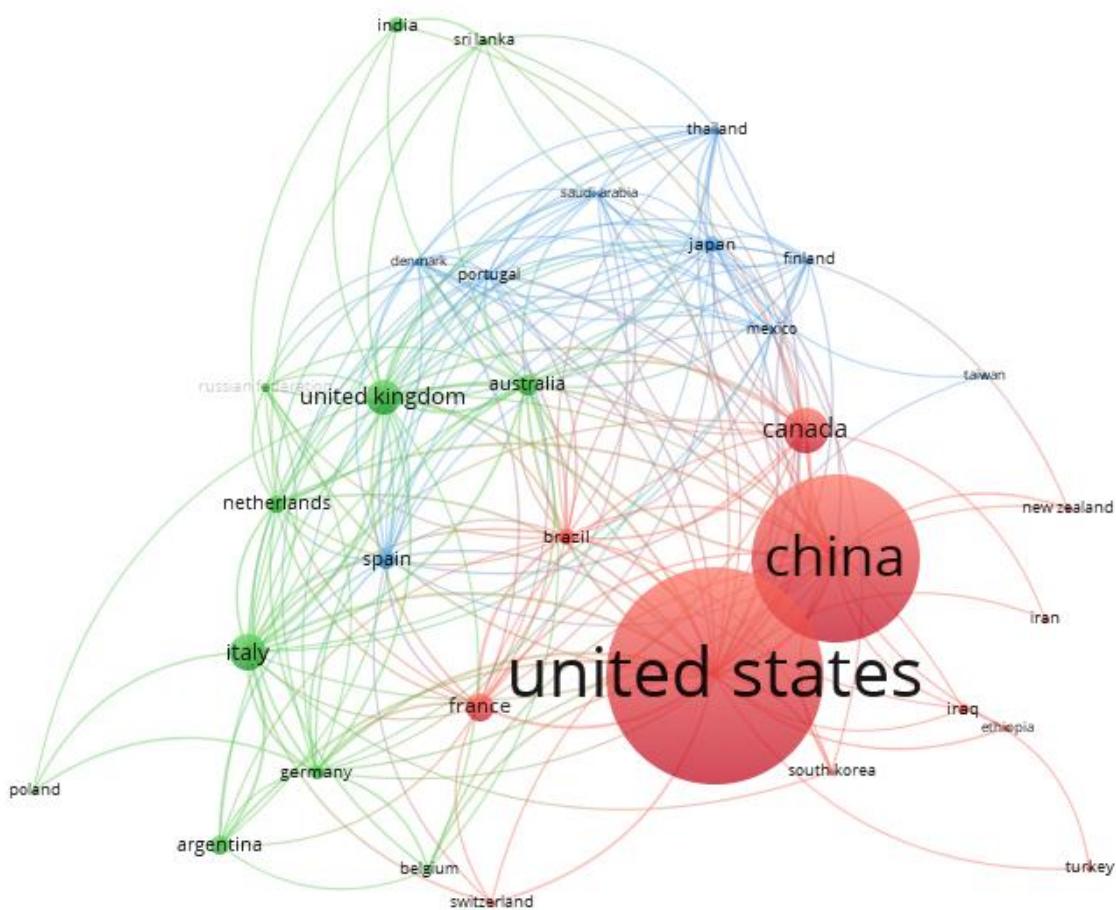


Fonte: Scopus (2021). Elaborado pelo autor.

Os temos em verde mostram que a palavra-chave “classificação” (*classification*) aparece junto com termos como “*random forest*”, “*support vector machine*”, e “*redes neurais artificiais*” (*neural artificial networks*), além da utilização de imagens “LiDAR” e “hiperespectrais”. As “Áreas Úmidas costeiras” (*coastal wetlands*) possuem palavras-chave voltadas, principalmente, à “vegetação” (*vegetation*), como o nome científico de espécies, “fenologia” (*phenology*), “biomassa” (*biomass*).

Ao direcionamos a pesquisa para o sensoriamento remoto de áreas de Banhados (*marshes*), substituindo o termo Áreas Úmidas, os Estados Unidos passam a ser o país com maior número de publicações, com 349 artigos publicados, seguido da China, com 266 publicações e Canadá com 67 manuscritos sobre Banhados e sensoriamento remoto. O Brasil aparece em décimo primeiro lugar, com 23 artigos na base de dados da *Scopus*. Destacamos que os três artigos que compõem esta tese estão na base da *Scopus* (Figura 22).

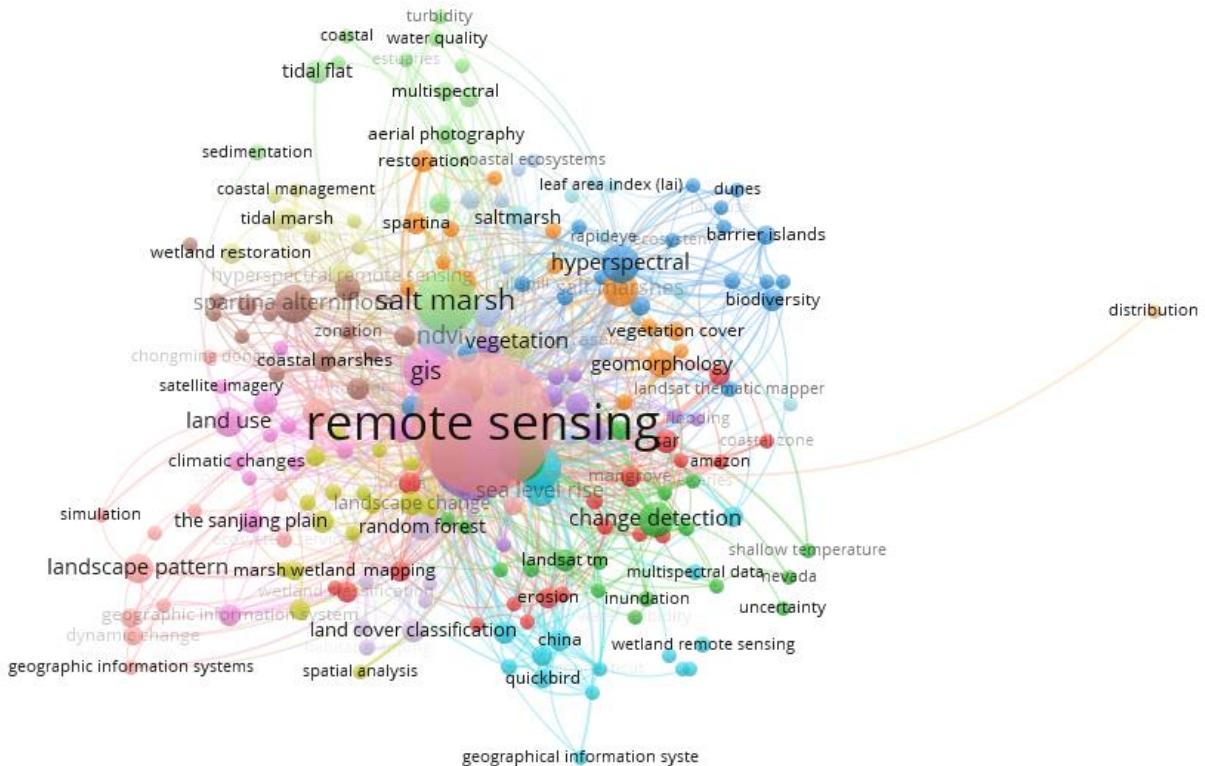
Figura 21 - Análise bibliométrica, países que mais publicaram sobre sensoriamento remoto e Banhados, entre 1971 e 2021.



Fonte: Scopus (2021). Elaborado pelo autor.

As palavras-chave que mais aparecem são “sensoriamento remoto”, “marismas” (*tidal marshes*) e “GIS” (*Geographic Information System*). Destacam-se também os termos “geomorfologia” (*geomorphology*), “vegetação” (*vegetation*), “NDVI”, “mudanças climáticas” (*climate change*) e “*Spartina alterniflora*”, vegetação típica de marismas. O termo “delineamento” não apareceu como palavra-chave em nenhum artigo buscado sobre o tema sensoriamento remoto e Banhados, realçando a lacuna científica acerca do delineamento destes ecossistemas. O termo “mapeamento” apareceu sete vezes, “monitoramento” duas vezes e “classificação” apareceu em dez palavras-chave (Figura 23).

Figura 22 - Análise bibliométrica, principais palavras-chave nos artigos envolvendo sensoriamento remoto e Banhados, entre 1971 e 2021.



Fonte: Scopus (2021). Elaborado pelo autor.

Também na base de dados Scopus, Kandus et al. (2018) analisaram as tipologias das publicações sobre Áreas Úmidas da América do Sul, encontrando 153 artigos em 63 periódicos diferentes, relacionados ao sensoriamento remoto de AUs, entre 1960 e 2015. Verificaram que o Brasil lidera o ranking com maior número de publicações sobre o tema, 88 manuscritos, seguido da Argentina com 35 estudos. Destacam-se a planície Amazônica com 58 estudos, a planície do rio Paraná com 17, o Pantanal com 14 e áreas de Banhados e lagoas costeiras com 17 estudos (KANDUS et al., 2018).

Em relação aos estudos sobre Banhados, identificamos dois objetivos principais, o mapeamento e o monitoramento. Dentre os trabalhos envolvendo sensoriamento remoto e áreas de Banhados, destacam-se Grings et al. (2009) que avaliaram a capacidade dos sistemas SAR para estimar o armazenamento de água em Banhados no baixo delta do rio Paraná, Argentina. Os autores estimaram o nível de água em Banhados com a presença de *Junco* (*Schoenoplectus californicus*) e de *Scirpus giganteus* com um erro Erro Médio Global de 22 cm.

E, González Trilla et al. (2013) que relacionaram parâmetros biofísicos de Banhados costeiros com dados de refletância hiperespectral e obtiveram um R^2 de 0,80 com o Índice de Vegetação por Diferença Normalizada (NDVI) e 0,67 com o Índice de Área Foliar (IAF), na identificação do capim-marinho (*Spartina alterniflora*).

Destacam-se também alguns trabalhos sobre sensoriamento remoto em Banhados após 2015, como Grimson et al. (2019) que aplicaram imagens SAR banda X para discriminar os tipos de macrófitas aquáticas em planície de inundação com acurácia global de 75,4%. Morandeira et al. (2016) que avaliaram os ângulos de incidência do SAR polarimétrico de banda C para discriminar diferentes tipos funcionais de planta aquáticas, com acuráncias máximas de 61,5%.

Nos Banhados do Rio Grande do Sul, Bittencourt; Guasselli (2017) aplicaram sensoriamento remoto para avaliar a dinâmica de inundação do Banhado São Donato; Simioni; Guasselli; Etchelar (2017) mapearam a conectividade entre as Áreas Úmidas da APABG; Leite; Guasselli (2013) e posteriormente, Ruiz et al. (2021) mapearam os padrões de vegetação do Banhado Grande.

6.1.4 Aprendizado de Máquina

O aprendizado de máquina é um subconjunto da inteligência artificial, que constrói um modelo matemático com base em dados de amostra, conhecido como "dados de treinamento", a fim de fazer previsões ou decisões sem ser explicitamente programado para realizar a tarefa (ZHANG, 2020).

O AM baseia-se em ideias de diferentes disciplinas, como inteligência artificial, probabilidade e estatística, ciência da computação, teoria da informação, psicologia, teoria do controle e filosofia. O AM tem sido aplicado em diversos campos, como reconhecimento de padrões, visão computacional, engenharia espacial, finanças, entretenimento, ecologia e aplicações biomédicas e médicas (NAQA; MURPHY, 2015)

Naqa; Murphy (2015) relatam que as primeiras aplicações do AM ocorreram no final da década de 1950, quando Samuel (1959) utilizou o termo para demonstrar que os computadores podem ser programados para aprender a jogar damas. Em 1975 é desenvolvido o *perceptron* multicamadas (MLP) por Werbos (1974), seguido das árvores de decisão e regressão (BREIMAN et al., 1984) e da máquina de vetor de suporte, desenvolvida por Cortes e Vapnik (1995).

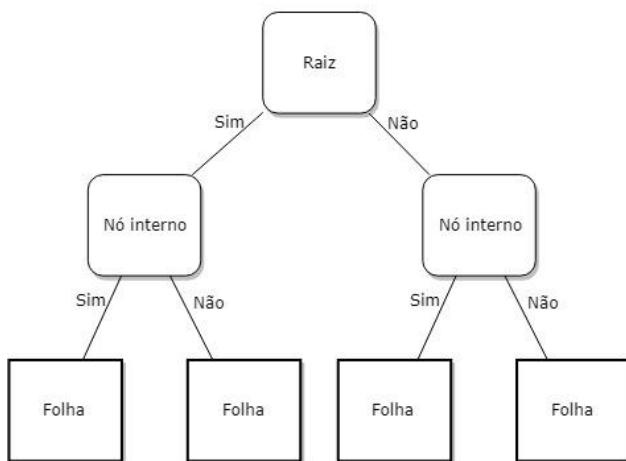
Existem três tipos de natureza dos dados no AM, que variam conforme a rotulagem dos dados, são eles: i) supervisionada, ii) não supervisionada e iii) semissupervisionada. A classificação supervisionada é usada para estimar um mapeamento desconhecido através de amostras conhecidas onde a saída é rotulada (por exemplo, classificação e regressão). Na classificação não supervisionada, apenas amostras de entrada são fornecidas ao sistema de aprendizado (por exemplo, agrupamento e estimativa da função de densidade de probabilidade). Por fim, a classificação semissupervisionada parte de uma combinação de ambas classificações (supervisionados e não supervisionados), onde parte dos dados é parcialmente rotulada e a parte rotulada é usada para inferir a porção não rotulada (por exemplo, sistemas de recuperação de texto/imagem) (NAQA; MURPHY, 2015).

Existem muitos métodos diferentes de aprendizado de máquina para modelar os dados para o problema subjacente. Nesta tese, optou-se por trazer os métodos mais abordados na literatura internacional, são eles: árvore de decisão e regressão, redes neurais artificiais, *random forest* e k-vizinho mais próximo.

6.1.4.1 Árvore de Decisão e Regressão

As árvores de decisão e regressão são modelos estatísticos de classificação de dados (BREIMAN *et al.*, 1984). A AD partitiona um conjunto de dados em subconjuntos menores com base em um teste definido em cada ramificação (nó) da árvore. A árvore é composta de um nó inicial (raiz), um conjunto de nós internos (divisões) e um conjunto de nós terminais (folhas). Exceto a raiz, cada nó interno (divisão) é composto por um nó pai; e exceto as folhas, cada nó interno tem dois ou mais nós filhos (ROKACH; MAIMON, 2005). A partir da árvore, as observações são divididas sequencialmente, e cada observação é atribuída a um rótulo de classe de acordo com o nó da folha que alcança (Figura 24) (BREIMAN *et al.*, 1984; ROKACH; MAIMON, 2005).

Figura 23 - Modelo básico de uma Árvore de Decisão.



Fonte: Elaborado pelo autor

A árvore de decisão é construída automaticamente por algoritmos, a partir de um determinado conjunto de dados. Normalmente, o objetivo é encontrar a árvore de decisão ótima, minimizando o erro de generalização. No entanto, outras funções alvo podem ser definidas pelo usuário antes da criação da árvore como, por exemplo, a modificação do número de nós ou a profundidade média. Como estes fatores alteram a acurácia da árvore, devem ser testados diferentes valores de número de nós e profundidade média (BITTENCOURT; CLARKE, 2003).

Diversas pesquisas têm aplicado AD em Áreas Úmidas. Destacam-se os trabalhos de Baker et al. (2006) e Parmuchi et al. (2002) que aplicaram árvore de decisão para mapear AUs, com acurárias de 73,1% e 85%, respectivamente; Liu et al. (2008) que monitoraram as mudanças em um manguezal a partir de classificação por AD, com acurácia de 82%; e Cordeiro; Rossetti (2015) que mapearam a vegetação em Áreas Úmidas da Amazônia usando análise de imagens baseada em objetos e classificação por árvores de decisão, com acurácia de 88%.

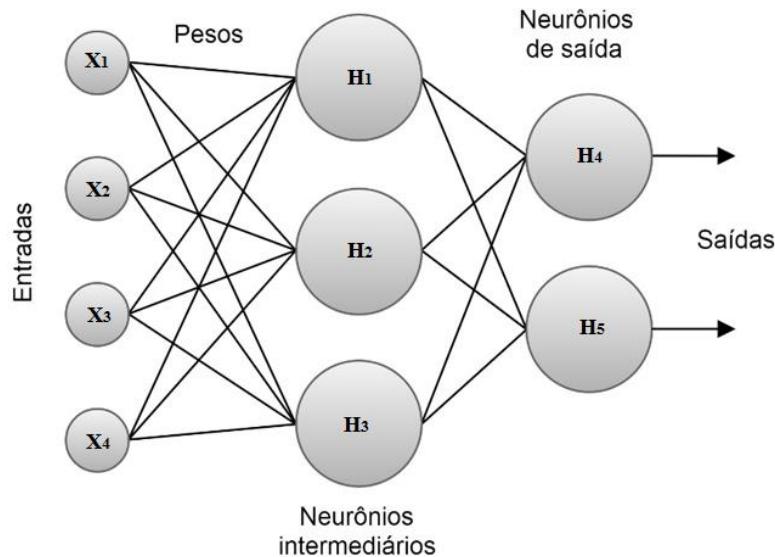
6.1.4.2 Redes Neurais Artificiais

RNAs é um método de resolver problemas, individualmente ou em combinação com outros métodos, para classificação, identificação, diagnóstico, e otimização de dados e eventos (SALAS, 2005).

As RNAs são baseadas no comportamento e função do cérebro humano, mais precisamente do sistema nervoso (SALAS, 2005). Para Matich (2001) é uma nova

forma de computação, inspirada em modelos biológicos, composto por um grande número de elementos processuais organizados em níveis. Processam informações por meio de seu estado dinâmico em resposta a entradas externas, interagindo com os objetos do mundo real. É composta por elementos de processamento simples chamados nós ou neurônios, organizados em camadas (Figura 25). Cada neurônio é conectado a outros neurônios através links de comunicação, onde cada neurônio tem um peso associado. Os pesos representam a informação usada pela rede neural para resolver um determinado problema (PALMER; MONTAÑO, 1999).

Figura 24 - Exemplo de funcionamento de um tipo de Rede Neural Artificial



Fonte: Elaborado pelo autor

Uma RNA é, geralmente, composta por vários neurônios, Equação 1:

$$h_j(x) = \sigma(w_j + \sum_{i=1}^n w_{ij}x_i) \quad (1)$$

Em que: σ é uma função de ativação não linear. Na maioria dos casos, essas unidades são estruturadas em camadas sucessivas, onde as saídas de uma camada são direcionadas através de conexões ponderadas (entradas da próxima camada). A primeira camada é a camada de entrada, que transmite os valores de entrada $x = (x_1, \dots, x_p)$ para a segunda camada. A segunda camada é formada pelas unidades de ativação h_j , tomando como entradas os valores ponderados da camada anterior e

produzindo transformações não-lineares como saídas. A última camada forma a unidade de ativação (LOUPPE, 2014).

Existem três tipos de camadas nas RNAs:

- i) Entrada: é a camada que recebe diretamente as informações vindas de fontes externas da rede;
- ii) Oculta: são internas à rede e não têm contato direto com o ambiente exterior. O número de níveis ocultos pode ser entre zero e um número alto. Os neurônios das camadas ocultas podem estar interconectados de diferentes formas, determinando, junto com seu número, as diferentes topologias das redes neurais;
- iii) Saídas: transferem informações da rede para o exterior.

A estrutura de uma rede multicamadas, Figura 25, mostra em que cada neurônio é conectado apenas a neurônios de um nível mais alto. Existem mais conexões do que neurônios; nesse sentido, diz que a rede está totalmente conectada se todas as saídas de um nível atingem todos os neurônios do próximo nível.

Augsteijn; Warrender (1998) desenvolveram um dos primeiros trabalhos aplicando RNA's para a classificar Áreas Úmidas, com base na integração de RNA's com imagens ópticas e de radar, com acurácia de 87,3%. Sayuri et al. (2009) classificaram a vegetação de Áreas Úmidas com RNA's, com acurácia global de 97,5%, evidenciando o potencial das RNA's para o mapeamento de Áreas Úmidas. Bao; Ren (2011) compararam RNA's e classificação Maxver, e verificaram que as RNA's apresentaram melhor acurácia global para classificar Áreas Úmidas (90,7%), enquanto a classificação por Maxver (86,5%).

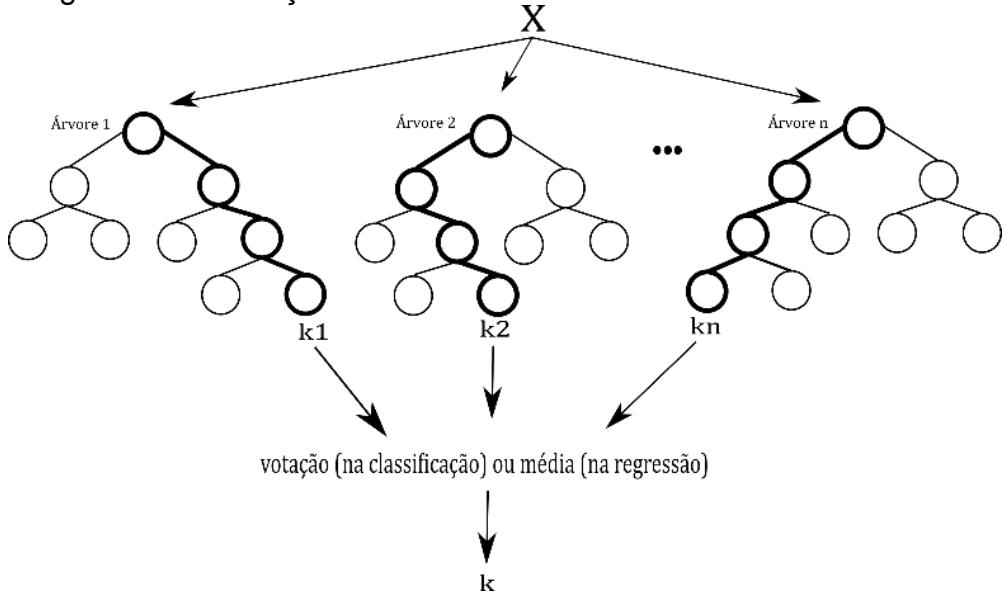
6.1.4.3 Random Forest (RF)

O *Random Forest* é uma abordagem de aprendizado de máquina desenvolvida por Breiman (2001) para aprimorar as árvores de classificação e regressão, a partir da combinação de um grande conjunto de árvores de decisão. O RF utiliza uma operação denominada *bagging (bootstrap)* para ajustar aleatoriamente diversas

árvores de decisão em várias subamostras do conjunto de dados e emprega a técnica de média para melhorar a precisão preditiva e controlar o ajuste excessivo (ROYIMANI *et al.*, 2019).

Breiman (2001) define o RF como um classificador que abrange uma coleção de classificadores estruturados em árvore $\{h(x, k), k = 1, \dots\}$ em que $\{k\}$ são vetores aleatórios distribuídos de forma idêntica e cada árvore lança um voto unitário para a classe mais popular na entrada x (Figura 26).

Figura 25 - Ilustração do funcionamento do modelo Randon Forest



Fonte: Elaborado pelo autor

No RF, várias árvores de classificação são criadas com base em um subconjunto aleatório de amostras. Por ser um método ensemble, o RF emprega algoritmos de aprendizado que constroem um conjunto de classificadores e combinam seus votos para classificar um novo exemplo (OSHIRO, 2013). Diferentemente do método *Classification And Regression Tree* (CART) utilizado na classificação por AD, o RF gera várias florestas aleatórias de árvores de classificação ou regressão, ao invés de criar apenas uma árvore (BORGES, 2016). Conforme Breiman (2001), a aleatoriedade introduzida garante que as árvores sejam minimamente correlacionadas, mantendo a força do conjunto.

Uma vantagem da classificação RF é o cálculo da importância relativa de cada variável. A importância relativa das variáveis é calculada através da substituição de valores em todo o intervalo do conjunto de dados e do cálculo da alteração relativa na

precisão da classificação entre os valores substituídos e originais. O melhor modelo é então identificado com um processo de votação ponderada para selecionar as variáveis preditoras mais significativas (MELVILLE; LUCIEER; ARYAL, 2018).

Breiman (2001) argumenta que o RF apresenta uma acurácia de previsão excepcional, sendo essa acurácia alcançada para uma ampla gama de configurações do parâmetro de sintonia única empregado.

O RF é o método de aprendizado de máquina mais encontrado na literatura, ganhando crescente atenção na classificação da cobertura do solo usando imagens de satélite, na última década. Apresenta diversas vantagens: (1) é menos afetado por *outliers* e conjuntos de dados mais ruidosos; (2) tem uma grande capacidade de trabalhar com um conjunto de dados de alta fonte e multifonte; e (3) representa uma maior precisão de classificação em comparação com outros classificadores conhecidos, como as Máquinas de Vetor de Suporte (SVM) e Máxima Verossimilhança (MAHDIANPARI *et al.*, 2017).

Tian et al. (2016) aplicaram RF, SVM e RNA's para mapear AUs, utilizando abordagem multi-sensores (Pleiades 1B e Landsat 8 Operational Land Imager - OLI). O RF obteve uma classificação satisfatória com acurácia de 92,5%, aproximadamente 10% maior do que a acurácia dos classificadores de SVM e RNA's. Mahdianpari et al. (2017) encontraram acurácia de 94,8% ao mapear Áreas Úmidas com imagens SAR nas bandas X, C e L. Fu et al. (2017) aplicaram imagens SAR (bandas C e L) para mapear vegetação de AUs, com acurácia de 89,6%, e verificaram que as classificações baseadas em objetos melhoraram a precisão geral entre 3% e 10% em todos os cenários quando comparadas às classificações baseadas em pixels.

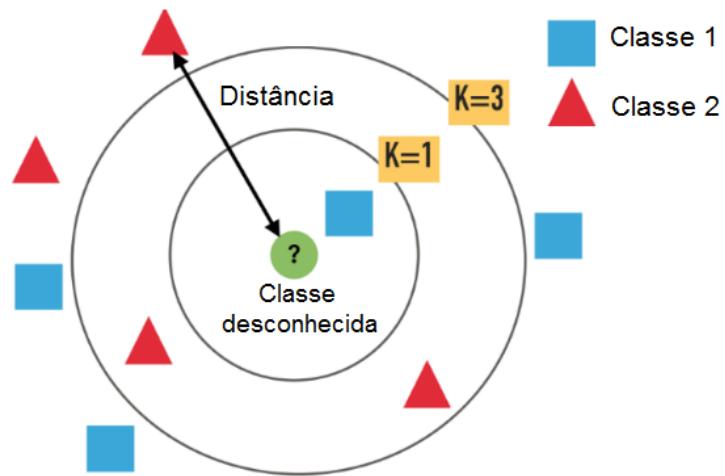
6.1.4.4 k-vizinho mais próximo

O algoritmo k-NN mais próximo é o mais simples dos algoritmos de aprendizado de máquina. O k-NN baseia-se no pressuposto da estimativa de um novo objeto com base nos exemplos do conjunto de treinamento que são próximos a ele com base em uma métrica definida (SCHIKOWSKI, 2016).

O k-NN aloca os pixels para os vizinhos que estão mais próximo no espaço, ou seja, procura k elementos do conjunto de treinamento que estejam mais próximos

deste elemento desconhecido, Figura 27. Uma função de ponderação inversa da distância pode ser incorporada ao k-NN para dar maior peso a um vizinho mais próximo da observação não classificada do que para um vizinho mais distante (TANG *et al.*, 2016).

Figura 26 - Ilustração do classificador k vizinho mais próximo.



Fonte: medium.com/aintriduction-to-k-nearest-neighbors-algorithm

Bronstein (2017) define o KNN como um algoritmo de aprendizado “preguiçoso”, ou seja, não usa os pontos de dados de treinamento para fazer qualquer generalização e não paramétrico. O k-NN usa um banco de dados onde os pontos são separados em várias classes para prever a classificação de um novo ponto de amostragem.

Para medir a distância entre os pontos A e B em um espaço, várias funções de distância têm sido usadas na literatura, sendo que, a função de distância euclidiana é a mais utilizada (HU *et al.*, 2016). Assim, sejam A e B representados pelos vetores $A = (x_1, x_2, \dots, x_m)$ e $B = (y_1, y_2, \dots, y_m)$, onde m é a dimensionalidade do espaço de feição. A distância euclidiana entre A e B , é calculada pela Equação 2:

$$d_{(x,y)} = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (2)$$

A maioria dos trabalhos envolvendo k-NN para mapear AUs é realizado em comparação com outros métodos de aprendizado de máquina. Na et al. (2015), por exemplo, compararam o k-NN e o RF para o mapear AUs florestadas a partir de dados ópticos SAR e MDE. A classificação baseada em objetos usando RF forneceu uma distribuição visualmente mais adequada para as culturas agrícolas presentes nas AUs, enquanto as classificações de objetos baseadas no algoritmo k-NN apresentaram melhores resultados para mapear AUs florestadas.

Uusi-Luomalathi (2016) comparou diferentes técnicas de reconhecimento de padrões para classificar AUs a partir de imagens SAR. Testou valores de $k = 1, 3, 6$, sendo que as melhores acurárias foram verificadas no $k=1$, com acurácia global de 98%.

6.2 Procedimentos Metodológicos

A seguir são descritos os procedimentos gerais utilizados nos artigos científicos inseridos na tese.

6.2.1 Levantamento e Pesquisa bibliográfica

A primeira etapa de consolidação desta tese foi a realização de pesquisa bibliográfica. Atualmente, existem inúmeras bases científicas de dados e, de modo a abranger o maior número de trabalhos sobre a temática realizamos pesquisas nas seguintes bases de dados: Periódicos Capes, Scopus (Elsevier), Google Scholar, Scielo (*Scientific Electronic Library Online*) e Springer database.

As palavras buscadas foram:

- i) Remote Sensing AND Wetlands AND mapping OR delineation OR monitoring OR classification;
- ii) remote sensing AND marshes AND mapping OR delineation OR monitoring OR classification;
- iii) Sensoriamento Remoto AND Áreas Úmidas;
- iv) Sensoriamento Remoto AND Banhados.

Realizamos também a análise bibliométrica, com a finalidade de identificar as palavras-chave, os países e os principais autores sobre a temática sensoriamento remoto e Áreas Úmidas. A análise bibliométrica foi realizada no software VOSviewer.

6.2.2 Aquisição das imagens de satélite

As imagens SAR foram adquiridas na plataforma da *Alaska Satellite Facility's* (<https://vertex.daac.asf.alaska.edu/>), e apresentam duas e quatro polarizações e multi-frequência, bandas L e C, Tabela 2.

Tabela 2 - Imagens SAR utilizadas no estudo

Data	Sensor	Polarização	Resolução (m)	Path/Frame	Frequência
10/04/2011	Alos Palsar 1	Quad-Pol	12,5	67/6590	L-Band
10/04/2018	Sentinel 1	VV+VH	10,0	66/ 78211	C-Band

Fonte: Copernicus; USGS. Elaborado pelo autor.

As imagens ópticas do satélite S2A foram obtidas no website do Programa Copernicus (<https://scihub.copernicus.eu/dhus/#/home>). Selecionamos duas imagens do satélite S2A, sensor MSI. Também buscamos imagens do satélite Landsat 5 TM, e WorldView para coletar os pontos de amostras, Tabela 3. As imagens Landsat 5 TM foram obtidas no site da *United States Geological Survey - USGS* (<https://earthexplorer.usgs.gov/>) e a imagem WorldView obtida por meio de doação.

Tabela 3 - Imagens ópticas utilizadas no estudo

Satélite	Data	Sensor	Resolução (m)	Granule	Órbita relativa
Sentinel 2A	09/02/2018	MSI	10,0	T22JEM	038
Sentinel 2A	19/07/2018	MSI	10,0	T22JEM	038
Landsat 5 TM	12/04/2011	TM	30,0	220	8
WorldView	05/02/2018	MS	1,84	-	-
WorldView	08/12/2018	MS	1,84	-	-

Fonte: Elaborado pelo autor.

6.2.3 Processamento das imagens

Nas imagens SAR, realizamos a calibração radiométrica (CR), com objetivo de obter imagens nas quais os valores de pixel (níveis digitais) podem ser diretamente relacionados ao retroespalhamento de radar da cena. As imagens SAR apresentam ruídos conhecidos como “sal e pimenta”, para redução dos ruídos foi aplicado o *speckle filter* com o filtro Lee sigma 5x5 (FURTADO; SILVA; NOVO, 2016). Por fim, realizamos a calibração geométrica para correção de elipsoide. Os procedimentos foram realizados no software SNAP Desktop da ESA.

Para as imagens S2A realizamos a transformação de radiância para reflectância e a correção atmosférica pelo método *dark pixel* através da ferramenta *sen2cor* do software SNAP (ESA). Como alguns índices utilizados no projeto aplicam as bandas do infravermelho longo, b11 e b12 do S2A, reamostramos os pixels de 20 metros para 10 metros, com base nas bandas b2, b3, b4 e b8, utilizando a interpolação bilinear (ZHOU; JING; JIANG, 2003).

6.2.4 Obtenção das amostras

Para obtenção das amostras de treinamento e validação da classificação, utilizamos como base na definição dos limites do BG o mapeamento das AUs do Rio Grande do Sul (RAMOS *et al.*, 2014). Coletamos amostras das 05 (cinco) classes presentes nos limites do BG, são elas:

- i) Banhados: composto por vegetação de transição, plantas flutuantes e plantas emergentes;
- ii) Campos úmidos: composto por vegetação rasteira, característica do bioma Pampa. Áreas sazonalmente inundadas pelos pulsos de inundação;
- iii) Lavouras de arroz: cultivo temporário, entre outubro e março;
- iv) Solo exposto: ocorre durante o preparo da terra, entre agosto e novembro, para o cultivo do arroz;
- v) Água aparente: área de águas abertas em corpos d’água naturais e artificiais (barragens e açudes).

Devido as dificuldades de acesso na área do Banhado Grande, a obtenção das amostras de treinamento e validação das áreas de Banhado e águas abertas foram obtidas somente a partir de interpretação visual de: (a) imagens multiespectral do satélite WorldView, obtidas em 05/02/2018 e 08/12/2018, com 1,85 m de resolução espacial; (b) imagem multiespectral do satélite Landsat 5 *Thematic Mapper*, Path/Row 220/8 com 30 m de resolução espacial, obtida em 12/04/2011 e disponibilizadas no website da *United States Geological Survey* (<https://earthexplorer.usgs.gov/>). As áreas de campos úmidos, lavouras de arroz e solo exposto foram identificadas em trabalhos de campo realizados nas áreas limítrofes ao Banhado Grande, nos dias 12/01/2018 e 12/04/2018.

Coletamos diferentes quantidades de amostras de treinamento e validação. Esse número dependeu dos objetivos e dos métodos aplicados em cada artigo científico. As precisões das classificações foram medidas pelos seguintes índices:

- i) Acurácia Global - estimativa da proporção de acerto global dos classificadores. É dada pela soma da diagonal principal da matriz de proporções (PONTIUS; MILLONES, 2011);
- ii) Acurácia do Produtor - mede o quão bem uma determinada área foi classificada. Está associado ao erro de omissão que se refere à proporção de classes observadas no terreno que não estão classificadas como tal no mapa. Quanto mais erros de omissão existirem, menor será a precisão do produtor (STORY; CONGALTON, 1986);
- iii) Acurácia do Usuário – refere-se a confiabilidade do mapa. Demonstra ao usuário o quão bem o mapa representa a realidade. Está associada ao erro de comissão, que é o erro cometido ao atribuir um pixel a uma determinada classe quando este pertence a outra classe. Quanto mais erros de comissão existirem, menor será a precisão do usuário (STORY; CONGALTON, 1986).

7 RESULTADOS

CASO PRÁCTICO

Small inner marsh area delimitation using remote sensing spectral indexes and decision tree method in southern Brazil

Simioni, J. P. D.*¹, Guasselli, L. A.¹, Ruiz, L. F. C.¹, Nascimento, V. F.¹, de Oliveira, G.²

¹*Federal University of Rio Grande do Sul, Center for Remote Sensing and Meteorology, Porto Alegre, Brazil.*

²*University of Kansas, Department of Geography and Atmospheric Science, Lawrence, KS, USA.*

Abstract: Vast small inner marsh (SIM) areas have been lost in the past few decades through the conversion to agricultural, urban and industrial lands. The remaining marshes face several threats such as drainage for agriculture, construction of roads and port facilities, waste disposal, among others. This study integrates 17 remote sensing spectral indexes and decision tree (DT) method to map SIM areas using Sentinel 2A images from Summer and Winter seasons. Our results showed that remote sensing indexes, although not developed specifically for wetland delimitation, presented satisfactory results in order to classify these ecosystems. The indexes that showed to be more useful for marshes classification by DT techniques in the study area were NDTI, BI, NDPI and BI_2, with 25.9%, 17.7%, 11.1% and 0.8%, respectively. In general, the Proportion Correct (PC) found was 95.9% and 77.9% for the Summer and Winter images respectively. We hypothesize that this significant PC variation is related to the rice-planting period in the Summer and/or to the water level oscillation period in the Winter. For future studies, we recommend the use of active remote sensors (e.g., radar) and soil maps in addition to the remote sensing spectral indexes in order to obtain better results in the delimitation of small inner marsh areas.

Key words: marshes, Sentinel 2A, remote sensing, CART method.

Delimitación de pequeñas marismas interiores mediante índices espectrales y árboles de decisión en el sur de Brasil

Resumen: En las últimas décadas se han perdido grandes áreas de pequeñas marismas interiores (SIM) a través de la conversión a tierras agrícolas, urbanas e industriales. Las marismas restantes enfrentan varias amenazas, como el drenaje para la agricultura, la construcción de carreteras e instalaciones portuarias, la eliminación de residuos, entre otras. Este estudio integra 17 índices espectrales de teledetección y un método basado en árboles de decisión (DT) para cartografiar áreas de pequeñas marismas interiores utilizando imágenes del satélite Sentinel 2A de verano e invierno. Los resultados muestran que los índices de teledetección, aunque no han sido desarrollados específicamente para la delimitación de marismas, presentan resultados satisfactorios

To cite this article: Simioni, J. P. D., Guasselli, L. A., Ruiz, L. F. C., Nascimento, V. F., de Oliveira, G. 2018. Small inner marsh area delimitation using remote sensing spectral indexes and decision tree method in southern Brazil. *Revista de Teledetección*, 52, 55-66. <https://doi.org/10.4995/raet.2018.10366>

* Corresponding author: joao.delapasse@ufrgs.br

para clasificar estos ecosistemas. Los índices que demostraron ser más útiles para la clasificación de marismas mediante técnicas de DT en el área de estudio fueron el NDTI, BI, NDPI y BI_2, con 25.9%, 17.7%, 11.1% y 0.8%, respectivamente. En general, la proporción correcta encontrada fue de 95.9% y 77.9% para las imágenes de verano e invierno, respectivamente. Nuestra hipótesis es que esta variación significativa de la proporción correcta está relacionada con el período de siembra del arroz en verano y/o con el período de oscilación del nivel del agua en invierno. Para futuras investigaciones, recomendamos el uso de sensores remotos activos (por ejemplo, radar) y mapas de suelo además de los índices espectrales de teledetección para obtener mejores resultados en la delimitación de pequeñas áreas de marismas interiores.

Palabras clave: marismas, Sentinel 2A, teledetección, método CART.

1. Introduction

Marsh is a type of wetland (WL) characterized by the presence of hydromorphic soil, graminoids, aquatic vegetation, and shrubs or emergent plants adapted to flood pulses (Junk *et al.*, 1989; Visser and Sasser, 1999; Canadian Wetland Inventory Technical Group, 2016; Simioni *et al.*, 2017). The Environmental Protection Agency of the United States of America (USA) (2001) defines marshes as “often or continuously flooded wetlands characterized by emergent soft-stem vegetation adapted to saturated soil conditions”.

Vast small inner marsh (SIM) areas have been lost in the past few decades through the conversion to agricultural, urban and industrial lands (Gedan *et al.*, 2009). The remaining marshes face several threats such as drainage for agriculture, construction of roads and port facilities, waste disposal, among others (Liu *et al.*, 2013; Fluet-Chouinard *et al.*, 2015).

Yan *et al.* (2017) suggest that the classification of marsh areas is an important way to understand the spatio-temporal changes that they are submitted. Junk (2013); Junk *et al.* (2014); and Nunes da Cunha *et al.* (2015) argue that the delimitation is fundamental to manage, protect and maintain wetlands. Teixeira (2011) and Junk and Piedade (2015) point out that there are currently several data sources to delimitate large wetland areas. However, there are several difficulties for the delimitation of SIM areas, which have specific characteristics and dynamics (Junk *et al.*, 1989; Nunes da Cunha *et al.*, 2015; Mahdavi *et al.*, 2017).

In the early 2000's, the Ramsar Convention (2002) recommended the use of remote sensing (RS) and geoprocessing for wetlands classification, mapping, delimitation, and inventory (Artigas and

Yang, 2006; Judd *et al.*, 2007; Sharpe *et al.*, 2016; Dvorett *et al.*, 2016). The radiometric, spectral and temporal resolutions of the satellites Landsat 5 and Landsat 8 and, recently, Sentinel 2A and 2B allow to conduct accurate studies for the identification of several types of wetlands (Jensen, 2007; Sharpe *et al.*, 2016; Kaplan and Avdan, 2017a).

Several authors have applied vegetation indexes (VIs) to delimitate, monitor and classify wetlands: 1) Stefano (2003) developed the water and wetland index (WWI) to identify different wetlands types; 2) Kulawardhana *et al.* (2007) used remote sensing indexes and digital elevation models to delimitate wetlands; 3) Sakané *et al.* (2011) classified, characterized and delimitated small wetlands using VIs; 4) Dong *et al.* (2014) applied NDVI (normalized difference vegetation index) and LSWI (land surface water index) for the mapping of lakes, rivers and flood plains; 5) White *et al.* (2016) adapted the NDVI to delimitate wetlands; 6) Kaplan and Avdan (2017a) used Sentinel 2A images to map wetlands using Sentinel 2A images; 7) Miranda *et al.* (2018) analyzed the vegetation variation in the Pantanal area in Brazil using VIs; and 8) Di Vittorio and Georgakakos (2018) used NDVI and MNDWI (Modified Normalized Difference Water Index) obtained from MODIS to map wetland areas.

In general, studies involving marshes focus on the characterization of salt or tidal marshes (Walsh *et al.*, 2014; Fariña *et al.*, 2017; Mcowen *et al.*, 2017; Mao *et al.*, 2018). These types of marsh have a grassy vegetation tolerant to salt water (Belluco *et al.*, 2006; Judd *et al.*, 2007) and have different water turbidity (Subramaniam and Saxena, 2011; Mondal and Bandyopadhyay, 2014) and soil types (Mao *et al.*, 2018) in comparison with inner marshes.

Based on the considerations above, this study proposes a method to delimitate SIM areas based on remote sensing spectral indexes and decision tree techniques using Sentinel 2A images.

1.1. Study Area

The study was conducted in the Banhado Grande (BG) marsh, located within the Gravataí river basin (GRB) in the eastern flank of Rio Grande do Sul State, Brazil (Figure 1).

As much of others Rio Grande do Sul marshes, the BG have historically suffered significant environmental impacts, such as drainage for agricultural crops (Belloli, 2016), soil erosion (Etchelar, 2017) and construction of roads (Silva, 2016).

The BG is a paludal environment with approximately 5951 ha (Ramos *et al.*, 2014). The main soil type found in the area is the gleisols (Nielsen, 1994). The annual precipitation average varies between 1700 and 1800 mm (Rossato, 2011). In a study developed by Simioni *et al.* (2017) it was verified that in great flood periods it is established a connection between BG with Banhado dos Pachecos and Gravataí river floodplain. This connectivity is responsible for several interactions

between WLs, such as nutrients, sediments and organisms exchange.

According to Leite and Guasselli (2013) the BG vegetation patterns shows a seasonal variability regulated by flood pulses. During the dry season (Summer and Fall) there is a predominance of *cyperaceae* species while in the wet season (Winter and Spring) macrophytes and paludal vegetation prevails.

2. Material and Methods

2.1. Satellite Image Acquisition

In this study two Sentinel 2A images were used. Satellites Sentinel 2A and 2B are part of the Copernicus Program, which is managed by the European Community and European Space Agency (ESA). These satellites collect data on vegetation, soil moisture, as well as rivers and coastal areas. The images were obtained through Copernicus website (<https://scihub.copernicus.eu/>) in the level-1C for the bands 3 (green), 4 (red), 8 (NIR), 11 (SWIR 1) and 12 (SWIR 2) (Table 1). The images were obtained considering the dry and wet seasons in the region in order to evaluate the performance

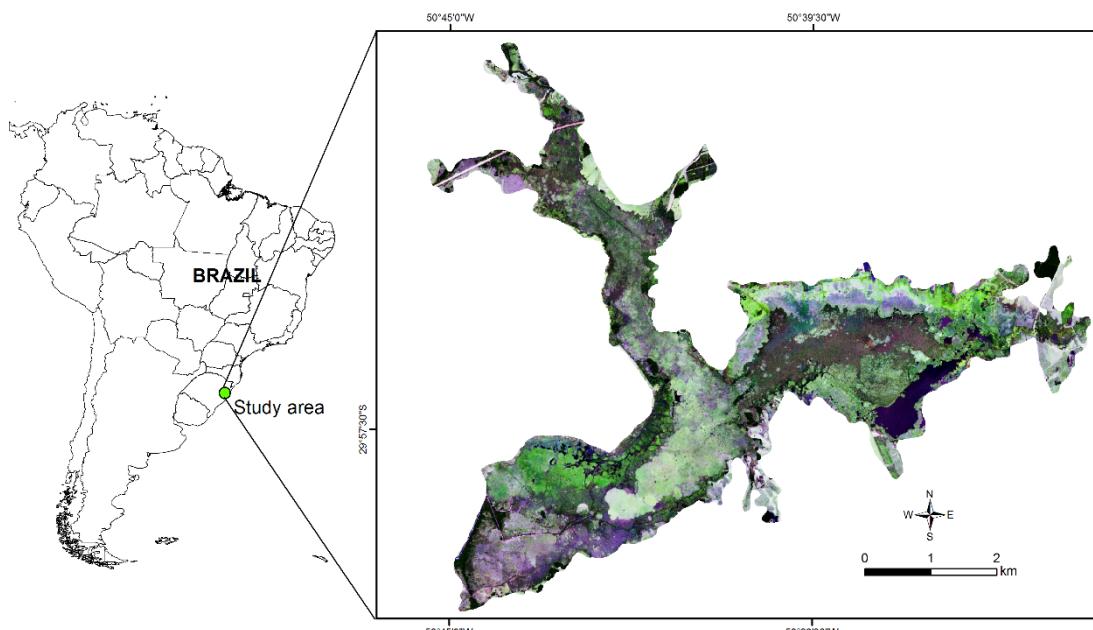


Figure 1. Map showing the location of the Banhado Grande marsh.

of the classification under two situations: 1) when the marsh surrounding areas are mainly used for rice cultivation (Summer and Fall); and 2) when there is higher amplitude of the water level oscillation (Winter and Spring).

Table 1. Sentinel 2A scenes used in the study.

Date	Sensor	Season	Level	Granule	Relative Orbit
02/09/2018	MSI	Summer	1C	T22JEM	038
07/19/2018	MSI	Winter	1C	T22JEM	038

First, the level-1C images were converted to surface reflectance using the *sen2cor* tool (Kaplan and Avdan, 2017b). The spatial resolution of the bands 3, 4, and 8 is 10 m while the spatial resolution of the bands 11 and 12 is 20 m. In this regard, we chose to resample the bands 11 (SWIR 1) and 12 (SWIR 2) to 10 m using the bilinear interpolation method according the proposition of Qianxiang *et al.* (2003).

2.2. Remote Sensing Spectral Indexes

We calculated seventeen vegetation, water and soil indexes using the Sentinel 2A images (Table 2). The indexes were applied using the ESA's Sentinel Application Platform (SNAP) tool.

2.3. Samples

Using a WorldView-2 multispectral satellite image from 02/05/2018 with 1.85 m spatial resolution we selected 2000 random points for three different classes: 1) SIM; wet meadow (WM) and rice crops (RC). In order to align the geometric resolution between the WorldView-2 and Sentinel 2A images we used the Erdas Autosync Workstation tool.

We chose to collect samples for WM and RC because of the similarity of the plants spectral response during the growing season. Although BG has aquatic plants in both permanent and periodic flooding periods, no samples were collected for the apparent optical properties of the water since there are several remote sensing indexes for this purpose in literature.

Table 2. Remote sensing spectral indexes used in the study.

Index	Equation	Author (s)
Weighted Difference Vegetation Index	$WDVI = B8 - g \times B4$	(Clevers <i>et al.</i> , 1989)
Soil Adjusted Vegetation Index	$SAVI = \frac{(1 + L) \times (B8 - B4)}{(B8 + B4 + L)}$	(Huete, 1988)
Transformed Normalized Difference Vegetation Index	$TNDVI = \sqrt{NDVI + 0.5}$	(Deering, 1975)
Brightness Index	$BI = \sqrt{\frac{(2 \times B4) + (2 \times B3)}{2}}$	(Escadafal, 1989)
Brightness Index_2	$BI_2 = \sqrt{\frac{(2 \times B4) + (2 \times B3) + (2 \times B8)}{3}}$	(Escadafal, 1989)
Ratio Vegetation Index	$RFI = B4/B8$	(Pearson & Miller, 1972)
Normalized Difference Water Index	$NDWI = (B8 - B11)/(B8 + B11)$	(Gao, 1996)
Normalized Difference Water Index 2	$NDWI_2 = (B3 - B8)/(B3 + B8)$	(McFeeters, 1996)
Normalized Difference Vegetation Index	$NDVI = (B8 - B4)/(B8 + B4)$	(Rouse <i>et al.</i> , 1973)
Normalized Difference Turbidity Index	$NDTI = (B4 - B3)/(B4 + B3)$	(Lacaux <i>et al.</i> , 2007)
Normalized Difference Pond Index	$NDPI = (B3 - B11 \times B12)/(B3 + B11 \times B12)$	(Lacaux <i>et al.</i> , 2007)
Normalized Difference Index	$NDI45 = (B5 - B4)/(B5 + B4)$	(Delegido <i>et al.</i> , 2011)
Modified Soil Adjusted Vegetation Index	$MSAVI = \frac{(1 + L) \times (B8 - B4)}{(B8 + B4 + L)}$	(Qi <i>et al.</i> , 1994)
Modified Normalized Difference Water Index	$MNDWI = (B3 - B11)/(B3 + B11)$	(Xu, 2006)
Green Normalized Difference Vegetation Index	$GNDVI = (B8 - B3)/(B8 + B3)$	(Gitelson <i>et al.</i> , 1996)
Difference Vegetation Index	$DVI = (B8 - B4)$	(Richardson & Wiegand, 1977)
Atmospherically Resistant Vegetation Index	$ARVI = (B8 - rb)/(B8 + rb)$	(Kaufman <i>et al.</i> , 1992)

Sampling points were divided into 70% of training samples and 30% of validation samples. To analyze the classification accuracy we used the proportion correct (PC) (Pontius and Millones, 2011), producer's accuracy (PA), and user's accuracy (UA) (Congalton, 1991).

2.4. Decision Tree and Marsh Delimitation

The classification and regression trees (CART) method was used to discriminate the different classes. The CART method uses non-parametric statistics without probabilistic assumptions, selecting the necessary variables automatically (Friedl and Brodley, 1997). The CART is a classification procedure that breaks a dataset into smaller subsets based on a test defined in each tree branch or node, resulting in a binary decision tree with more homogeneous and pure nodes. The decision tree (DT) is composed by an initial node (root), a set of internal nodes (divisions), and a set of terminal nodes (leaves). The purpose of constructing a DT is to reduce the nodes impurities and then obtain the input variables relevance (e.g., spectral indexes) (Ruiz *et al.*, 2014).

The DT complexity and its size can be controlled by the depth and the sample numbers in inner nodes. The DT complexity depth and child nodes number influence the proportion of correct pattern elements (Ruiz *et al.*, 2014). We tested six different DT depth values (5, 10, 15, 20, 25, and 30) and six child nodes numbers (20, 40, 60, 80, 100, and 120) in order to find the best fit for the study area. We used the Gini index to measure the impurity of the tree branches.

To delineate the marsh, the CART classification with the highest PC was converted into conditional tests and then spatialized. Subsequently, the majority filter (MF) was applied to replace cells based on the majority value of adjacent neighboring pixels for both classifications (Ruiz *et al.*, 2014).

3. Results

3.1. Maximum Tree Depth

The maximum tree depth controls the maximum number of growth levels below the root node and

the minimum case numbers rules the minimum node case numbers. The nodes that do not meet these criteria have no divisions. The minimum case values increase lean towards to produce trees with fewer nodes. The Figure 2 shows the PC into the CART method in relation to maximum tree depth and the minimum case numbers for the validation samples.

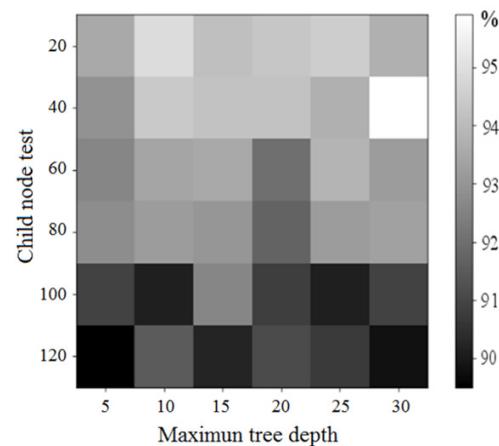


Figure 2. Decision tree (DT) proportion correct (PC) using the classification and regression trees (CART) method.

The highest PC was found at depths ranging from 20 to 30 and minimum cases between 20 and 40. The maximum depth of 30 and the minimum case numbers of 40 were the most accurate among all the parameters analyzed, achieving the PC of 95.9% for the validation samples during the Summer and 77.9% during the Winter images. It was observed a trend of reduction in the PC values when the minimum case numbers is greater than or equal to 100.

3.2. Decision Tree Classification

We used the same training samples to classify the Summer (02/09/2018) and Winter (07/19/2018) images. The DT classification was automatically divided into 18 nodes (Figure 3). The root node determined by the CART method was the NDTI (normalized difference turbidity index) (Lacaux *et al.*, 2007). The NDTI values lower than -0.31 corresponded to ~5% of the samples as SIM and they were directly related to ARVI (atmospherically resistant vegetation index) (Kaufman *et al.*, 1992). The NDTI and ARVI values showed

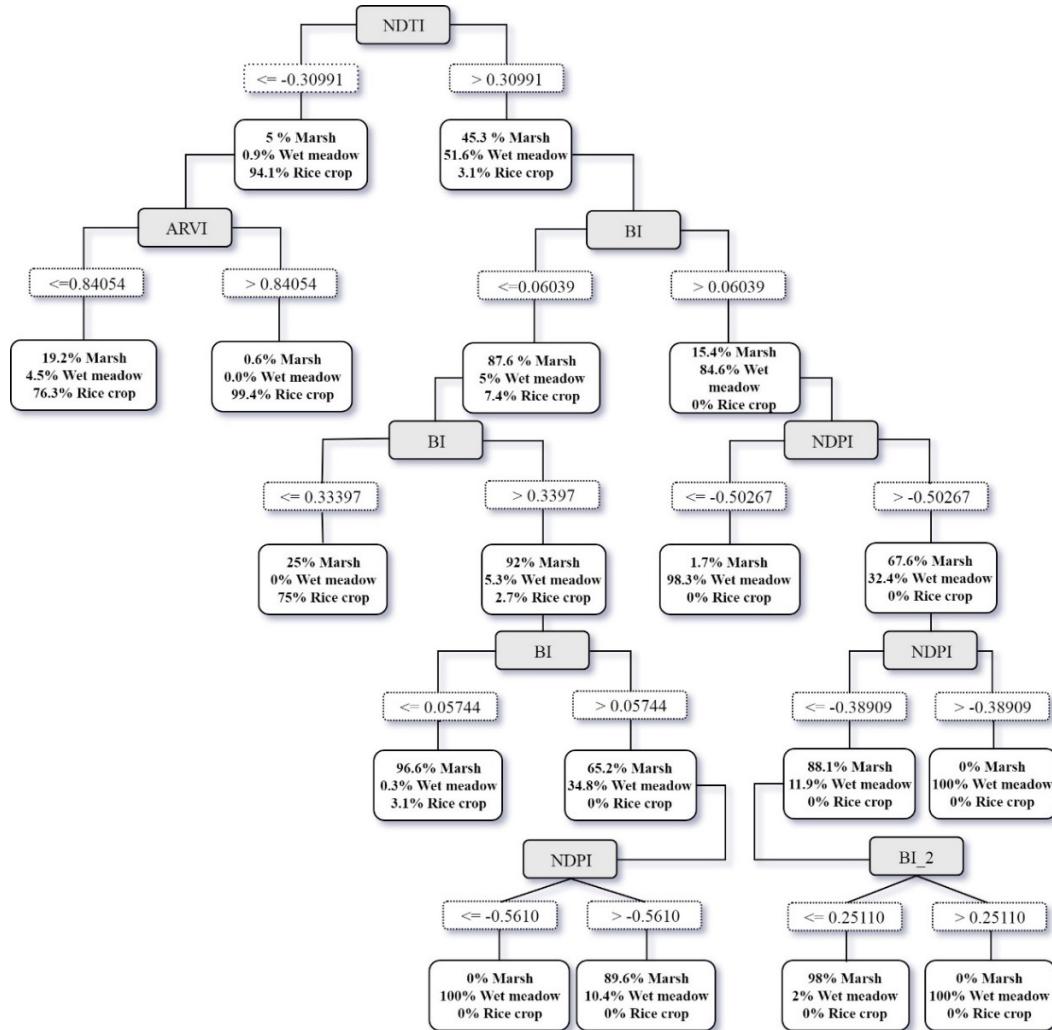


Figure 3. Classification and regression trees (CART) method decision tree (DT) for the present study.

that this index is reliable to classify rice cultivation areas since 98.5% of ARVI values higher than 0.84054 were categorized as rice crops.

The NDTI values higher than -0.31 classified 45.3% of the samples as SIMA and they were automatically associated with BI_1 (brightness index) (Escadafal, 1989). The BI showed to be adequate to classify marshes since 87.6% of the BI samples with values smaller than 0.06 were categorized as marsh areas. It is also important to note that the NDPI values higher than -0.56 classified 89.6% of the samples as marsh areas and the BI_2 values

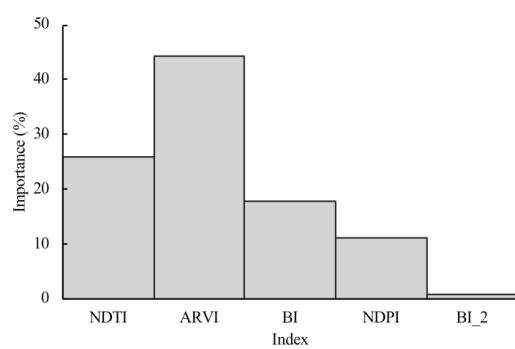


Figure 4. Indexes importance in the Decision Tree (DT) classification.

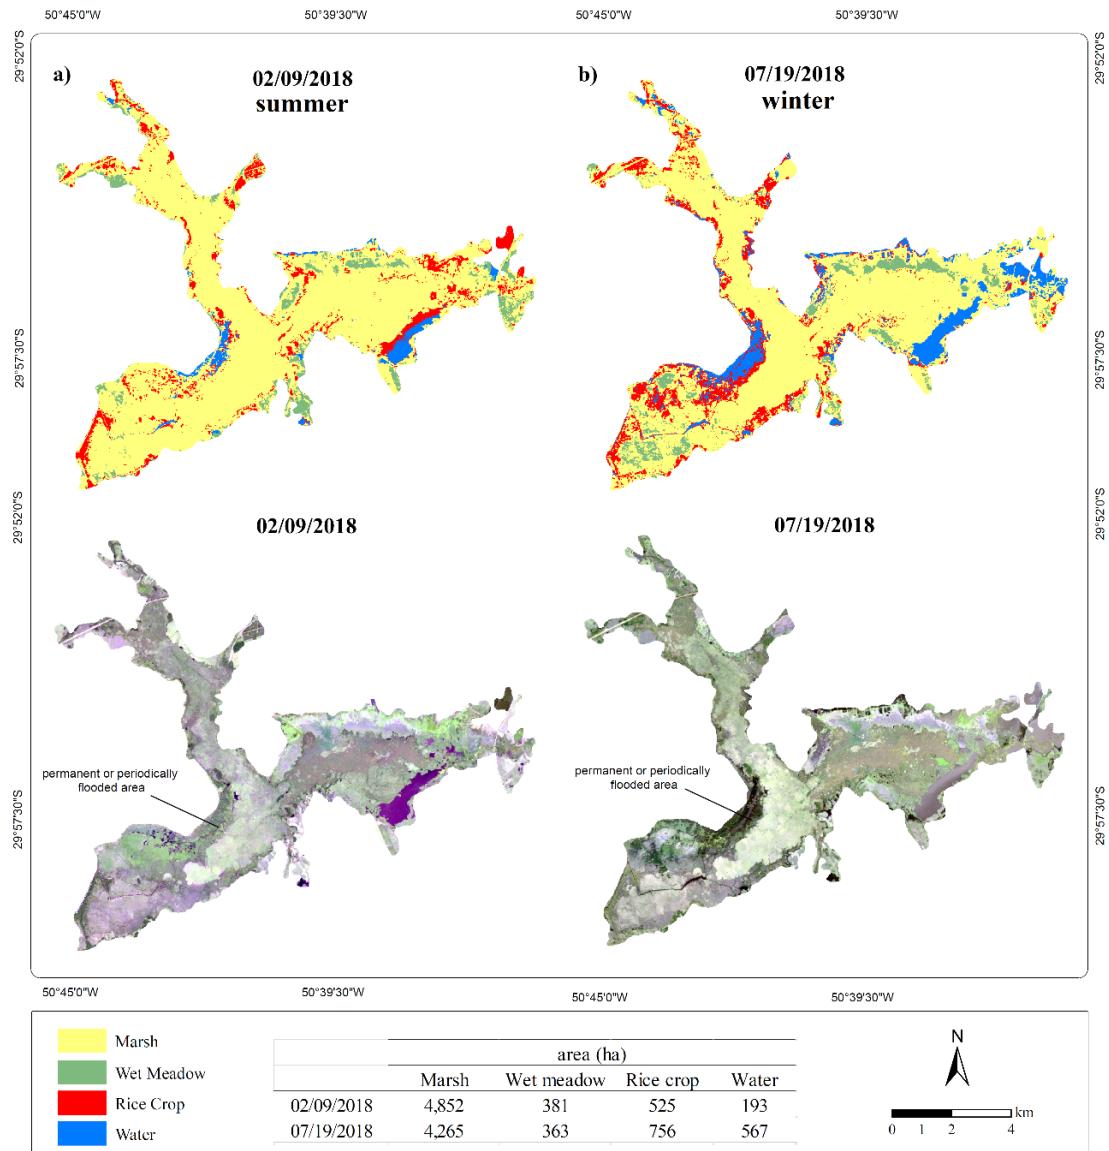


Figure 5. Classification and regression trees (CART) method results for the BG small inner marsh (SIM) area during the Summer (a) and Winter (b).

smaller than 0.25 classified 98% of the samples as marsh areas.

The relevant indexes for the DT creation using the CART method are showed in Figure 4. The most important index was ARVI (44% of total relevance) followed by NDTI, BI, NDPI and BI_2, with 25.9%, 17.7%, 11.1% and 0.8% total relevance, respectively. ARVI presented the best results to classify rice crops while NDTI, BI,

NDPI and BI_2 presented the best results to classify marsh areas.

The classification indexes relevance is related to the minimum impurity reduction required to divide a node, which means that higher values tend to produce trees with fewer nodes. This fact was noticed in both ARVI and NDTI, which created only one node each. The BI_2 is an exception

Table 3. Validation samples confusion matrix.

	Classification 1 (Summer) – 02/09/2018			
	SIMA	WM	RC	UA (%)
SIMA	512	9	40	91.3
WM	8	595	6	97.7
RC	12	0	628	98.1
PA (%)	96.2	98.5	93.2	-
PC (%)		95.9		
	Classification 2 (Winter) – 07/19/2018			
	SIMA	WM	RC	UA (%)
SIMA	455	69	37	81.1
WM	87	477	30	80.3
RC	78	88	440	72.6
PA (%)	73.3	75.2	86.7	-
PC (%)		77.9		

because it is in the last tree level characterizing itself as a leaf.

3.3. Marsh Delimitation

The areas classified as marshes by the DT for Summer and Winter seasons are presented in Figure 5. The summer image presented the best classification results compared to the winter image. The areas classified as rice crops are found on the BG edges (Figure 5a). In the Winter image (Figure 5b), CART classified flooded areas erroneously as rice cultivation. This error is most likely associated to the image acquisition period given the fact that in February rice cultivation presents a spectral response related to grain ripening phenology. On the other hand, in July, there is fallow vegetation and higher amplitude in the water level oscillation with similar response to the marshes areas.

The DT classification results showed that the SIM class presents the lower UA. For the Summer image, the SIM samples used for validation presented a 91.3% UA, followed by WM areas with 97.7% UA. The RC areas presented the best UA for the Summer image, with 98.1%. For the Winter image, the SIM class presented the higher UA, 81.1%, followed by the WM and RC areas, with 80.3% and 72.6% UA, respectively.

4. Discussion

ARVI was successful for rice crop classification with up to 98.5% PC. However, for marsh areas this index did not perform well, classifying only

23.3% of the samples as marshes. For SIM, the best results were obtained by the NDTI, BI and NDPI indexes, respectively. NDTI and NDPI have been successfully applied for wetland mapping by several studies. Some examples are the studies developed by 1) Mondal and Bandyopadhyay (2014), which delimitated wetlands based on turbidity by mixing NDTI and NDPI techniques; and 2) Sharma *et al.* (2014), which used NDTI and NDPI to understand vegetation patterns and water turbidity in wetlands.

NDTI and NDPI indexes were specifically developed for studies over wetlands and their reliability in the delimitation of these areas was expected (Sharma *et al.*, 2014). We also highlight the good performance obtained with the BI. This index represents the average sensitive brightness to the soil, which is highly correlated with the moisture and the salt at the surface. The BI was developed to explore the soil surface characterization, mainly in arid environments, where vegetation is scarce and not green (Escadafal, 1989).

The hydromorphic soils presence in the study area, which is characterized by a high content of organic matter, allowed the BI application for marshes delimitation. This is discussed by Kandus *et al.* (2008), highlighting the importance of the soil taxonomic classification for wetlands delimitation. The marshes delimitation from the hydromorphic soils is also discussed by (Maltchik *et al.*, 2004). For these authors, the hydromorphic soils must be used as an environmental attribute in marshes delimitation in addition to the hydrological regime and aquatic vegetation patterns.

Our findings showed that the classification results for the Summer image presented a higher PC than the Winter image. This fact is most likely be related to seasonality of the flood pulses and vegetation patterns in the BG (Belloli, 2016; Simioni *et al.*, 2017).

5. Conclusions

The SIM areas delimitation remains a challenge for the scientific community considering that these wetlands present their own dynamics, with different aquatic vegetation types adapted to water level oscillations.

Our results showed that remote sensing indexes, although not developed specifically for wetland delimitation, present satisfactory results in order to classify these ecosystems. The indexes that showed to be more useful for marshes classification by DT techniques in the study area were NDTI, BI, NDPI and BI_2, with 25.9%, 17.7%, 11.1% and 0.8%, respectively. In general, the PC found was 95.9% and 77.9% for the Summer and Winter images respectively. We hypothesize that this significant PC variation is related to the rice-planting period in the Summer and/or to the water level oscillation period in the Winter.

For future studies, we recommend the use of active remote sensors (e.g., radar) and soil maps in addition to the remote sensing spectral indexes in order to obtain better results in the delimitation of small inner marsh areas.

Acknowledgment

João Paulo Delapasse Simioni thanks the CAPES agency for providing a doctoral fellowship. The authors acknowledge the Center for Remote Sensing and Meteorology (CEPSRM) at the Federal University of Rio Grande do Sul (UFRGS) for the support provided for this research.

References

Artigas, F. J., Yang, J. 2006. Spectral discrimination of marsh vegetation types in the New Jersey Meadowlands, USA. *Wetlands*, 26(1), 271. [https://doi.org/10.1672/0277-5212\(2006\)26\[271:sdmvt\]2.0.co;2](https://doi.org/10.1672/0277-5212(2006)26[271:sdmvt]2.0.co;2)

Belloli, T. F. 2016. *Environmental Impacts Due to Rice, Large Banhado Environmental Protection Area - RS*. Federal University of Rio Grande do Sul. Retrieved from <https://www.lume.ufrgs.br/bitstream/handle/10183/158968/001023034.pdf?sequence=1>

Belluco, E., Camuffo, M., Ferrari, S., Modenese, L., Silvestri, S., Marani, A., Marani, M. 2006. Mapping salt-marsh vegetation by multispectral and hyperspectral remote sensing. *Remote Sensing of Environment*, 105(1), 54-67. <https://doi.org/10.1016/j.rse.2006.06.006>

Canadian Wetland Inventory Technical Group. 2016. *Canada Wetland Inventory (Data Model)*. Stonewall. Retrieved from http://www.ducks.ca/assets/2017/01/CWIDMv7_01_E.pdf

Clevers, J. G. P. W., Leeuwen, H. J. C. Van, Sensing, R., Verhoef, W. 1989. Estimating apar by means of vegetation indeces: a sensitivity analysis. *XXIX ISPRS Congress Technical Commission VII: Interpretation of Photographic and Remote Sensing Data*, 691-698.

Congalton, R. G. 1991. A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35-46. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B)

Deering, D. W. 1975. Measuring forage production of grazing units from Landsat MSS data. *Proceedings of 10th International Symposium on Remote Sensing of Environment*, 1975, 1169-1178.

Delegido, J., Verrelst, J., Alonso, L., Moreno, J. 2011. Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. *Sensors*, 11(7), 7063-7081. <https://doi.org/10.3390/s110707063>

Di Vittorio, C. A., Georgakakos, A. P. 2018. Land cover classification and wetland inundation mapping using MODIS. *Remote Sensing of Environment*, 204, 1-17. <https://doi.org/10.1016/j.rse.2017.11.001>

Dong, Z., Wang, Z., Liu, D., Song, K., Li, L., Jia, M., Ding, Z. 2014. Mapping Wetland Areas Using Landsat-Derived NDVI and LSWI: A Case Study of West Songnen Plain, Northeast China. *Journal of the Indian Society of Remote Sensing*, 42(3), 569-576. <https://doi.org/10.1007/s12524-013-0357-1>

Dvorett, D., Davis, C., Papés, M. 2016. Mapping and Hydrologic Attribution of Temporary Wetlands Using Recurrent Landsat Imagery. *Wetlands*, 36(3), 431-443. <https://doi.org/10.1007/s13157-016-0752-9>

Environmental Protection Agency. 2001. *Functions and Values of Wetlands*. Watershed Academy Web. Washington. Retrieved from <https://www.epa.gov/wetlandsfunctionsvalues>

- Escadafal, R. 1989. Remote sensing of arid soil surface color with Landsat thematic mapper. *Advances in Space Research*, 9(1), 159-163. [https://doi.org/10.1016/0273-1177\(89\)90481-X](https://doi.org/10.1016/0273-1177(89)90481-X)
- Etchelar, C. B. 2017. *Erosive Processes in Wetlands*. Rio Grande do Sul Federal University. Retrieved from <https://www.lume.ufrrgs.br/bitstream/handle/10183/171041/001054625.pdf?sequence=1>
- Fariña, J. M., He, Q., Silliman, B. R., Bertness, M. D. 2017. Biogeography of salt marsh plant zonation on the Pacific coast of South America. *Journal of Biogeography*, 12, 238-247. <https://doi.org/10.1111/jbi.13109>
- Fluet-Chouinard, E., Lehner, B., Rebelo, L. M., Papa, F., Hamilton, S. K. 2015. Development of a global inundation map at high spatial resolution from topographic downscaling of coarse-scale remote sensing data. *Remote Sensing of Environment*, 158, 348-361. <https://doi.org/10.1016/j.rse.2014.10.015>
- Friedl, M.A. M. A., Brodley, C. E. C. E. 1997. Decision tree classification of land cover from remotely sensed data. *Remote Sensing of Environment*, 61(3), 399-409. [https://doi.org/10.1016/S0034-4257\(97\)00049-7](https://doi.org/10.1016/S0034-4257(97)00049-7)
- Gao, B. C. 1996. NDWI - A normalized difference water index for remotesensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257-266. [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- Gedan, K. B., Crain, C. M., Bertness, M. D. 2009. Small-mammal herbivore control of secondary succession in New-England tidal marshes. *Ecology*, 90(2), 430-440. <https://doi.org/10.1890/08-0417.1>
- Gitelson, A. A., Kaufman, Y. J., Merzlyak, M. N. 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, 58(3), 289-298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Huete, A. R. 1988. A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295-309. [https://doi.org/10.1016/0034-4257\(88\)90106-X](https://doi.org/10.1016/0034-4257(88)90106-X)
- Jensen, J. R. 2007. *Remote sensing of the environment : an earth resource perspective*. Pearson Prentice Hall.
- Judd, C., Steinberg, S., Shaughnessy, F., Crawford, G. 2007. Mapping salt marsh vegetation using aerial hyperspectral imagery and linear unmixing in Humboldt Bay, California. *Wetlands*, 27(4), 1144-1152. [https://doi.org/10.1672/0277-5212\(2007\)27\[1144:msmvua\]2.0.co;2](https://doi.org/10.1672/0277-5212(2007)27[1144:msmvua]2.0.co;2)
- Junk. 2013. *Definição e Classificação das Áreas Úmidas (AUs) Brasileiras* : Base Científica para uma Nova Política de Proteção e Manejo Sustentável Prefácio : Lista dos autores e suas instituições : Centro de Pesquisa Do Pantanal, Brazil.
- Junk, W. J., Bayley, P. B., Sparks, R. E. 1989. The Flood Pulse Concept in River-Floodplain Systems. *International Large River Symposium*.
- Junk, W. J., Piedade, M. F. 2015. Áreas Úmidas (AUs) Brasileiras: Avanços e Conquistas Recentes. *Boletim Ablimno*, 41(2), 20-24.
- Junk, W. J., Piedade, M. T. F., Lourival, R., Wittmann, F., Kandus, P., Lacerda, L. D., Agostinho, A. A. 2014. Brazilian wetlands: Their definition, delineation, and classification for research, sustainable management, and protection. *Aquatic Conservation: Marine and Freshwater Ecosystems*, 24(1), 5-22. <https://doi.org/10.1002/aqc.2386>
- Kandus, P., Minotti, P., Malvárez, A. I. 2008. Distribution of wetlands in Argentina estimated from soil charts. *Acta Scientiarum - Biological Sciences*, 30(4), 403-409. <https://doi.org/10.4025/actascibiolsci.v30i4.5870>
- Kaplan, G., Avdan, U. 2017. Mapping and Monitoring Wetlands Using SENTINEL 2 Satellite Imagery. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, IV, 271-277. <https://doi.org/10.5194/isprs-annals-IV-4-W4-271-2017>
- Kaplan, G., Avdan, U. 2017. Wetland Mapping Using Sentinel 1 SAR Data. In Suha Ozden, R. Cengiz Akbulak, Cuneyt Erenoglu, Oznur Karaca, Faize Saris, & Mustafa Avcioglu (Eds.), *International Symposium on GIS Applications in Geography & Geosciences*.
- Kaufman, Y., Tanre, D. 1992. 1992. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2). <https://doi.org/10.1109/36.134076>
- Kulawardhana, R. W., Thenkabail, P. S., Vithanage, J., Biradar, C., Islam, M. A. a, Gunasinghe, S., Alankara, R. 2007. Evaluation of the wetland mapping methods using Landsat ETM+ and SRTM data. *Journal of Spatial Hydrology*, 7(2), 62-96. <https://doi.org/10.1017/CBO9780511806049>
- Lacaux, J. P., Tourre, Y. M., Vignolles, C., Ndione, J. A., Lafaye, M. 2007. Classification of ponds from high-spatial resolution remote sensing: Application to Rift Valley Fever epidemics in Senegal. *Remote Sensing of Environment*, 106(1), 66-74. <https://doi.org/10.1016/j.rse.2006.07.012>
- Leite, M. G., Guasselli, L. A. 2013. Spatio-temporal dynamics of aquatic macrophytes in Banhado Grande, Gravataí River basin,. *Para Onde!?*, 7(1), 17-24.

- Liu, L., Liu, Y. H., Liu, C. X., Wang, Z., Dong, J., Zhu, G. F., Huang, X. 2013. Potential effect and accumulation of veterinary antibiotics in *Phragmites australis* under hydroponic conditions. *Ecological Engineering*, 53, 138-143. <https://doi.org/10.1016/j.ecoleng.2012.12.033>
- Mahdavi, S., Salehi, B., Amani, M., Granger, J. E., Brisco, B., Huang, W., Hanson, A. 2017. Object-Based Classification of Wetlands in Newfoundland and Labrador Using Multi-Temporal PolSAR Data. *Canadian Journal of Remote Sensing*, 43(5), 432-450. <https://doi.org/10.1080/07038992.2017.1342206>
- Maltchik, L., Rolon, A. S., Guadagnin, D. L., Stenert, C. 2004. Wetlands of Rio Grande do Sul, Brazil: a classification with emphasis on plant communities. *Acta Limnol. Bras.*, 16(2), 137-151.
- Mao, R., Ye, S.-Y., Zhang, X.-H. 2018. Soil Aggregate-Associated Organic Carbon Along Vegetation Zones in Tidal Salt Marshes in the Liaohe Delta. *CLEAN - Soil, Air, Water*, 1-7. <https://doi.org/10.1002/clen.201800049>
- McFeeters, S. K. 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425-1432. <https://doi.org/10.1080/01431169608948714>
- Mcowen, C. J., Weatherdon, L. V., Bochove, J.-W. Van, Sullivan, E., Blyth, S., Zockler, C., Fletcher, S. 2017. A global map of saltmarshes. *Biodiversity Data Journal*, 5(S), e11764. <https://doi.org/10.3897/BDJ.5.e11764>
- Miranda, C. de S., Paranhó Filho, A. C., Pott, A. 2018. Changes in vegetation cover of the Pantanal wetland detected by vegetation index: a strategy for conservation. *Biota Neotropica*, 18(1), 1-6. <https://doi.org/10.1590/1676-0611-bn-2016-0297>
- Mondal, I., Bandyopadhyay, J. 2014. Coastal Wetland Modeling Using Geoinformatics Technology of Namkhana Island, South 24 Parganas, WB, India. *Open Access Library Journal*, 975, 1-17. <https://doi.org/10.4236/oalib.1100975>
- Nielsen, S. 1994. Geomorfologia da bacia do rio Gravataí-RS. In *Bacia do rio Gravataí-RS: informações básicas para a gestão territorial* (pp. 1–18). Porto Alegre: Proteger.
- Nunes da Cunha, C., Piedade, M. T. F., Junk, W. J. 2015. *Classificação e Delineamento das Áreas Úmidas Brasileiras e de seus Macrohabitats*. EdUFMT (Vol. 1). Cuiabá. <https://doi.org/10.1017/CBO9781107415324.004>
- Pearson, R. L., Miller, L. D. 1972. Remote Mapping of Standing Crop Biomass for Estimation of the Productivity of the Shortgrass Prairie. *Remote Sensing of Environment*, 8, 1355-1365.
- Pontius, R. G., Millones, M. 2011. Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32(15), 4407-4429. <https://doi.org/10.1080/01431161.2011.552923>
- Qi, J., Chehbouni, A., Huete, A. R., Kerr, Y. H., Sorooshian, S. 1994. A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48(2), 119-126. [https://doi.org/10.1016/0034-4257\(94\)90134-1](https://doi.org/10.1016/0034-4257(94)90134-1)
- Ramos, R. A., Pasqualetto, A. I., Balbuena, R. A., Quadros, E. L. L. de, Neves, D. D. das. 2014. Mapeamento e diagnóstico de áreas úmidas no Rio Grande do Sul, com o uso de ferramentas de geoprocessamento. In *Anais do Simpósio de Áreas Protegidas* (pp. 17-21). Viçosa.
- Ramsar. 2002. *A Framework for Wetland Inventory*. 8th Meeting of the Conference of the Contracting Parties to the Convention on Wetlands. Valencia. Retrieved from <http://archive.ramsar.org/pdf/inventory-framework-2002.pdf>
- Richardson, A. J., Wiegand, C. L. 1977. Distinguishing vegetation from soil background information. *Photogrammetric Engineering and Remote Sensing*, 43(12), 1541-1552.
- Rossato, M. S. 2011. *Os climas do Rio Grande do Sul: variabilidade, tendências e tipologia*. Universidade Federal do Rio Grande do Sul.
- Rouse, J. W., Hass, R. H., Schell, J. A., Deering, D. W. 1973. Monitoring vegetation systems in the great plains with ERTS. *Third Earth Resources Technology Satellite (ERTS) Symposium*, 1, 309-317. <https://doi.org/citeulike-article-id:12009708>
- Ruiz, L. F. C., Caten, A. ten, Dalmolin, R. S. D. 2014. Árvore de decisão e a densidade mínima de amostras no mapeamento da cobertura da terra. *Ciência Rural*, 44(6), 1001-1007. <https://doi.org/10.1590/S0103-84782014000600008>
- Sakané, N., Alvarez, M., Becker, M., Böhme, B., Handa, C., Kamiri, H. W., Langensiepen, M., Menz, G., Misana, S., Mogha, N. G., Mösseler, B. M., Mwita, E. J., Oyieke, H. A., Van Wijk, M. T. 2011. Classification, characterisation, and use of small wetlands in East Africa. *Wetlands*, 31, 1103. <https://doi.org/10.1007/s13157-011-0221-4>
- Sharma, A., Panigrahy, S., Singh, T. S., Patel, J. G., Tanwar, H. 2014. Wetland Information System Using Remote Sensing and GIS in Himachal Pradesh, India. *Asian Journal of Geoinformatics*, 14(4), 13-22.

- Sharpe, P. J., Kneipp, G., Forget, A. 2016. Comparison of Alternative Approaches for Wetlands Mapping: A Case Study from three U.S. National Parks. *Wetlands*, 36(3), 547-556. <https://doi.org/10.1007/s13157-016-0764-5>
- Silva, R. C. da. 2016. *Estudo da dinâmica da fragilidade ambiental na Bacia Hidrográfica do Rio Gravataí*, RS. Universidade Federal da Bahia.
- Simioni, J. P. D., Guasselli, L. A., Etchelar, C. B. 2017. Connectivity among Wetlands of EPA of Banhado Grande, RS Conetividade entre Áreas Úmidas, APA do Banhado Grande, RS. *Brazilian Journal of Water Resources*, 22(15). <https://doi.org/10.1590/2318-0331.011716096>
- Stefano, L. de. 2003. *WWF's Water and Wetland Index Summary of Water Framework Directive results*. WWF European Living Waters Programme c/o. San Francisco.
- Subramaniam, S., Saxena, M. 2011. Automated algorithm for extraction of wetlands from IRS resourcesat LISS III data. In *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* (pp. 193-198). Bhopal.
- Teixeira, S. G. 2011. *Radar de abertura sintética aplicado ao mapeamento e reconhecimento de zonas úmidas costeiras*. Universidade Federal do Pará.
- Visser, J. M., Sasser, C. E. 1999. Marsh Vegetation of the Mississippi River Deltaic Plain. *Estuaries*, 21(4B), 818-828.
- Walsh, N., Bhattacharji, N., Chay, F. 2014. Mapping Tidal Salt Marshes.
- White, D. C., Lewis, M. M., Green, G., Gotch, T. B. 2016. A generalizable NDVI-based wetland delineation indicator for remote monitoring of groundwater flows in the Australian Great Artesian Basin. *Ecological Indicators*, 60, 1309-1320. <https://doi.org/10.1016/j.ecolind.2015.01.032>
- Xu, H. 2006. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025-3033. <https://doi.org/10.1080/01431160600589179>
- Yan, D., Wünnemann, B., Hu, Y., Frenzel, P., Zhang, Y., Chen, K. 2017. Wetland evolution in the Qinghai Lake area, China, in response to hydrodynamic and eolian processes during the past 1100 years. *Quaternary Science Reviews*, 162, 42-59.
- Zhou, Q., Jing, Z., Jiang, S. 2003. Remote sensing image fusion for different spectral and spatial resolutions with bilinear resampling wavelet transform. In *Proceedings of the 2003 IEEE International Conference on Intelligent Transportation Systems* 2, 1206-1213. Shanghai: IEEE. <https://doi.org/10.1109/ITSC.2003.1252676>



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

João Paulo Delapasse Simioni¹ · Laurindo Antonio Guasselli¹ ·
Victor Fernandez Nascimento² · Luis Fernando Chimelo Ruiz¹ · Tassia Fraga Belloli¹

Received: 9 July 2018 / Accepted: 5 August 2019
© Springer Nature B.V. 2019

Abstract

Marsh is a wetland type characterized by hydromorphic soils, herbaceous vegetation, aquatic and emergent vegetation; usually, the apparent water surface does not exceed 25% of the area. Multi-polarized active remote sensors with different frequencies have characteristics that make them ideal for mapping and delineating marsh areas since they provide information on canopy roughness, vegetation moisture and amount of biomass. Therefore, the main objective of this study is to develop a method based on multi-frequency radar satellites images to delineate marsh areas using decision tree classification. In order to reach this objective, we sought to answer the following questions: (1) Are L-band SAR images more efficient for marshes delineation than C-band SAR images? (2) Is multi-sensor (L and C-band) integration more accurate for marsh areas delineation than a single sensor? and (3) What are the most efficient channels for marshes delineation? Our findings showed that L-band images present greater proportion correct (PC) for marshes delineation compared to C-band images. However, the greatest PC was found using integration of Alos Palsar 1 and Sentinel 1 satellites images, reaching more than 72% of correctness. Regarding the polarization importance to Alos Palsar 1 image, HVVH presented the highest importance, with 29%, followed by VH and HV polarizations, both with 28%. For Sentinel 1 image, the most important polarization was VH, with 22%, followed by VV + VH that presented 20%. HVVH polarization was the most important in Alos and Sentinel images integration, with 35%, followed by Alos Palsar HV and VH, with 34 and 33%, respectively. Thus, we concluded that the method based on SAR multi-frequency data integration used in this study can be easily applied by other researchers interested in marsh delineation since the radar images used are freely available and can be processed and manipulated in free GIS software.

Keywords Data mining · Hydromorphic soils · Polarization · Wetlands

✉ João Paulo Delapasse Simioni
joao.delapasse@ufrgs.br

¹ Federal University of Rio Grande do Sul, Research Center on Remote Sensing and Meteorology, Bento Gonçalves Avenue, n. 9500 - Agronomia, Porto Alegre, RS 91501-970, Brazil

² National Institute for Space Research, Earth System Science Center, Avenida dos Astronautas Street, n. 1758 - Jardim da Granja, São José dos Campos, SP 12227-010, Brazil

1 Introduction

Wetlands are among the most productive ecosystems in the world, presenting high levels of ecological diversity including primary and secondary productivity (An and Verhoeven 2019). These environments provide food and habitat for birds and terrestrial animals and act on nutrient and sediment cycling, flood control, coastal zone conservation, climate regulation and carbon storage (Ballanti et al. 2017; White et al. 2015) In addition, wetlands are responsible for storing about 25% of the Earth's total carbon (Mitsch et al. 2013).

Approximately 20% of South America territory is covered by wetlands (Kandus et al. 2018). For this reason, it is necessary to carefully treat these environments in face of climate change and land use pressures. Therefore, wetlands monitoring and classification are fundamental, given the benefits provided by these ecosystems (Henderson and Lewis 2008).

The difficult access to wetlands is one of the factors that favor the use of remote sensing data, mainly because of short time acquisition periods and low cost (Guo et al. 2017). Free access to remote sensing images and open source software (Kaya et al. 2018), for example, allows the development of efficient methods for delineating wetlands at low cost and with high accuracy.

Radar remote sensing has great potential to complement traditional remote sensing images (Jahncke et al. 2018; Mohammadimanesh et al. 2018). Using images in the microwave range of electromagnetic spectrum presents significant potential in targets' spectral behavior (Fu et al. 2017; Kaplan and Avdan 2019). Its main advantages are, first, penetration through clouds, second, data acquisition during the day or night and finally, in the case of vegetation and biomass, access to information on the entire canopy and not just the first leaves layer (Wang et al. 2018; White et al. 2015).

In addition, radar images are an important tool for wetlands delineation and characterization (White et al. 2015; Furtado et al. 2016; Mohammadimanesh et al. 2018), because they are sensitive to dielectric properties, such as soil and vegetation moisture content and also due to their scanned surface geometry (Bwangoy et al. 2010; Henderson and Lewis 2008).

In areas with large cloud cover as in the equatorial region, it is difficult to use traditional satellite images for wetlands delineation and classification (Mleczko and Mróz 2018), and radar images become fundamental to understand and classify floodable areas (Furtado et al. 2016; Jahncke et al. 2018).

SAR systems can also penetrate vegetation; usually, the longer the wavelength, the deeper the penetration through the canopy. However, several factors can affect the radar backscatter, such as angle of incidence, soil moisture, dielectric constant and ground features' structure/composition (White et al. 2015).

There are several radar image sensors in orbit, with different spatial resolutions, polarizations and wavelengths (Mahdianpari et al. 2017). In general, the use of X- (2.43–3.75 cm) and C-bands (3.75–7.5 cm) is preferred for herbaceous wetlands and less dense canopies, while L-band (15–30 cm) is preferred for woody wetlands such as swamps and other wetland classes with high biomass (Dabboor and Brisco 2018). Marsh is a wetland type dominated by herbaceous vegetation, usually covering more than 75% of the surface area with shrubs and trees covering the remaining extent (Canadian Wetland Inventory Technical Group 2016).

Although wetlands importance is widely recognized (White et al. 2015), these environments have been suffering significant negative impacts, such as conversion to agricultural

land (Saha and Pal 2018), grounding for urban and industrial buildings, pollution from agrochemicals and waste disposal (Eniolorunda et al. 2017; Fluet-Chouinard et al. 2015; Saha and Pal 2018).

Therefore, classifying, mapping and delineating marshes are fundamental to understand the importance of the wetlands (Cunha et al. 2015). Among all mapping and delineation techniques using radar, polarimetry has great potential to discriminate similar land cover uses, including different wetland compartments (Mahdianpari et al. 2018). Radar systems may have different polarization combinations, such as single (H or V); dual (HH and HV or VV and VH); and also quadruple or full polarimetric (HH, VV, HV and VH) (Andrade 2012).

The use of dual-pol synthetic aperture radar (SAR) images for wetlands mapping and classification has shown good results using dual-pol data channels HH-VV (Moser et al. 2016). In addition, the use of high spatial resolution dual-pol SAR images can predict space–time dynamic processes in wetlands such as vegetation colonization, flood design and extension (Betbeder et al. 2015).

The use of dual-pol SAR images in wetlands studies is well recognized in the literature. Kim et al. (2008) and Betbeder et al. (2015) applied Alos Palsar data (HH/HV channels) for wetlands mapping and monitoring, and Moser et al. (2016), Mleczko and Mróz (2018) and Kaplan and Avdan (2019) applied Sentinel 1 satellite images with VV/VH polarization for wetlands mapping and classification.

Furthermore, Mleczko et al. (2016), de Furtado et al. (2016), Morandeira et al. (2016), Jahncke et al. (2018), Johansson et al. (2018), Mahdianpari et al. (2018) also applied quad-Pol SAR images for wetlands mapping and delineation. In general, studies involving quad-Pol presented better accuracy for wetlands mapping when compared to dual-Pol SAR (de Furtado et al. 2016).

In this study, a method based on multi-frequency radar satellites images was developed to delineate marsh areas using decision tree classification. Our main questions are: (1) Are L-band SAR images more efficient than C-band SAR images for marsh delineation? (2) Is multi-sensor (L and C-band) integration more accurate for marsh delineation than a single sensor? and (3) What is the most efficient channel for marsh delineation?

2 Methodology

2.1 Study area

The study area is *Banhado Grande* (BG) marsh ($29^{\circ}57' S$, $50^{\circ}41' W$) (Fig. 1), a paludal environment with approximately 5591 ha (Ramos et al. 2014), one of the main contributors to Gravataí River basin drainage in the State of Rio Grande do Sul, Brazil.

The predominant vegetation cover in BG is aquatic macrophytes community, mainly emergent and floating plants which have heterogeneous distribution pattern, influenced by flood dynamics and hydrodynamics (Leite and Guasselli 2013).

Although marsh areas are considered permanent preservation units by Rio Grande do Sul State legislation, BG has historically suffered a series of negative impacts, such as drainage for agricultural crops, agrochemicals, urban and industrial effluents dump and soil erosion.

Understanding precipitation on a regional basis is an important component of wetlands planning and management (Roushangar et al. 2018). The average monthly

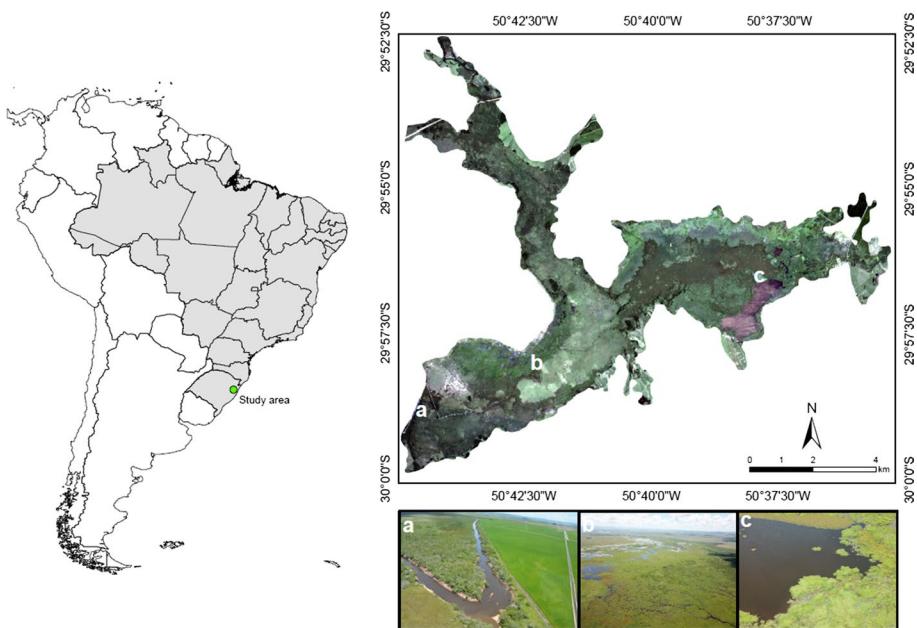


Fig. 1 Banhado Grande marsh location and vegetation cover patterns. **a** Gravataí river and rice crop, **b** emergent vegetation and **c** aquatic vegetation

precipitation in BG is 125.0 mm (Fig. 2), and there is no seasonal precipitation pattern definition (Simioni et al. 2017, 2018). The historical least rainy month average is February, with 114 mm, while for October, the highest rainfall average month is 167.0 mm.

Standard deviation (SD) values show flood and dry pulses unpredictability. In March, June, October and November, SD ranges from 83 to 114 mm, making of pulses an outstanding wetlands feature in Rio Grande do Sul state when compared to the rest of Brazil.

The average annual temperature ranges from 17 to 20 °C. In the hottest month (January) the average temperature fluctuates between 23 and 26 °C, while in the coldest month (July) it fluctuates between 11 and 14 °C (Committee Gravatahy 2013).

Fig. 2 BG average monthly precipitation. Source: INMET (2018)

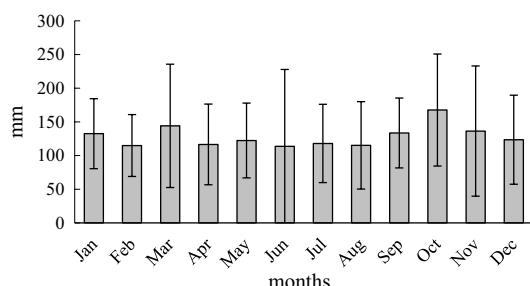
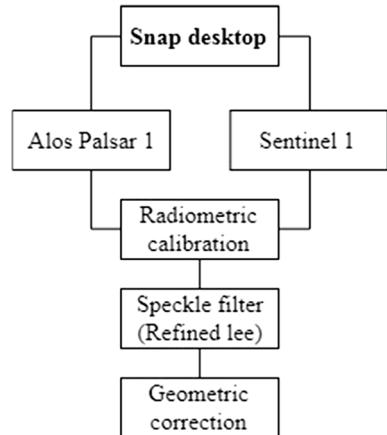


Table 1 SAR images used

Date	Sensor	Polarization	Resolution (m)	Path/frame	Frequency
04/10/2011	Alos Palsar 1	Quad-Pol	12.5	67/6590	L-band
04/10/2018	Sentinel 1	VV + VH	10.0	66/78,211	C-band

Fig. 3 Image processing flowchart in SNAP software

2.2 Radar image acquisition

The present study used radar images from Alos Palsar 1 and Sentinel 1, acquired on Alaska Satellite Facility site (www.vertex.daac.asf.alaska.edu). The images have double and quadruple polarizations, with multi-frequencies, such as bands L and C, as demonstrated in Table 1.

Alos Palsar 1 image dated from 04/10/2011 is the only full-polarimetric image available for the study area. Sentinel 1 image was chosen to contemplate the day and month, similar to that of Alos Palsar image.

2.3 Processing SAR images

SNAP software was used to follow image digital processing, as shown in flowchart in Fig. 3. First, radiometric calibration was applied. Radiometric calibration is necessary for SAR images comparison, performed at different times. Second, speckle filtering Refined Lee 5×5 used in de Furtado et al. (2016) was applied to reduce the image noise and to finally correct the geometric using the geolocation grid tool.

2.4 Samples

Samples were randomly collected from marsh area (MA), wet meadow (WM), rice crops (RC) and bare soils (BS) classes (Fig. 4). A Landsat 5 TM image was used to

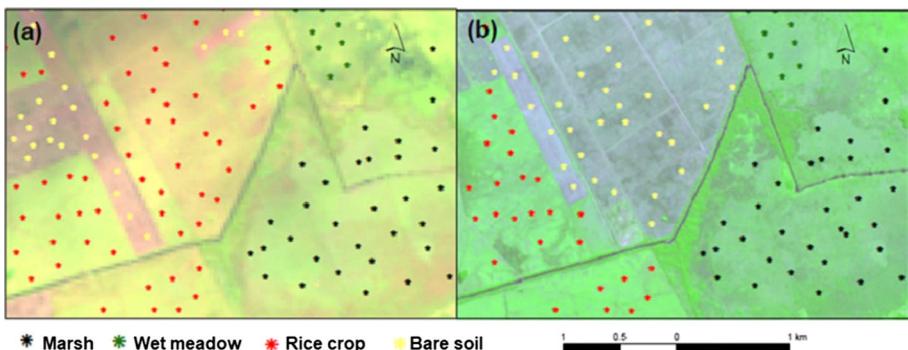


Fig. 4 Example of some samples collected for this study

Table 2 Optical images used for sample collection

Date	Sensor	Resolution (m)	Path/row
04/12/2011	Landsat 5 TM	30.0	220/8
04/10/2018	Sentinel 2A MSI	10.0	14,621/38

collect samples for Alos Palsar 1 image, while to obtain Sentinel 1 samples a Sentinel 2a image was used (Table 2).

These classes and 1000 samples were chosen for each one because radar backscatter is influenced by vegetation and the soil moisture, which affects energy electromagnetic absorption and propagation. In addition, increased moisture content reduces radar signal penetration through vegetation canopy or bare soil.

Although up to 25% of marsh areas are composed of superficial water, no samples were collected in areas with apparent water depth, because the discrimination of these environments is well documented in the literature, mainly through thresholding (Silveira and Heleno 2009; Wentao-Lv et al. 2010). Finally, sampling points were divided into 70% for training and 30% for validation, respectively, 700 and 300 samples. To analyze classification accuracy, proportion correct (PC) (Pontius and Millones 2011), producer's accuracy (PA) and user's accuracy (UA) (Congalton 1991) were used.

2.5 Decision tree

The method used to discriminate classes was classification and regression trees (CART) (Breiman et al. 1984; Lawrence and Wright 2001). CART uses as class discrimination procedure the binary recursive partitioning (Waheed et al. 2006), where each parent node is divided into two child nodes. The process is repeated by treating each child node as a parent node. When data from a node cannot be divided into additional nodes, it is called a terminal node. Once the first terminal node has been chosen, the algorithm repeats the procedure for each dataset until all data are categorized as terminal nodes (Waheed et al. 2006).

The tree complexity can be controlled by its depth and by the child nodes sample numbers. Due to this, the following sample values were evaluated for depth: 5, 10, 15, 20, 25

and 30, and for the maximum number of samples at the child nodes: 40, 60, 80, 100 and 120. In addition, Gini index (Gini 1912) was used as the impurity measure of tree branches.

Gini index measures the data heterogeneity degree; it searches the largest category in the dataset, e.g., marshes, and tries to isolate it from the other categories (Waheed et al. 2006).

Equation 1 gives Gini index in a given node:

$$\text{Gini} = 1 - \sum_{i=1}^c p_i^2 \quad (1)$$

where p_i is each class relative frequency in each node and c is class number; in this study, it has four classes.

When Gini index is zero, the node is pure. However, when Gini index approaches one, the node is impure and increases the number of classes evenly distributed on this node. Therefore, for CART, Gini index isolates in a branch the records that represent the most frequent class (Breiman et al. 1984). In our study, the decision tree was applied in the Statistical Package for the Social Sciences (SPSS) software.

2.6 Marshes delineation

CART classification that resulted in the highest proportion correct was converted into conditional and spatialized tests using ArcGIS 10.4 software. Subsequently, the majority filter (MF) which replaces the cells was applied based on the contiguous neighboring pixels majority value. MF tool has two criteria to meet before a replacement can occur. First, neighboring cells number with the same value must be large enough to be the majority value or at least half of the cells must have the same value, depending on the parameter specified. Second, the criterion regarding the spatial cells connectivity needs to minimize the cellular spatial patterns alteration. If these criteria are not met, there will be no substitution.

3 Results

3.1 Maximum tree depth and minimum number of child nodes

The tree maximum depth controls the maximum growth levels number below the root node, i.e., the longest path between the decision tree root and leaf. The minimum cases number controls the minimum cases numbers for nodes, and nodes that do not meet these criteria will not be divided. Increasing minimum values tends to produce trees with fewer child nodes, and consequently, decision tree with smaller PC's. On the other hand, decreasing minimum values tends to produce decision tree with larger PC's, but with larger and more complex models. Figure 5 shows CART method accuracy in relation to maximum tree depth and child nodes minimum number for Alos Palsar 1, Sentinel 1 images and the integration of these two sensors.

It was found that decision tree parameters and complexity directly influence the proportion correct model. In general, the maximum tree depth increase and the number of children nodes decrease produced the highest PC's model. For Alos Palsar 1 and Sentinel 1, the highest PCs were found at depth 25 and minimum child nodes number 20, with 71%

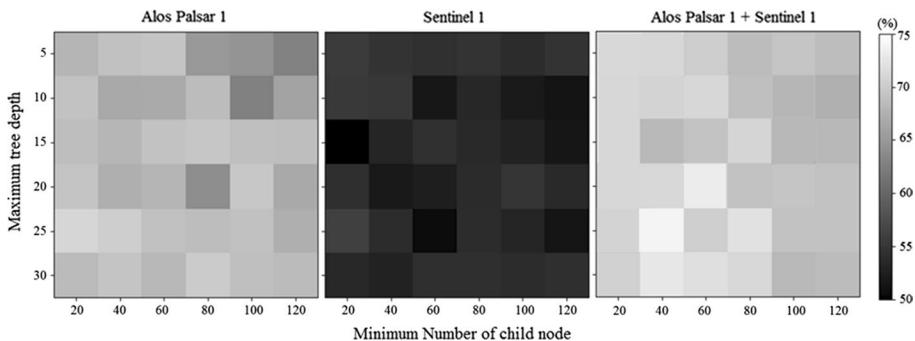


Fig. 5 Decision trees accuracy using CART method

and 56%, respectively. The integration of sensors Alos Palsar 1 and Sentinel 1 presented the highest PC, with approximately 73%.

3.2 Decision tree

The results of the decision tree classification for the three methods analysis are presented below.

3.2.1 Alos Palsar

The decision tree for Alos Palsar 1 presented 18 nodes and nine terminal nodes (Fig. 6). The root node was (HV) channel. (HV) values lower than 0.01294 classified 48% of the areas as wet meadow and constituted a terminal node. On the other hand, (HV) values greater than 0.01294 classified 48% as marsh area. This node was divided into two child nodes (HV + VH).

Alos Palsar 1 confusion image matrix (Table 3) shows that the user's accuracy values, i.e., the probability of a pixel ranked in a particular class, actually represent that category on the map ranges from 57.6 to 85.5%. The highest user's accuracy was found in wet meadow class, with 85.5%. Marsh areas had user's accuracy of 79.7%. In contrast, bare soil areas had the lowest user's accuracy values, with 57.6%, and from the 674 bare soil samples used by the decision tree, only 388 were classified correctly. The biggest bare soil confusion areas were with the marsh area classes.

Producers accuracy represents how good the benchmark class pixels are corrected rated. Marsh areas class presented the highest producer's accuracy, with 77.4%. Alos Palsar 1 images classification proportion correct was 71%.

3.2.2 Sentinel

Sentinel 1 image decision tree presented the lowest proportion correct among the analyzed methods, with 56.1%. The decision tree presented 12 nodes, seven of which were terminals (Fig. 7). It stands out VH terminal node with values higher than 0.04331, which classified 75.9% as marsh areas.

Sentinel 1 image confusion matrix (Table 4) shows that marsh areas had the lowest user's accuracy values, with 29.8%. The highest user's accuracy was found in bare soil

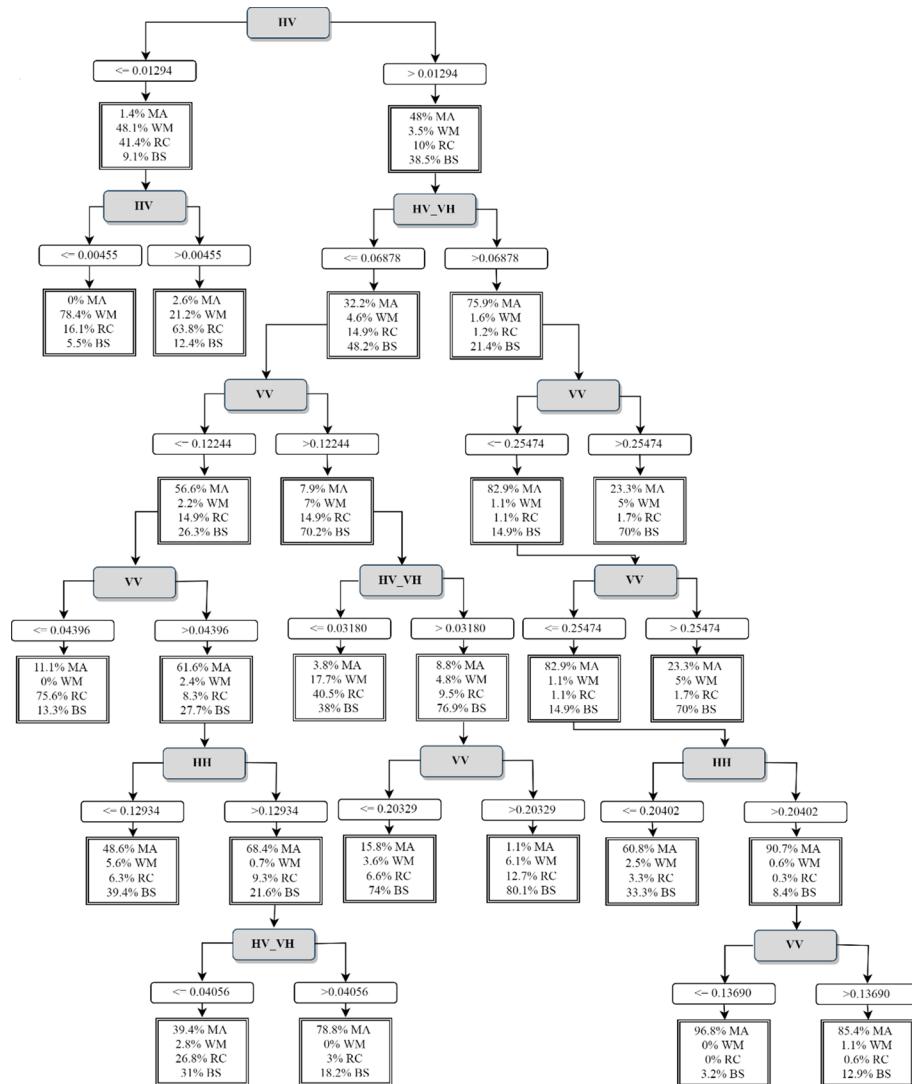


Fig. 6 Decision tree for Alos Palsar 1 quad-Pol image classification. *MA* marsh area, *WM* wet meadow, *RC* rice crop, *BS* bare soil

Table 3 Alos Palsar 1 image confusion matrix classification

	Marsh	Wet meadow	Rice	Bare soil	UA (%)
Marsh	561	0	27	116	79.7
Wet meadow	7	600	66	29	85.5
Rice	30	200	427	46	60.7
Bare soil	126	51	109	388	57.6
PA (%)	77.4	70.5	67.8	67.0	—
PC (%)	71.0				

PA producer's accuracy, *UA* user's accuracy, *PC* proportion correct

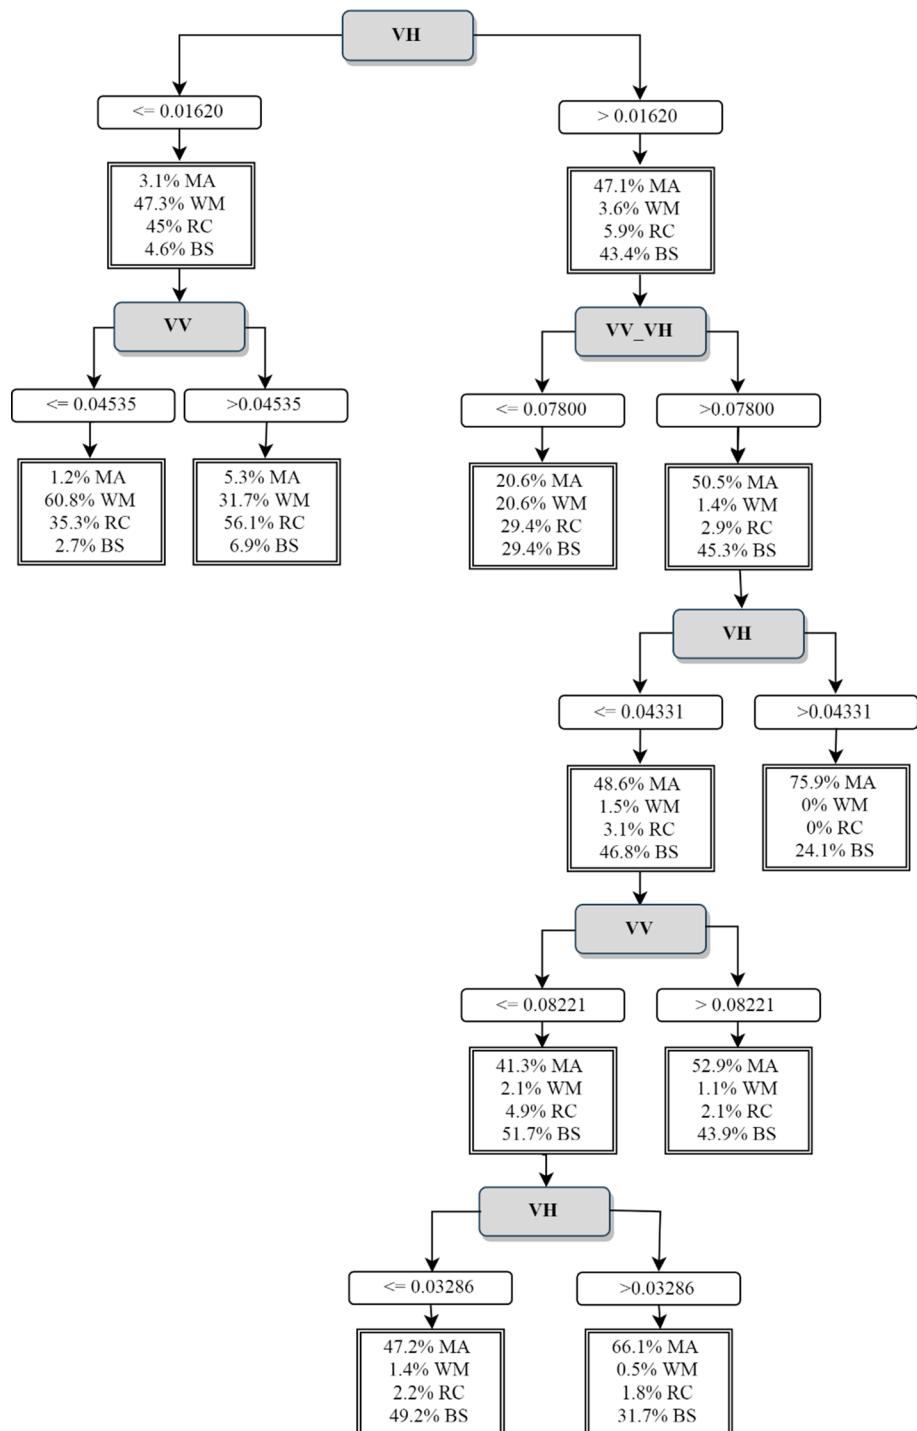


Fig. 7 Decision tree for Sentinel 1 dual-Pol image classification. *MA* marsh area, *WM* wet meadow, *RC* rice crop, *BS* bare soil

Table 4 Sentinel 1 image confusion matrix classification

	Marsh	Wet meadow	Rice crop	Bare soil	UA (%)
Marsh	210	9	34	451	29.8
Wet meadow	1	490	162	49	69.8
Rice crop	4	278	342	79	48.6
Bare soil	90	20	44	520	77.2
PA (%)	68.8	61.4	59.2	47.3	—
PC (%)	56.1				

PA producer's accuracy, UA user's accuracy, PC proportion correct

areas, with 77.2%. The highest Producer's accuracy was found in marsh areas, with 68.8%. The proportion correct was 56.1% for this classification.

3.2.3 Alos Palsar and sentinel integration

The decision tree classification from Alos Palsar 1 L-band and Sentinel 1 C-band data integration presented 12 and 7 nodes (Fig. 8). In this decision tree, HV values of Alos Palsar 1 higher than 0.04306, which classified 86.4% as marsh areas, are highlighted.

The confusion matrix (Table 5) presented the highest proportion correct among the evaluated methods, with 72.9%, the same user's accuracy samples value classified as marsh areas. Bare soil class was the one with the best user's accuracy, with 77.4%, and wet meadow class had the highest producer's accuracy, with 80.9%.

The importance of each polarization for class discrimination is presented in Fig. 9. For Alos Palsar 1 image, the most important polarization in the model was HVVH, with 29%, followed by VH and HV polarizations, both with 28%. For Sentinel 1, the most important polarization in the model was VH, with 22%, followed by VV + VH polarization, with 20%. HVVH polarization was the most important in Alos and Sentinel images integration, with 35%, followed by the HV and VH polarizations of Alos Palsar, with 34% and 33%, respectively.

The spatialization of the analyzed results (Fig. 10) shows that Alos Palsar 1 (Fig. 10a) and Sentinel 1 (Fig. 10b) images added areas with bare soil to marshes delineation. However, Alos Palsar 1 and Sentinel 1 integration (Fig. 10c) presented more concise marsh areas classification when compared to Fig. 10a, b. It can be noticed that (Fig. 10c) was able to discriminate marsh areas from bare soils, a fact not verified in the previous images (Fig. 10a, b).

4 Discussions

Wetlands delineation using radar remote sensing has developed rapidly in recent years thanks to images availability and best SAR sensors geometric resolution (Mleczko et al. 2016). In addition, multi-polarized active remote sensors provide more information than single polarization (Jahncke et al. 2018).

Multi-frequency data acquisition is important because each wavelength has specific advantages for wetlands mapping and delineation. Longer wavelengths, such as L-band (~ 24 cm), present greater penetration depths through vegetation canopy, maintaining

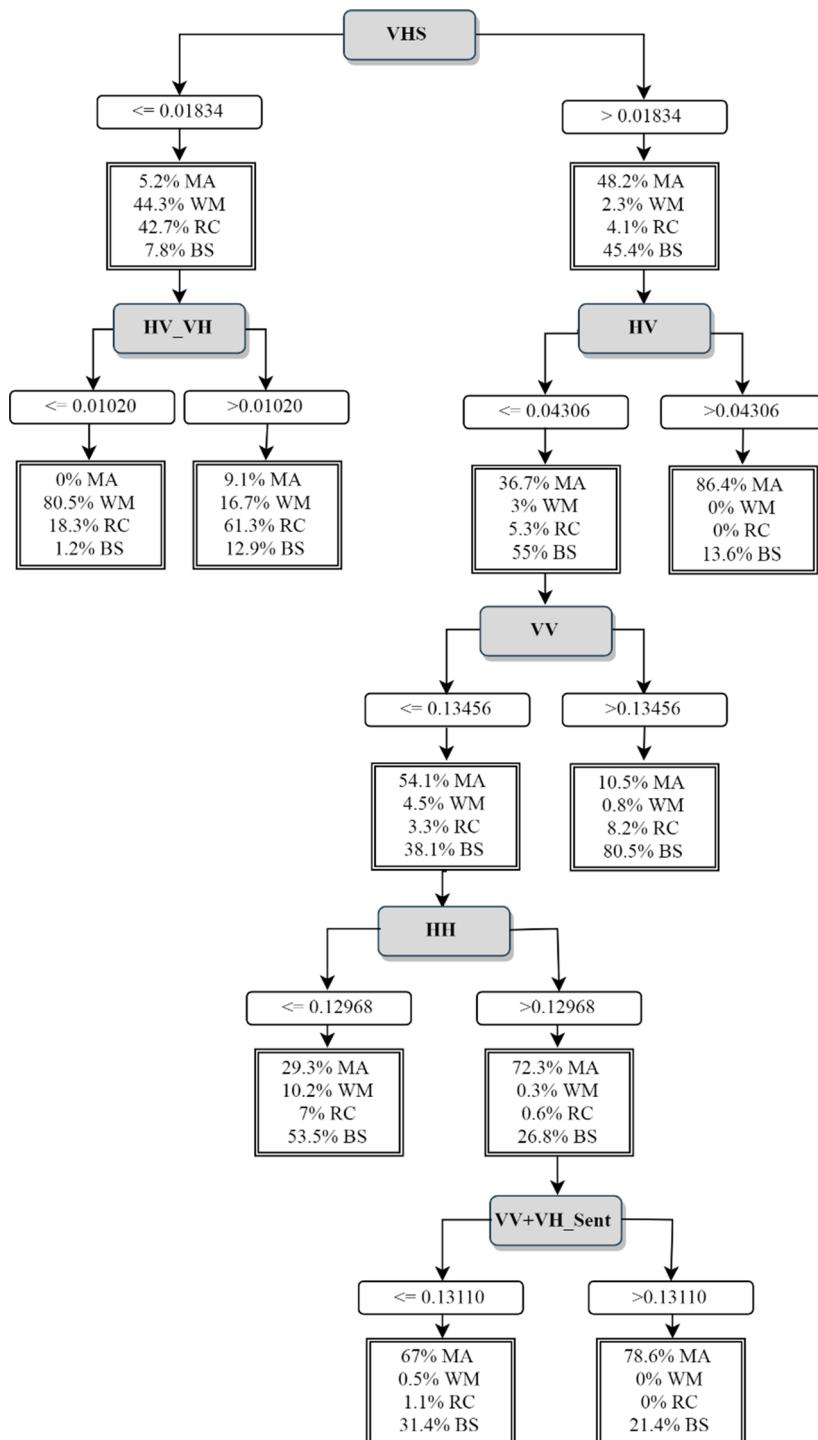
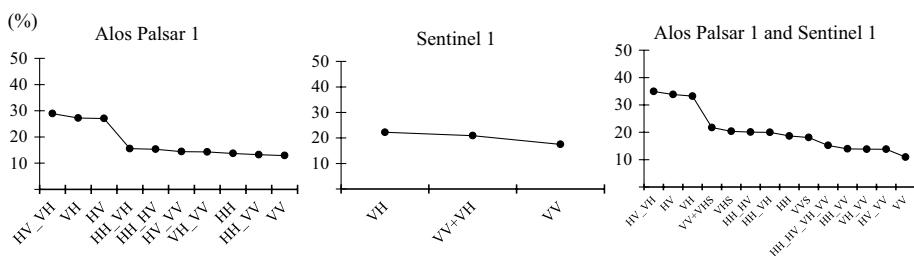
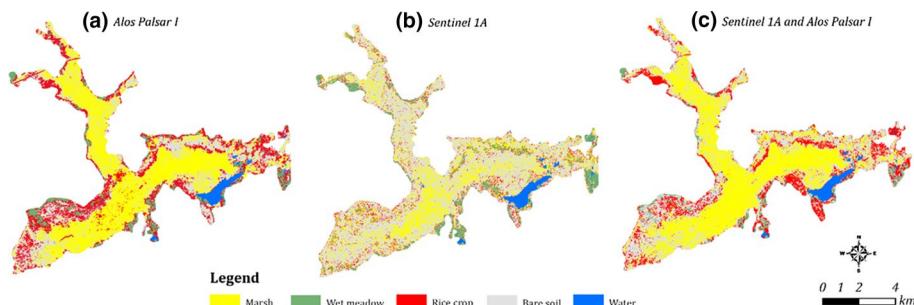


Fig. 8 Decision tree for Alos Palsar and Sentinel integration image classification. *MA* marsh area, *WM* wet meadow, *RC* rice crop, *BS* bare soil

Table 5 Alos Palsar and sentinel integration image confusion matrix classification

	Marsh	Wet meadow	Rice crop	Bare soil	UA (%)
Marsh	500	0	13	173	72.9
Wet meadow	0	515	103	76	74.2
Rice crop	0	117	473	113	67.3
Bare soil	126	4	30	547	77.4
PA (%)	79.8	80.9	76.4	60.1	—
PC (%)	72.9				

PA producer's accuracy, UA user's accuracy, PC proportion correct

**Fig. 9** Polarimetric channels relevance for marsh discrimination**Fig. 10** Marsh areas classification: **a** Alos Palsar 1; **b** Sentinel 1A and **c** Alos Palsar 1 and Sentinel 1 integration

sensitivity to soil moisture and flooding, which highlight its importance in studies involving swamp delineation. Nevertheless, shorter wavelengths, such as C-band (~ 5.6 cm), are more commonly used to discriminate non-forested wetlands vegetation patterns, such as marshes (Mahdianpari et al. 2017).

Pope et al. (1997) emphasized that C-band is better suited for marshes where grasses and smaller tree vegetation are present, due to their lower penetration capacity when compared to L-band.

SAR backscatter L-band is sensitive to vegetation structure, biomass and moisture content, so this band is able to distinguish features and pattern areas with presence of

forests flooded and swamps, mainly due to its ability to penetrate into the vegetation and reflect back the water (Jahncke et al. 2018).

However, despite studies showing the L-band importance for mapping flooded forests (Jahncke et al. 2018), in this study Alos Palsar 1 full-polarimetric L-band image presented maximum proportion correct of 71% in the decision tree classification. This result is close to the 79% proportion correct found by Mleczko et al. (2016) in a full-polarimetric data comparison study using TanDEM-X and Sentinel 1 satellite image data for wetlands mapping.

In addition, our study showed that the Sentinel 1 dual-Pol SAR image showed a proportion correct of 56.1%. This value was similar to that found in the study by Mleczko et al. (2016) which the lowest global accuracy, 65%, was also found in Sentinel 1 images, and were not recommended to map marshes.

The proportion correct difference is also discussed in Li and Chen (2005) study, which looks at C-band limitations, especially when penetrating high-density forest, resulting in a problem detection in these areas. Recognizing Sentinel 1 satellite images importance for wetlands mapping, Muro et al. (2016) emphasize that the application of these images together with other conventional techniques, such as optical images, soil maps and hydrological data, can become an accurate tool for different types of wetlands delineation.

In this study, the integration of Alos Palsar 1 and Sentinel 1 satellite images presented the highest proportion correct, reaching 72%. When analyzing the importance of each polarization to the DT classification, it is noticed that Sentinel 1 contribution is 81%, classifying 621 samples as marsh areas.

The proportion correct found in our study was lower than that verified by Larocque et al. (2014) which reached 94.3% of correctness when evaluated the use of C- and L-bands for wetlands mapping. However, besides C- and L-bands, Larocque et al. (2014) used Landsat 5 TM and digital elevation model (DEM) images and incorporated them into wetlands delimitation rather than vegetation, areas with apparent water presence, which usually have high dielectric constant and result in greater backscatter (Jahncke et al. 2018).

Marsh areas classification spatialization shows that the integration of Alos Palsar 1 and Sentinel 1 images presented the best marsh areas delineation in comparison with each of these images alone. When evaluating multi-frequency X- and C-band data for wetlands delineation, Moser et al. (2016) also verified that the multi-frequency images fusion resulted in the best proportion correct when compared to single frequencies.

Therefore, multi-frequency integration can become an important tool for wetlands mapping. In addition, according to Twele et al. (2016), Sentinel-1 images are generally acquired in (VVVH) polarization in South America, and because of this, it is not possible to achieve the best performance in practice, once studies show that the finest wetlands results are achieved with HH-polarized data. This emphasizes the use of multi-frequency integration in our study area.

However, for marshes, the backscattering of L-band in the (VV) channel is relatively low for the emergent vegetation presence, whereas in (HH) and (VH) channels, backscattering is high (Pope et al. 1997).

Aubert et al. (2013) highlighted that bare soil areas can be distinguished from vegetated areas using Alos Palsar images, and that the integration of L- and C-bands presents an approximate accuracy of 98%. However, in this study, the confusion matrices of the three methods used found that the greatest errors also occurred in the discrimination between marshes and bare soil classes.

As a consequence, SAR images have the capability to become of great importance in wetlands planning and management, since, according to Muro et al. (2016), managers can

easily, through geographic information system (GIS), interpret the change patterns in these areas and use them to locate and delineate high rates areas of change susceptible to high ecological value.

5 Conclusions

The main objective of this study was to develop a method based on multi-frequency radar satellite images to delineate marsh areas using decision tree classification. In order to reach this objective, we sought to answer the following questions: (1) Are L-band SAR images more efficient for marshes delineation than C-band SAR images? (2) Is multi-sensor (L and C-band) integration more accurate for marsh areas delineation than a single sensor? and (3) What are the most efficient channels for marshes delineation?

Therefore, to answer the first questions, our findings concluded that L-band images present greater global accuracy for marshes delineation compared to C-band images, reaching 71% and 56.1% of proportion correct, respectively. In addition, to answer the second question, our results showed that the greatest proportion correct for marshes delimitation was found using the integration between Alos Palsar 1 and Sentinel 1 satellites images, reaching 72% of correctness. Finally, to answer our last question, we concluded that the most important channel in the decision tree classification was Alos Palsar 1 L-band (HVVH), with 39.1% importance, followed by HV channel of Alos Palsar 1 with 33.8% of importance in the DT.

It is important to note that in our study several errors were found across marshes and bare soil classes, which in the future could be improved through other analysis methods such as radar images with optical images and land use cover classifications.

As a consequence, the methodology based on SAR multi-frequency data integration used in this study can be easily applied by other researchers or even wetlands managers, since Alos Palsar 1 and Sentinel 1 images are freely available and can be processed and manipulated in free software, such as SNAP Desktop and QGis.

Funding This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brazil (CAPES) – Finance Code 001.

References

- An, S., & Verhoeven, J. (2019). In A. Shuqing, & T. A. Jos (Eds.), *Wetlands : Ecosystem services, restoration and wise use*, 1st edn. Switzerland: Springer International Publishing. <https://doi.org/10.1007/978-3-030-14861-4>.
- Andrade, N. S. D. O. (2012). *R-99B polarimetric synthetic aperture radar: Analysis and applications*. University of Brasilia. Retrieved from http://repositorio.unb.br/bitstream/10482/10752/1/2012_NiloSergio_deOliveiraAndrade.pdf.
- Aubert, M., Baghdadi, N. N., Zribi, M., Ose, K., El Hajj, M., Vaudour, E., et al. (2013). Toward an operational bare soil moisture mapping using TerraSAR-X data acquired over agricultural areas. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(2), 900–916. <https://doi.org/10.1109/JSTARS.2012.2220124>.
- Ballanti, L., Byrd, K. B., Woo, I., & Ellings, C. (2017). Remote sensing for wetland mapping and historical change detection at the Nisqually River Delta. *Sustainability (Switzerland)*. <https://doi.org/10.3390/su9111919>.

- Betbeder, J., Rapinel, S., Corgne, S., Pottier, E., & Hubert-Moy, L. (2015). TerraSAR-X dual-pol time-series for mapping of wetland vegetation. *Journal of Photogrammetry and Remote Sensing*, 107, 90–98. <https://doi.org/10.1016/j.isprsjprs.2015.05.001>.
- Breiman, L., Friedman, J., Stone, C. J., & Olshen, R. A. (1984). *Classification and regression trees regression trees*. Wadsworth: Belmont, CA (Vol. 14). Oxfordshire: Taylor & Francis. <https://doi.org/10.1002/widm.8>.
- Bwangoy, J.-R. B., Hansen, M. C., Roy, D. P., Grandi, G. De, & Justice, C. O. (2010). Wetland mapping in the Congo Basin using optical and radar remotely sensed data and derived topographical indices. *Remote Sensing of Environment*, 114(1), 73–86. <https://doi.org/10.1016/J.RSE.2009.08.004>.
- Canadian Wetland Inventory Technical Group. (2016). *Canada wetland inventory (data model)*. Stonewall. http://www.ducks.ca/assets/2017/01/CWIDMv7_01_E.pdf.
- Comitê Gravatahy. (2013). *Plano de Recursos Hídricos da Bacia Hidrográfica do Rio Gravataí*, 582. <http://www.comitegravatahy.com.br/index.php/plano-da-bacia>.
- Congalton, R. G. (1991). A review of assessing the accuracy of classifications of remotely sensed data. *Remote Sensing of Environment*, 37(1), 35–46. [https://doi.org/10.1016/0034-4257\(91\)90048-B](https://doi.org/10.1016/0034-4257(91)90048-B).
- Cunha, C. N., Piedade, M. T. F., & Junk, W. J. (2015). *Classificação e Delineamento das Áreas Úmidas Brasileiras e de seus Macrohabitats*. EdUFMT (Vol. 1). Cuiabá. <https://doi.org/10.1017/cbo9781107415324.004>.
- Dabboor, M., & Brisco, B. (2018). Wetland monitoring and mapping using synthetic aperture radar. In *Wetlands management: Assessing risk and sustainable solutions* (Vol. 1, p. 13). London: Intechopen. <http://dx.doi.org/10.5772/intechopen.80224>.
- de Furtado, L. F., Silva, T. S., & de Moraes Novo, E. M. (2016). Dual-season and full-polarimetric C band SAR assessment for vegetation mapping in the Amazon várzea wetlands. *Remote Sensing of Environment*, 174, 212–222. <https://doi.org/10.1016/J.RSE.2015.12.013>.
- Eniolurunda, N. B., Mashi, S. A., & Nsofor, G. N. (2017). Toward achieving a sustainable management: Characterization of land use/land cover in Sokoto Rima floodplain, Nigeria. *Environment, Development and Sustainability*, 19(5), 1855–1878. <https://doi.org/10.1007/s10668-016-9831-6>.
- Fluet-Chouinard, E., Lehner, B., Rebelo, L. M., Papa, F., & Hamilton, S. K. (2015). Development of a global inundation map at high spatial resolution from topographic downscaling of coarse-scale remote sensing data. *Remote Sensing of Environment*, 158(March 2015), 348–361. <https://doi.org/10.1016/j.rse.2014.10.015>.
- Fu, B., Wang, Y., Campbell, A., Li, Y., Zhang, B., Yin, S., et al. (2017). 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*, 73, 105–117. <https://doi.org/10.1016/J.ECOLIND.2016.09.029>.
- Gini, C. (1912). *Variabilità e mutabilità : contributo allo studio delle distribuzioni e delle relazioni statistiche*. Bologna: Archivio Cognetti. <http://archive.digibess.eu/islandora/object/librib:680892#page/10/mode/2up>.
- Guo, M., Li, J., Sheng, C., Xu, J., & Wu, L. (2017). A review of wetland remote sensing. *Sensors (Switzerland)*, 17(4), 1–36. <https://doi.org/10.3390/s17040777>.
- Henderson, F. M., & Lewis, A. J. (2008). Radar detection of wetland ecosystems: A review. *International Journal of Remote Sensing*, 29(20), 5809–5835. <https://doi.org/10.1080/01431160801958405>.
- Jahncke, R., Leblon, B., Bush, P., & LaRocque, A. (2018). Mapping wetlands in Nova Scotia with multi-beam RADARSAT-2 Polarimetric SAR, optical satellite imagery, and Lidar data. *International Journal of Applied Earth Observation and Geoinformation*, 68, 139–156. <https://doi.org/10.1016/J.IJAG.2018.01.012>.
- Johansson, A. M., Brekke, C., Spreen, G., & King, J. A. (2018). X-, C-, and L-band SAR signatures of newly formed sea ice in Arctic leads during winter and spring. *Remote Sensing of Environment*, 204(October 2017), 162–180. <https://doi.org/10.1016/j.rse.2017.10.032>.
- Kandus, P., Minotti, P. G., Morandeira, N. S., Grimson, R., González Trilla, G., González, E. B., et al. (2018). Remote sensing of wetlands in South America: Status and challenges. *International Journal of Remote Sensing*, 39(4), 993–1016. <https://doi.org/10.1080/01431161.2017.1395971>.
- Kaplan, G., & Avdan, U. (2019). Evaluating the utilization of the red edge and radar bands from sentinel sensors for wetland classification. *CATENA*, 178, 109–119. <https://doi.org/10.1016/J.CATENA.2019.03.011>.
- Kaya, E., Agca, M., Adiguzel, F., & Cetin, M. (2018). Spatial data analysis with R programming for environment. *Human and Ecological Risk Assessment*. <https://doi.org/10.1080/10807039.2018.1470896>.
- Kim, S., Hong, S., & Wdowinski, S. (2008). Space-based detection of wetlands' surface water level changes from L-band SAR interferometry. *Remote Sensing of Environment*, 112, 681–696. <https://doi.org/10.1016/j.rse.2007.06.008>.

- Larocque, A., Leblon, B., Woodward, R., Mordini, M., Bourgeau-Chavez, L., Landon, A., et al. (2014). Use of Radarsat-2 and ALOS-PALSAR SAR images for wetland mapping in New Brunswick. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 1, 1226–1229. <https://doi.org/10.1109/IGARSS.2014.6946653>.
- Lawrence, R. L., & Wright, A. (2001). Rule-based classification systems using classification and regression tree (CART) analysis. *Photogrammetric Engineering & Remote Sensing*, 67(10), 1137–1142. [https://doi.org/10.1016/S0034-4257\(01\)00247-4](https://doi.org/10.1016/S0034-4257(01)00247-4).
- Leite, M. G., & Guasselli, L. A. (2013). Spatio-temporal dynamics of aquatic macrophytes in Banhado Grande, Gravataí River basin. *Para Onde!*, 7(1), 17–24.
- Li, J., & Chen, W. (2005). A rule-based method for mapping Canada's wetlands using optical, radar and DEM data. *International Journal of Remote Sensing*, 26(22), 5051–5069. <https://doi.org/10.1080/01431160500166516>.
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., Brisco, B., Mahdavi, S., Amani, M., et al. (2018). Fisher linear discriminant analysis of coherency matrix for wetland classification using PolSAR imagery. *Remote Sensing of Environment*, 206(January 2017), 300–317. <https://doi.org/10.1016/j.rse.2017.11.005>.
- Mahdianpari, M., Salehi, B., Mohammadimanesh, F., & Motagh, M. (2017). Random forest wetland classification using ALOS-2 L-band, RADARSAT-2 C-band, and TerraSAR-X imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 130, 13–31. <https://doi.org/10.1016/j.isprsjprs.2017.05.010>.
- Mitsch, W. J., Bernal, B., Nahlik, A. M., Mander, Ü., Zhang, L., Anderson, C. J., et al. (2013). Wetlands, carbon, and climate change. *Landscape Ecology*, 28(4), 583–597. <https://doi.org/10.1007/s10980-012-9758-8>.
- Mleczko, M., & Mróz, M. (2018). Wetland mapping using SAR data from the Sentinel-1A and Tandem-X missions: A comparative study in the Biebrza floodplain (Poland). *Remote Sensing*, 10(2), 78. <https://doi.org/10.3390/rs10010078>.
- Mleczko, M., Mroż, M., & Fitzyk, M. (2016). Wetland mapping with Sar/quad-pol data acquired during Tandem-X Science Phase. In *The international archives of the photogrammetry, remote sensing and spatial information sciences* (pp. 809–813), Prague. <https://doi.org/10.5194/isprsaarchives-xli-b7-809-2016>.
- Mohammadimanesh, F., Salehi, B., Mahdianpari, M., Brisco, B., & Motagh, M. (2018). Multi-temporal, multi-frequency, and multi-polarization coherence and SAR backscatter analysis of wetlands. *ISPRS Journal of Photogrammetry and Remote Sensing*. <https://doi.org/10.1016/j.isprsjprs.2018.05.009>.
- Morandeira, N., Grings, F., Facchinetto, C., Kandus, P., Morandeira, N. S., Grings, F., et al. (2016). Mapping plant functional types in floodplain wetlands: An analysis of C-band polarimetric SAR data from RADARSAT-2. *Remote Sensing*, 8(3), 174. <https://doi.org/10.3390/rs8030174>.
- Moser, L., Schmitt, A., Wendleder, A., & Roth, A. (2016). Monitoring of the Lac Bam Wetland extent using dual-polarized X-band SAR data. *Remote Sensing*, 8(4), 302. <https://doi.org/10.3390/rs8040302>.
- Muro, J., Carty, M., Conradsen, K., Hüttich, C., Nielsen, A. A., Skriver, H., et al. (2016). Short-term change detection in wetlands using Sentinel-1 time series. *Remote Sensing Article*, 8(775), 1–14. <https://doi.org/10.3390/rs8100795>.
- Pontius, R. G., & Millones, M. (2011). Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32(15), 4407–4429. <https://doi.org/10.1080/01431161.2011.552923>.
- Pope, K. O., Rejmánková, E., Paris, J. F., & Woodruff, R. (1997). Detecting seasonal flooding cycles in marshes of the Yucatan Peninsula with SIR-C polarimetric radar imagery. *Remote Sensing of Environment*, 59(2), 157–166. [https://doi.org/10.1016/S0034-4257\(96\)00151-4](https://doi.org/10.1016/S0034-4257(96)00151-4).
- Ramos, R. A., Pasqualeto, A. I., Balbuena, R. A., Quadros, E. L. L. de, & das Neves, D. D. (2014). Mapeamento e diagnóstico de áreas úmidas no Rio Grande do Sul, com o uso de ferramentas de geoprocessamento. In *Anais do Simposio de Áreas Protegidas* (pp. 17–21), Viçosa.
- Roushangar, K., Alizadeh, F., & Adamowski, J. (2018). Exploring the effects of climatic variables on monthly precipitation variation using a continuous wavelet-based multiscale entropy approach. *Environmental Research*, 165, 176–192. <https://doi.org/10.1016/J.ENVRES.2018.04.017>.
- Saha, T. K., & Pal, S. (2018). Emerging conflict between agriculture extension and physical existence of wetland in post-dam period in Atreyee River basin of Indo-Bangladesh. *Environment, Development and Sustainability*. <https://doi.org/10.1007/s10668-018-0099-x>.
- Silveira, M., & Heleno, S. (2009). Separation between water and land in SAR images using region-based level sets. *IEEE Geoscience and Remote Sensing Letters*, 6(3), 471–475. <https://doi.org/10.1109/LGRS.2009.2017283>.

- Simioni, J. P. D., Guasselli, L. A., & Etchelar, C. B. (2017). Connectivity among Wetlands of EPA of Banhado Grande, RS Conetividade entre Áreas Úmidas, APA do Banhado Grande, RS. *Brazilian Journal of Water Resources*, 22, 15. <https://doi.org/10.1590/2318-0331.011716096>.
- Simioni, J. P. D., Nascimento, V. F., Guasselli, L. A., Ruiz, L. F. C., & De Oliveira, G. (2018). Small inner marsh area delimitation using remote sensing spectral indexes and decision tree method in southern Brazil. *Revista de Teledetección*, 52, 55. <https://doi.org/10.4995/raet.2018.10366>.
- Twele, A., Cao, W., Plank, S., & Martinis, S. (2016). Sentinel-1-based flood mapping: A fully automated processing chain. *International Journal of Remote Sensing*, 37(13), 2990–3004. <https://doi.org/10.1080/01431161.2016.1192304>.
- Waheed, T., Bonnell, R. B., Prasher, S. O., & Paulet, E. (2006). Measuring performance in precision agriculture: CART-A decision tree approach. *Agricultural Water Management*, 84(1–2), 173–185. <https://doi.org/10.1016/j.agwat.2005.12.003>.
- Wang, Y., Yésou, H., Wang, Y., & Yésou, H. (2018). Remote sensing of Floodpath Lakes and wetlands: A challenging frontier in the monitoring of changing environments. *Remote Sensing*, 10(12), 1955. <https://doi.org/10.3390/rs10121955>.
- Wentao-Lv, W., Qiuze-Yu, Q., & Wenxian-Yu, W. (2010). Water extraction in SAR images using GLCM and support vector machine. In *IEEE 10th international conference on signal processing proceedings* (pp. 740–743), IEEE. <https://doi.org/10.1109/icosp.2010.5655766>.
- White, L., Brisco, B., Dabboor, M., Schmitt, A., Pratt, A., White, L., et al. (2015). A collection of SAR methodologies for monitoring wetlands. *Remote Sensing*, 7(6), 7615–7645. <https://doi.org/10.3390/rs70607615>.

Publisher's Note Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.



ORIGINAL PAPER

A comparison of data mining techniques and multi-sensor analysis for inland marshes delineation

Joao P. D. Simioni · Laurindo A. Guasselli · Guilherme G. de Oliveira · Luis F. C. Ruiz · Gabriel de Oliveira

Received: 30 October 2018 / Accepted: 29 May 2020
© Springer Nature B.V. 2020

Abstract Inland Marsh (IM) is a type of wetland characterized by the presence of non-woody plants as grasses, reeds or sedges, with a water surface smaller than 25% of the area. Historically, these areas have been suffering impacts related to pollution by urban, industrial and agrochemical waste, as well as drainage for agriculture. The IM delineation allows to understand the vegetation and hydrodynamic dynamics and also to monitor the degradation caused by human-induced activities. This work aimed to compare four machine learning algorithms (classification and regression tree (CART), artificial neural network (ANN), random forest (RF), and k-nearest neighbors (k-NN)) using active and passive remote sensing data in order to address the following questions: (1) which of the four machine learning methods has the greatest potential for inland marshes delineation? (2) are SAR features more important for inland marshes delineation than optical features? and (3) what are the most accurate classification parameters for inland marshes

delineation? To address these questions, we used data from Sentinel 1A and Alos Palsar I (SAR) and Sentinel 2A (optical) sensors, in a geographic object-based image analysis (GEOBIA) approach. In addition, we performed a vectorization of a 1975 Brazilian Army topographic chart (first official document presenting marsh boundaries) in order to quantify the marsh area losses between 1975 and 2018 by comparing it with a Sentinel 2A image. Our results showed that the method with the highest overall accuracy was k-NN, with 98.5%. The accuracies for the RF, ANN, and CART methods were 98.3%, 96.0% and 95.5%, respectively. The four classifiers presented accuracies exceeding 95%, showing that all methods have potential for inland marsh delineation. However, we note that the classification results have a great dependence on the input layers. Regarding the importance of the features, SAR images were more important in RF and ANN models, especially in the HV, HV + VH and VH channels of the Alos Palsar I L-band satellite, while spectral indices from optical images were more important in the marshes delineation with the CART method. In addition, we found that the CART and ANN methods presented the largest variations of the overall accuracy (OA) in relation to the different parameters tested. The multi-sensor approach was critical for the high OA values found in the IM delineation ($> 95\%$). The four machine learning methods can be accurately applied for IM delineation, acting as an important low-cost tool for monitoring and managing these environments,

J. P. D. Simioni (✉) · L. A. Guasselli ·
G. G. de Oliveira · L. F. C. Ruiz
Center for Remote Sensing and Meteorology, Federal
University of Rio Grande Do Sul, 9500 Bento Goncalves
Av., Porto Alegre, RS 91501-970, Brazil
e-mail: joao.delapasse@ufrgs.br

G. de Oliveira
Department of Geography and Planning, 100 Saint George
St, Toronto, ON M5S 3G3, Canada

in the face of advances in agriculture, soil degradation and pollution of water resources due to agrochemical dumping.

Keywords Machine learning · GEOBIA · Image classification · Wetlands

Introduction

Wetlands are ecosystems at the interface between aquatic and terrestrial environments; they may be continental or coastal, natural or artificial, permanently or periodically inundated by shallow water or consist of waterlogged soils (Junk et al. 2014). Wetlands have high biodiversity, playing an important role in maintaining/improving water quality, flood mitigation, aquifer recharge (Cowardin et al. 1979), microclimate regulation (Şimşek and Ödül 2018) and carbon sequestration (Mitsch et al. 2013). Wetlands can be classified as swamp, fen, bog, wet meadow and shallow water (Jahncke et al. 2018). Inland marshes are wetland types characterized by the presence of non-woody plants as grasses, reeds or sedges (Neiff et al. 2002; Keddy 2008). Due to the high accumulation of organic matter in these environments, it is possible to observe the formation of peatland layers or soils rich in organic matter (Sasser et al. 2017).

The delineation of inland marshes allows to understand the hydrodynamic patterns and also to monitor the development of agriculture over these areas (Junk et al. 2014). Although public awareness of wetland conservation has increased in the past few decades (Brock et al. 1999; Mui et al. 2015), the degradation of these areas has increased significantly. In the state of Rio Grande do Sul, southern Brazil, marsh areas are considered permanent preservation areas by legislation. However, there are no accurate inventories or mapping of the marsh areas located in the state. Due to conversion to agricultural areas, urbanization and waste disposal, important marsh areas have been extensively degraded in Rio Grande do Sul (Brenner 2016; Silva 2016).

The advance of geographic information systems has led to the improvement of methods used for the classification of remotely sensed images (França and Amaral 2013; Girolamo Neto 2014; Neves 2015). Remote sensing has an important role in the

delineation of wetlands in regional scale (Karlson et al. 2019). The improved spatial, temporal, spectral and radiometric resolutions of optical sensors, especially Landsat 8 Operational Land Imager (OLI) and Sentinel 2 Multispectral Instrument (MSI) satellites, allows the development of strategies for continuous monitoring of vegetation patterns, water level oscillation and loss and degradation in wetlands (Sánchez-espinosa and Schröder 2019).

In the past few years, Synthetic Aperture Radar (SAR) sensors have been increasingly used for delineation and monitoring different wetland ecosystems in South America (Kandus et al. 2018), such as the Amazon river floodplain (Ferreira-Ferreira et al. 2015; Furtado et al. 2016; Pereira et al. 2018), the Brazilian Pantanal floodplain (Evans et al. 2010, 2014), the Paraná River floodplain (Morandeira et al. 2016; Gayol et al. 2019), and inland marshes areas (Grimson et al. 2019; Simioni et al. 2019).

SAR images have advantages in delineation of wetlands in comparison with optical images (White et al. 2015; Dabboor and Brisco 2018). SAR microwaves can collect data at day or night, and are able to penetrate through clouds and interact three-dimensionally with vegetation, detecting canopy structural characteristics and soil moisture (Morandeira et al. 2016; Pereira et al. 2018).

There are many SAR sensors, with different spatial resolutions, polarizations and wavelengths (Mahdianpari et al. 2017). The use of X (2.43–3.75 cm) and C (3.75–7.5 cm) bands are preferable for mapping herbaceous, less dense wetlands, and the L-band (15–30 cm) is indicated for mapping woody wetlands such as swamps and other high biomass wetlands (Dabboor and Brisco 2018).

With the wide range of satellite imagery available lately, different methods and techniques allow to delineate and classify wetlands with high accuracy. Geographic Object-Based Image Analysis (GEOBIA) offers a promising framework for segmenting landscapes into heterogeneous wetlands. The main benefits of GEOBIA in relation to pixel-based methods include: (1) the possibility of incorporating the shape, texture and any relevant contextual variables of the object into the classification, (2) to soften part of the local variation within the objects, which can reduce the speckle noise and increase the accuracy of the classification; and (3) to explain the landscape hierarchy, different land cover types and ecosystem

structure, by using multiple layers of objects at different spatial scales (Blaschke et al. 2014). Dronova (2015) states that there is an increase in precision using GEOBIA when compared to pixel-based approaches. Kamal and Phinn (2011) found a difference of $\sim 20\%$ between GEOBIA and pixel-based approaches.

Another method that has been widely used in recent years is the knowledge discovery in database (KDD), an exploratory automatic data analysis, designed to identify and to organize spatial patterns from large and complex remote sensing data sets (Maimon and Rokach 2005). One of KDD main steps is data mining (DM), a classification process used to identify patterns and to establish relationships within large data sets (Hand 2007). DM comprises a set of methods and algorithms with different usability and accuracy. Among them, we highlight the artificial neural networks (ANN), k-nearest neighbors (k-NN), classification and regression tree (CART), and random forest (RF) methods (Behrens and Scholten 2007). These algorithms have been successfully applied to delineate and classify different wetlands types. Bao and Ren (2011) applied ANN to classify the landscape heterogeneity in a wetland in DaLinor Lake and Van Beijma et al. (2014) applied RF to classify the vegetation in a salt marsh in Llanrhidian salt marshes, both with accuracy greater than 90%. RF is widely applied in studies to map wetlands with GEOBIA because of its ability to handle large datasets from different sources and the ability to evaluate the importance of features (Mahdianpari et al. 2017). The combination of multiple sources was a determining factor for the high accuracy ($> 93\%$ and $> 94\%$) observed by Silva et al. (2010), which used GEOBIA to map seasonal changes in aquatic macrophyte cover, and by Dubeau et al. (2017), which mapped wetlands using optical data, SAR and a Digital Elevation Model (DEM), respectively. By using DEM, SAR, and optical imaging data separately, Dubeau et al. (2017) found that the OA decreased to 89%. Wang et al. (2019) applied different DM methods to classify land cover in a coastal wetland in Linhong River Estuary Wetland with accuracy of 86.6% with RF and 77.2% with the k-NN method. Baker et al. (2006), using CART, obtained 73.1% accuracy in the mapping of wetlands and riparian areas in Gallatin River watershed, USA.

Although the integration between multi-sensor analysis, GEOBIA and data mining techniques for

wetlands mapping has been well discussed in the literature (Belluco et al. 2006; Silva et al. 2010; Van Beijma et al. 2014; Walsh et al. 2014; Wester et al. 2018; Wang et al. 2019), this is the first study to apply these methods to map inland marshes. We hypothesize that the multi-sensor approach of the Sentinel-1 and Sentinel-2 satellites may have a high potential to discriminate the vegetation of wetlands.

Based on the consideration above, this work aimed to compare four machine learning algorithms (classification and regression tree (CART), artificial neural network (ANN), random forest (RF), and k-nearest neighbors (k-NN)) using active and passive remote sensing data in order to address the following questions: (1) which of the four machine learning methods has the greatest potential for inland marshes delineation? (2) are SAR features more important for inland marshes delineation than optical features? and (3) what are the most accurate classification parameters for inland marshes delineation? To address these questions, we used data from Sentinel 1A and Alos Palsar I (SAR) and Sentinel 2A (optical) sensors, in a geographic object-based image analysis (GEOBIA) approach. In addition, we performed a vectorization of a 1975 Brazilian Army topographic chart (first official document presenting marsh boundaries) to quantify marsh area losses between 1975 and 2018.

Methodology

Study area

The Banhado Grande (BG) marsh ($29^{\circ}57' S$, $50^{\circ}41' W$) is located within the Gravataí river basin, state of Rio Grande do Sul, Brazil. The BG is a marsh remnant in a predominantly agricultural landscape, with an original area of 5,591 ha (Geographic Service Directorate 1975; Ramos et al. 2014) and it is included in the Banhado Grande System (BGS) wetlands complex. The BGS is an extensive mosaic of wetlands, which is formed by marshes, wet meadow (WM) and rice crops (RC). The BGS is delimited by a 20-m altimeter quota (Fig. 1).

In large flood pulses, the area comprised by the BGS floods, connecting different small inner marshes (Leite and Guasselli 2013; Simioni et al. 2017). The connectivity established during flood pulses is

responsible for large amounts of nutrient and sediment exchanges between wetlands.

The mean annual precipitation varies between 1500 mm and 1700 mm. August has the highest mean precipitation (140 mm) and April has the lowest (86 mm). The average annual temperature varies between 17 and 20 °C. In the hottest month, January, the average temperature oscillates between 23 and 26 °C, and in the coldest month, July, it oscillates between 11 and 14 °C.

Most of the vegetation in the BG is basically composed of three large compartments, (i) *Cyperaceae*s of the genus *Scirpus*; (ii) *Pontederiaceae*s of the genus *Eichhornia*, and (iii) transition vegetation, characterized by diverse macrophytes, grasses and shrubby. Plants of the *Scirpus* genus are characterized by dense vegetation, ranging from 1.5 to 2.5 m above the water level and cover about 28% of the BG area, and do not show significant seasonal differences, given the high leaf turnover, with continuous growth and appearance of new green leaves even during the winter months (Leite and Guasselli 2013). *Eichhornia* plants have seasonal variability regulated by flood pulses, have an average height between 10 and 16 cm and cover approximately 15% of the BG area (Leite and Guasselli 2013). The other 57% of the BG area consists of open water and transitional vegetation, characterized by diverse macrophytes, grasses and shrubby (Leite and Guasselli 2013). The BG marsh presents rice crops and wet meadow areas within its limits (Ramos et al. 2014). In addition to the marsh samples, we also collected samples for rice crop and wet meadow. The dominant species in each of the classes are described in Table 1.

Image processing

The satellite images were obtained from three sensors: Alos Palsar (Phased Array L-band Synthetic Aperture Radar) 1 L-band, Sentinel 1a C-band (level Ground Range Detected—GRD) and Sentinel 2a Multispectral Instrument with preprocessing level 1C (Table 2). Both Alos Palsar 1 L-band and Sentinel 1a C-band images were obtaining from the Alaska Satellite Facility website (www.vertex.daac.asf.alaska.edu). The Also Palsar I satellite collected data from 2006 and 2011, the image from 12/05/2011 is the only full-polarimetric image collected in the study area. We understand that different dates used in the study may

interfere in the results, however there have been studies showing the efficacy of Alos Palsar I L-band to map marshes (Simioni et al. 2019). To minimize this problem, we used images with same day and month to the Alos Palsar I image acquisition. These images have full and dual-polarization, with L and C bands multi-frequencies. The Sentinel 2a MSI images were obtained from the Copernicus Program website (www.scihub.copernicus.eu).

For the synthetic aperture radar (SAR) images, we first conducted a radiometric calibration (RC), which is required to compare SAR images obtained with different sensors or same sensor at different times. The radiometric calibration corrects the pixel values in order to truly represent the backscatter of the imaged surface, so the values were converted to intensity. The speckle noise causes the cancellation (destructive interference) or the sum of the signal (interference), generating images with a “salt and pepper” effect. To mitigate this effect, the Lee sigma filter was applied, with a 5 × 5 movable window (Furtado et al. 2016). Due to the lateral geometry of the SAR image, the generated image is mapped in the inclined plane (Slant Range Domain). For the Sentinel 1a C-band image, we applied a terrain correction in order to convert the image from the inclined plane to the ground level (Ground Range Geometry) and then defined a cartographic system. For the terrain correction, altimetry images from the Shuttle Radar Topography Mission (SRTM) were used, with spatial resolution of 30 m and the Mercator Transverse Universe (UTM) projection system, spindle 22, southern hemisphere and horizontal datum SIRGAS 2000.

For the Sentinel 2a MSI satellite images, we first performed the atmospheric correction and transformation of radiance to reflectance by using the *sen2cor* tool (Kaplan and Avdan 2017). Then, the bands 11 and 12 of Sentinel 2a were resampled from 20 to 10 m by the bilinear interpolation method (Zhou et al. 2003). To calculate the spectral indices we used the bands B3 (green), B4 (red), B8 (NIR), B11 (SWIR 1) and B12 (SWIR 2). Since we have extracted these spectral indices from the Sentinel 2a images, we did not use the bands 1, 5, 6, 7, 8A, 9 and 10.

RC and refined Lee filter processing of the SAR images and atmospheric correction of Sentinel 2a magnets were performed on the SNAP desktop software. After pre-processing the images, we obtained 29 features: 16 from vegetation, soil and

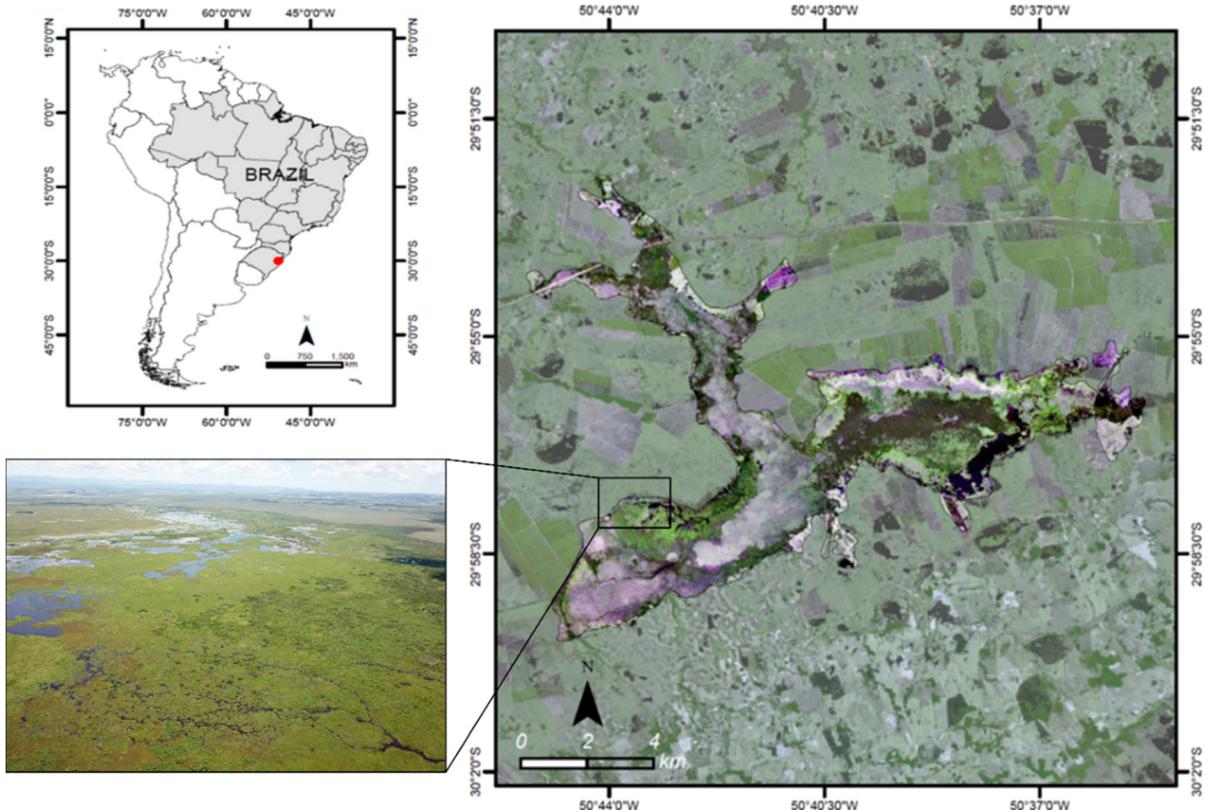


Fig. 1 Localization of the Banhado Grande (BG) marsh

Table 1 Orbital sensors used in the study

Date	Sensor	Polarization	Resolution (m)	Path/Frame	Frequency
12/05/2011	Alos Palsar 1	Quad-Pol	12.5	67/6590	L-band
12/04/2018	Sentinel 1a	VV + VH	10.0	66/78,211	C-band
12/07/2018	Sentinel 2a MSI	–	10.0	14,621/38	–

water indexes (Sentinel 2a image) and 13 from polarimetric channels (Sentinel 1a and Alos Palsar 1 images) (Table 3).

In addition, we performed the BG boundary vectorization using the 1:50,000 scale Brazilian Army topographic map (Geographic Service Directorate 1975) to quantify the loss of marsh area between 1975 and 2018. The topographic map was performed from surveys and fieldwork, and is the first official document presenting the BG limits.

Reference samples

The reference samples were collected by two methods. First, we collected 450 samples of the wet meadow

and rice crop samples from fieldwork that took place between 12/01/2018 to 12/04/2018. To collect the samples, two Global Navigation Satellite System (GNSS) Ruide R90-X dual-frequency (L1/L2) receivers were used. The receiver's integrated GSM/GPRS modem enables the use of Networked Transport of RTCM via Internet Protocol (NTRIP) technology, which uses TOA-IP protocol to send GNSS receivers Real-time Kinematics (RTK) data. The reference base was the Brazilian Continuous Monitoring Network (BCMN) located in Porto Alegre, RS. Then, inland marshes, wet meadow and rice crops samples were collected by visual interpretation of World View 2 satellite images obtained on 12/08/2018. The multi-spectral resolution of the images is 2.0 m and the

Table 2 Indexes and polarizations used in the study

Index	Equation	Author(s)
<i>Optical</i>		
Weighted Difference Vegetation Index	$WDVI = (B8 - g*B4)$	Clevers et al. (1989)
Soil Adjusted Vegetation Index	$SAVI = (((1 + L)*(B8-B4))/((B8 + B4 + L)))$	Huete (1988)
Transformed Normalized Difference Vegetation Index	$TNDVI = \sqrt{((NDVI + 0.5))}$	Deering (1975)
Brightness Index	$BI = \sqrt{(((2*B4) + (2*B3))/2)}$	Escadafal (1989)
Brightness Index 2	$BI_2 = \sqrt{(((2*B4) + (2*B3) + (2*B8))/3)}$	Escadafal (1989)
Ratio Vegetation Index	$RVI = (B4/B8)$	Pearson and Miller (1972)
Normalized Difference Water Index	$NDWI = ((B8 - B11)/(B8 + B11))$	Gao (1996)
Normalized Difference Water Index 2	$NDWI_2 = ((B3 - B8)/(B3 + B8))$	McFeeters (1996)
Normalized Difference Vegetation Index	$NDVI = ((B8-B4)/(B8 + B4))$	Rouse et al. (1973)
Normalized Difference Turbidity Index	$NDTI = ((B4 - B3))/(B4 + B3))$	Lacaux et al. (2007)
Normalized Difference Pond Index	$NDPI = ((B3-B11*B12)/(B3 + B11*B12))$	Lacaux et al. (2007)
Normalized Difference Index	$NDI45 = ((B5 - B4)/(B5 + B4))$	Delegido et al. (2011)
Modified Normalized Difference Water Index	$MNDWI = ((B3-B11)/(B3 + B11))$	Xu (2007)
Green Normalized Difference Vegetation Index	$GNDVI = ((B8 - B3)/(B8 + B3))$	Gitelson et al. (1996)
Difference Vegetation Index	$DVI = (B8 - B4)$	Richardson and Wiegand (1977)
Atmospherically Resistant Vegetation Index	$ARVI = (((B8 - rb))/(B8 + rb))$	Kaufman and Tanre (1992)
<i>Polarization</i>		Satellite
<i>SAR</i>		
VV, VH and VV + VH	Sentinel 1a	C
VV, VH, HH and HV	Alos Palsar 1	L
VV + VH, VV + HH, and VV + HV	Alos Palsar 1	L
VH + HH and VH + HV	Alos Palsar 1	L
HH + HV	Alos Palsar 1	L

radiometric resolution is 11 bits. The visual interpretation of the World View 2 images was due to the impossibility of access to BG.

Segmentation

The segmentation was done through the object-based geographic analysis (GEOBIA), which segments the image in objects, which are groups of pixels representing homogeneous areas, entities or their (primitive) elements. These segments can then be classified into different categories by unsupervised, supervised or rule-based algorithms (Dronova 2015; Jones et al. 2018).

The segmentation was performed using the bands 2 (blue), 3 (green), 4 (red), 8 (near-infrared), 11 (Short-wave infrared SWIR) and 12 (SWIR) of Sentinel 2a MSI, and the channels VV and VH of Sentinel 1A, both with 10 m spatial resolution. We opted for the joint segmentation of SAR and optical images, because the joint analysis has shown better results compared to a sensor only (Macrì-Pellizzeri et al. 2002). For segmentation, we used the region-growth algorithm (Happ et al. 2013). The region-growth segmentation brings together adjacent pixels that meet a given heterogeneity criterion. Thus, the regions of the image are grouped or divided depending on whether the pixels have similar characteristics in terms of color, texture or shape. The region

Table 3 Dominant species for each class

Class	Dominant species/typology
Inland Marsh (IM)	Eichhornia crassipes, Eichhornia azurea, Salvinia auriculata, Hydrochleis nymphoides, Leersia sp., Cabomba australis, Leersia sp., Pontederia lanceolata, Nymphoides sp., Hygrophila sp., Polygonum spp., Myriophyllum brasiliensis, Scirpus sp., Cyperus sp., Zizaniopsis sp., Eryngium pandanifolium sp.
Wet Meadow (WM)	Erianthus sp., Andropogon bicornis, Sida sp., Mimosa bimucronata, Panicum prionitis, grasses and shrubby
Rice Crops (RC)	Rice cultivation (<i>Oryza sativa</i>)

segmentation started with the launch of seed pixels from previously defined samples. It was obtaining 1,000 samples for each class analyzed (inland marshes, wet meadow and rice crop).

The region-growth algorithm is controlled by the similarity threshold (ST). Values from 0 to 1 were tested. High ST values mean higher freedom for growth of the regions (geographic objects) and vice versa. In addition, we evaluated the minimum number of cells (MNC), which determines the minimum size of the geographic objects. Low MNC values mean smaller geographic-objects generated by the segmentation. We tested MNC values between 200 and 600, varying by 200.

In order to incorporate the collected samples into the segmentation polygons, we performed the union of attributes by geographic location, through the spatial join plugin of QGis 3.4 Madeira. The segmentation was performed in the QGis 3.4 software, through the Geopatterns plugin (Ruiz 2019). Sample distribution ensured that no spatial object spanned more than one sampling point.

Classification and validation

In order to define the training and validation samples, 1000 points were generated on each of the three classes (inland marshes, wet meadow and rice crops), totaling 3000 samples. We used 80% of the samples for training and 20% for validation. The sampling and validation samples were randomly separated by the Geopatterns plugin, in the QGIS software 3.4. The accuracy of the classification was measured by the following indexes: (1) overall accuracy (OA) (Pontius and Millones 2011), (2) producer's accuracy (PA), and (3) user's accuracy (UA) (Story and Congalton 1986). The following non-parametric methods were used for

classification: (1) classification and regression tree (CART), (2) artificial neural network (ANN), (3) random forest (RF), and (4) k-nearest neighbors (k-NN). The CART, RF and k-NN algorithms were applied based on the classification tool from the Geopatterns plugin (Ruiz 2019), and the ANN was applied in the MATLAB R2012b (MathWorks) software.

Classification and regression tree (CART)

The CART method uses the binary recursive partitioning analysis for class discrimination, in which each parent node is divided into two child nodes (Breiman et al. 1984; Lawrence and Wright 2001). The process is repeated by treating each child node as a parent node. When data from a node cannot be divided into additional nodes, it is called the terminal node. Once the first terminal node has been created, the algorithm repeats the procedure for each data set until all data are categorized as terminal nodes (Waheed et al. 2006).

The sample values 3, 5, 10, 15, 20, 25 and 30 were evaluated for tree depth and the values 8, 20, 40, 60, 80, 100 and 120 for the maximum number of samples at child nodes. The gini index (Rokach and Maimon 2005) was used as a measure of impurity of tree branches. The gini index measures the degree of heterogeneity of the data, searches the largest category in the data set (i.e., inland marsh) and tries to isolate it from other categories (Waheed et al. 2006).

The index of a node is given by Eq. 1:

$$Gini = 1 - \sum_{i=1}^c p_i^2 \quad (1)$$

where p_i is the relative frequency of each class in each node, and c is the number of classes (in this case, 3).

Artificial neural network (ANN)

The ANN is a structured group of processing units, called artificial neurons, which comprises a mathematical model capable to approach complex relationships within data sets. Each neuron in the network can receive input signals, process them and send an output signal (Fantin-Cruz et al. 2011).

The ANN training was performed by the multi-layered backpropagation method (Rumelhart et al. 1986) and the updating of the synaptic weights and internal connections of the network was done through the delta rule (Gurney 1997). The values of the input attributes were scaled from linear transformations according the Eq. 2:

$$\frac{(y_t - p_o)}{s_o} = ANN \left(\frac{(x_t - p_i)}{s_i} \right) \quad (2)$$

where x_t and y_t are the input and output variables, respectively, s_o and p_o are the scale and position parameters of the model outputs, and s_i and p_i are the scale and position parameters of the model inputs.

Several model configurations were tested, varying the number of neurons in the hidden layer of the network. The activation function used in both layers of the model was the sigmoidal. The output of the model was calculated from the function presented in Eq. 3:

$$ANN \left(\frac{(x_t - p_i)}{s_i} \right) = f_o \left(\sum_h w_{oh} \left(\sum_i w_h \left(\frac{x_t - p_i}{s_i} \right) + b_h \right) + b_o \right) + e_o \quad (3)$$

where w_h , b_h , f_h , w_o , b_o and f_o are the synaptic weights (w), biases (b) and activation functions (f), respectively, of the hidden (h) and output (o) layers, while e_o is the expected error in the output layer.

Once the weights initialization is random, we executed 30 iterations for each model configuration. At each iteration, a maximum number of learning cycles for training interruption was defined if the model did not reach the convergence threshold. After several tests, the number of 15,000 cycles was defined, since it was sufficient to achieve an ideal fit for the synaptic weights. The training and calibration parts were separated for an internal cross-validation process in order to avoid the model overfitting. The relevance of the input attributes of the model was quantified by the relative contribution (RC) index (Oliveira et al. 2015).

Random forest (RF)

The RF is an ensemble classifier, which is comprised by a decision tree set $\{h(X, v_k), k, 1, \dots\}$, in which v_k are independently sampled random vectors equally distributed in all the trees of the forest (Breiman 2001). The RF method can produce multiple decision trees by using a subset of samples and training variables. The result of the classification process is the X class, with the highest number of votes among all trees (Han et al. 2012).

After the forest formation, there are many decision trees to be tested and all contribute for the classification of the object under study by choosing which class the target attribute should belong to. The RF defines its decision by counting the votes of the predictor components in each class and then selecting the winning class in terms of the number of votes accumulated (Han et al. 2012).

The number of trees and their maximum depth can be adjusted. We evaluated the values between 5 and 50 for both parameters. As a criterion of division it was used the gini index.

k-nearest neighbors (k-NN)

The k-NN is a supervised classification method based on the proximity of its neighbors in a sample space (Mazzillo JR and Anzanello 2015). The aim of k-NN is to form a generalization that is based on a training set, maximizing the accuracy of the classification (Han et al. 2012). The parameter k controls the number of neighbors to be analyzed. The k-NN values were defined from the following distances: Manhattan (power = 1), Euclidean (power = 2) and Chebyshev (power = 3).

Results

Model calibrations

The highest OA for the CART method (95.5%) was obtained considering a MNC of 400, a maximum depth of 10 and a number of child nodes of 20 (Fig. 2). As we increase the number of child nodes, the OA decreases. For the CART method, the smallest OA values (90%) were found considering a number of child nodes of 120 and a maximum depth of 10. For the

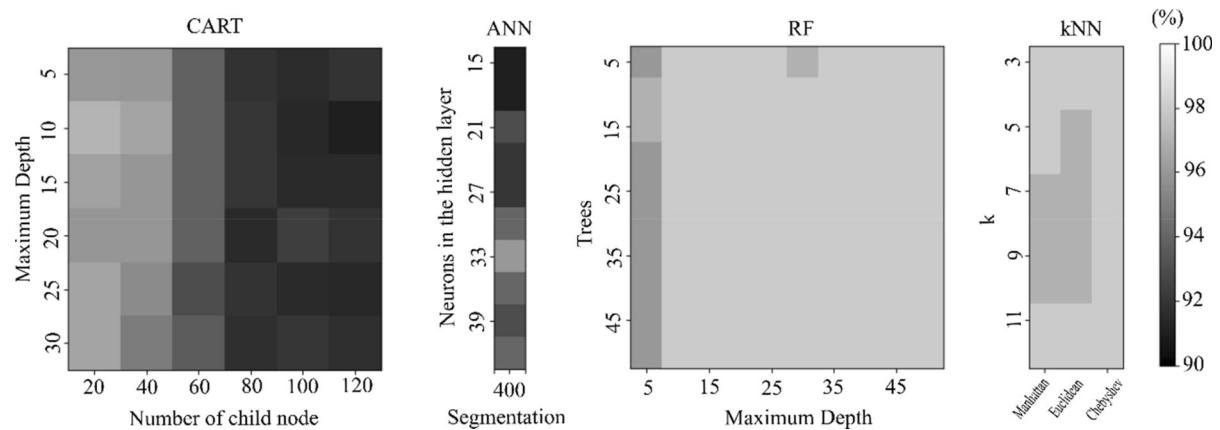
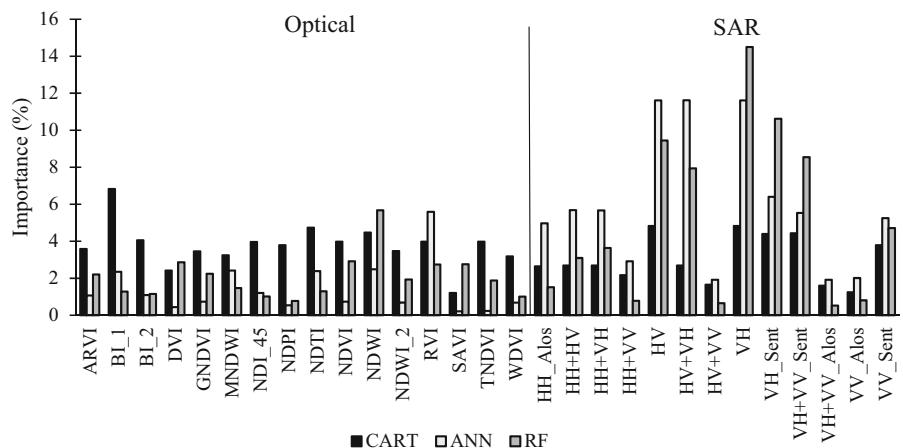


Fig. 2 Correct Proportion (CP) of each method: CART, ANN, RF, and k-NN

Fig. 3 Importance of the layers for CART, ANN and RF classifiers



ANN method, the highest OA (96%) was obtained with a MNC of 400 a number of neurons in the hidden layer equal to 33. As in the CART method, the lowest OA value for ANN was 90%. The RF presented the highest OA values (96%-98.2%) considering a MNC equal to 600. The k-NN presented the highest OA variations (96.5%-98.4%) by using the Chebyshev metric. In this metric, the distance between two vectors is the largest of their differences along any dimension.

Layer importance and mapping

The importance of the layers in the classifications is presented in Fig. 3. The optical images were more relevant only in the CART method. The ANN and RF methods presented a similarity in the importance of the layers, with greater relevance for SAR images. In the

ANN, the highest importance was for the HV, VH and HV + VH channels, of about 11.6%. The highest importance for ANN using optical images were observed in the RVI index. For the SAR images, the greatest importance was obtained by using the VH channel of Alos Palsar I through the RF method (14.5%). For the optical images, the greatest importance was obtained by using the NDWI index through the RF method (5.7%).

In Fig. 4, we observe that the CART, ANN, RF and k-NN methods classified, respectively, 69.3%, 77.2%, 68.9%, and 71.9% of BG as IM. The ANN presented more homogeneous IM areas in the central portion of BG in comparison with the other methods. The RF method presented the smallest IM area and the largest RC area among the analyzed methods. The k-NN classified more RC fragmented areas inside IM zones.

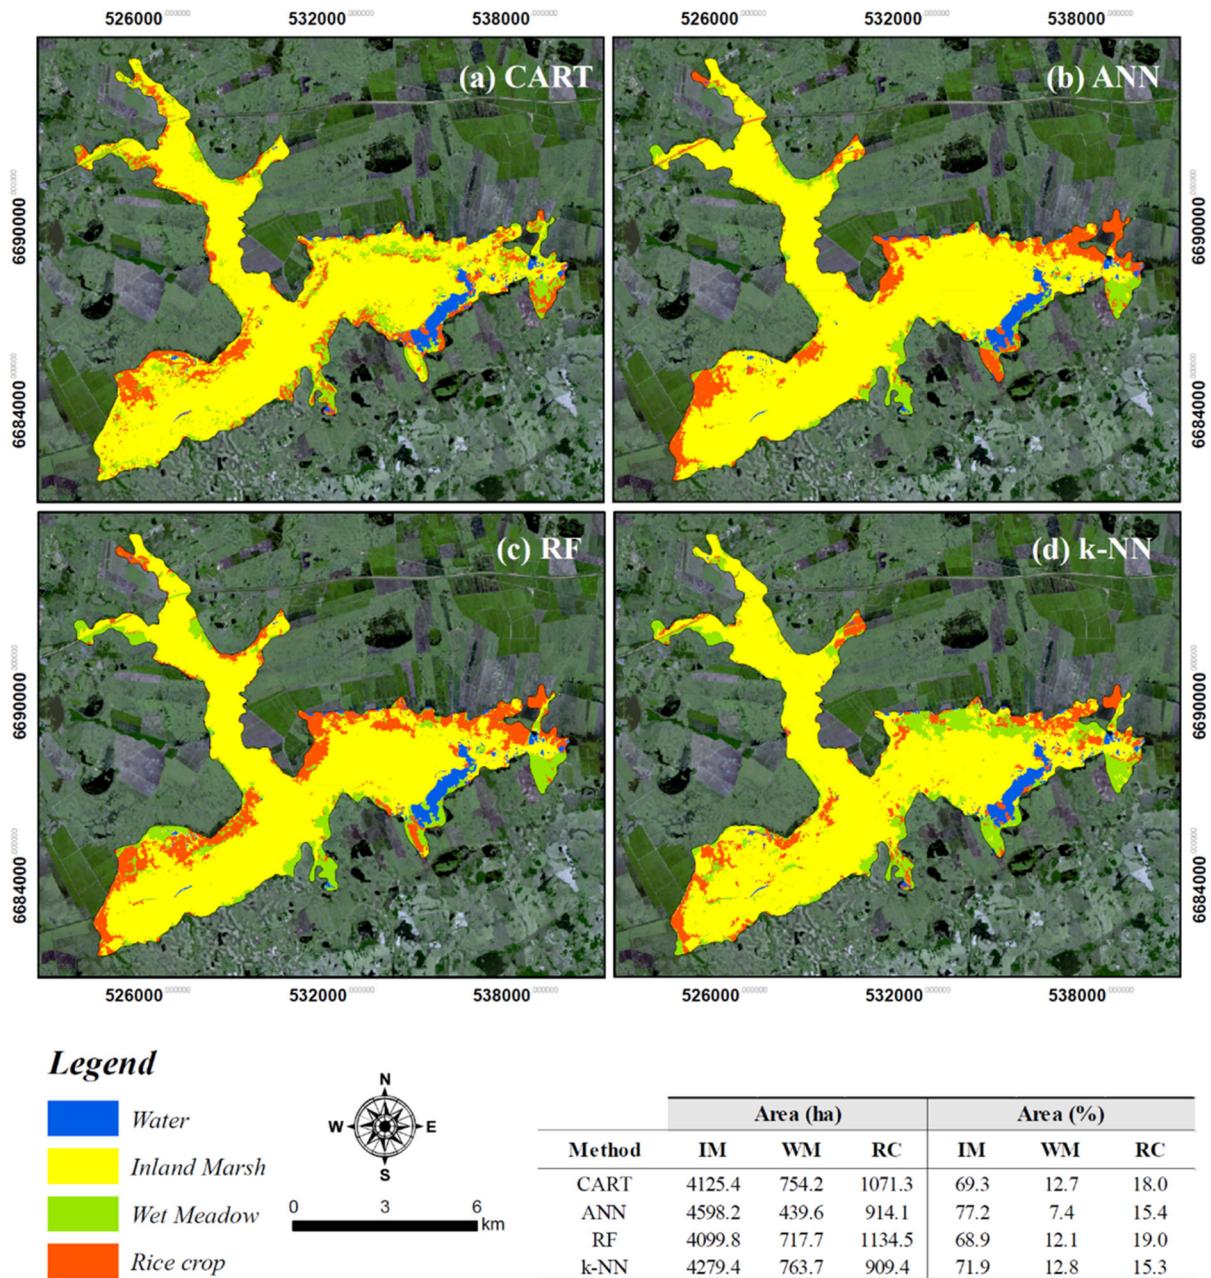


Fig. 4 Classification results for the different methods: (1) CART, (2) ANN, (3) RF, and (4) k-NN

The confusion matrix shows the values of PA, UA and Kappa for the different classifiers (Table 4). For the CART method, there was confusion between WM and RC classes within the IM areas. For the ANN method, the IM areas presented confusion only with RC, reaching 97.7% for UA. Both PA (98.6%) and kappa (0.93) were one tenth higher than the CART

method. Both RF and k-NN presented 100% on UA for IM. The PA for IM using RF and k-NN was lower when compared to CART and ANN (97.2%). Nevertheless, RF and k-NN showed the highest overall kappa values (0.97 and 0.98, respectively).

Table 4 Confusion matrix for the different methods: (1) CART, (2) ANN, (3) RF, and (4) k-NN

	CART				ANN				RF				k-NN			
	IM	WM	RC	UA (%)	IM	WM	RC	UA (%)	IM	WM	RC	UA (%)	IM	WM	RC	UA (%)
IM	186	5	7	93.9	210	0	5	97.7	209	0	0	100	209	0	0	100
WM	0	199	6	97.1	1	177	15	91.7	0	193	4	98.0	0	192	2	99.0
RC	3	6	187	95.4	2	1	188	98.4	6	0	187	96.9	6	1	189	96.4
PA (%)	98.4	94.8	93.5	95.5	98.6	99.4	90.4	96.0	97.2	100	97.9	98.3	97.2	99.5	99.0	98.5
Kappa	0.92				0.93				0.97				0.98			

IM inland Marsh, WM wet meadow, RC rice crop, UA User's accuracy, PA producer's accuracy

Discussion

In this study, we analyzed several methods to delineate inland marshes in southern Brazil using machine learning algorithms and a multi-sensor approach. Optical remote sensing data provides spectral information of molecular and structural features related to leaf area index, biomass and coverage of the canopy. On the other hand, SAR data provides structural (roughness and geometry) and dielectric (water presence) features (Van Beijma et al. 2014). Within this context, recent work have shown that GEOBIA is a promising method in the mapping of wetlands, since it allows to separate the heterogeneity of plant communities into objects, reducing the noise in the spectral data (Dronova 2015; Mui et al. 2015).

Simioni et al. (2018) mapped inland marshes using a pixel-based approach, finding a 95.9% accuracy. In this study, using GEOBIA, we obtained a 98.5% accuracy. Despite the fact that the present study shows a better accuracy in relation to the work of Simioni et al. (2018), it is understood that we cannot say that GEOBIA was more reliable, since the difference in accuracy values is small (< 3%) and may be associated with the date of obtaining the image or even the method of classification used.

We also highlight the potential of data mining techniques for inland marshes delineation. The four methods analyzed showed accuracy greater than 90% for all parameters tested. CART and ANN presented 6% differences in the OA values, demonstrating the importance to evaluate different parameters in the models.

Our results also showed that the RF and k-NN classifiers presented the highest OA for inland marshes

delineation (98.3% and 98.5%, respectively). The k-NN was the method that presented the highest OA. This method is considered a lazy learning (Guo et al. 2003), because it simply stores the entire training set and postpones all effort towards inductive generalization until classification time (Wettschereck et al. 1997). Although studies have stated that k-NN is highly sensitive to the definition of its distance function (Wettschereck et al. 1997; Guo et al. 2003), we found that the variation of k between 3 and 13 showed the same OA in Chebyshev distance and decreased only 1% in some values of k in the Manhattan and Euclidean distances. One explanation for the success of k-NN is that lazy learnings perform better for forecasts that use a single training set and few classes (Webb et al. 2011). In this study, we chose to use only three classes (IM, WM and RC). We also found that the UA (forecasting ability to represent reality) achieved 100% in the inland marshes areas for the RF and k-NN methods. However, both methods had the lowest PAs (the quality of the classification of training set pixels) for IM, of the order of 97.2%. The best PA verified for IM areas was found in the ANN method.

The L-band VH channel had the greatest importance in mapping wetlands for RF and ANN methods. The SAR images show differences in the backscatter response between flooded and non-flooded vegetation, playing an important role in the hydrological monitoring of wetlands (Baghdadi et al. 2001; Ferreira-Ferreira et al. 2015). For the Brazilian Pantanal, Evans et al. (2014) found a OA of 80% by mapping the vegetation cover with the integration of SAR C and L-bands images. According to the authors, the main errors found in the classification were due to the

similarity of wetland type classes in terms of vegetation structure and flood dynamics, and, therefore, similar backscatter characteristics.

When mapping wetlands using SAR C and X-bands data, Mleczko and Mróz (2018) obtained a OA of ~ 65% using Sentinel 1 C-band. Franklin and Ahmed (2017) used SAR C- band and Landsat 8 OLI images together with Lidar-derived geomorphometric variables, and found a OA of 91%. The authors highlight the importance of the multisensor approach, especially with optical and SAR images, to improve wetland mapping accuracy.

We highlight that among the four classifiers analyzed in this study, RF is the most common method found in literature to map wetlands (Millard and Richardson 2013; Van Beijma et al. 2014; Mahdianpari et al. 2017), showing overall accuracies higher than 90%. The k-NN method, which presented the highest accuracy in this study (98.5%), did not show the same performance on other studies over similar environments. Na et al. (2015), i.e., assessing the k-NN and RF methods to map flooded forests in China observed accuracies of 41.6% and 83.6 using k-NN and RF, respectively.

In relation to the CART and ANN methods, the accuracies obtained in this study (OA of 95.5% and 96%, respectively) are still more reliable than previous studies aiming to map inland marshes. The CART method, for example, was evaluated by Pantaleoni et al. (2009), where the authors observed a precision of

76.1% by using Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER) images. The ANN method has been used for wetlands mapping since the last two decades (Augusteijn and Warrender 1998; Ghedira et al. 2000; Fantin-Cruz et al., 2011; Chatziantoniou et al., 2017), with accuracies ranging between 70 and 90%. Using machine learning methods to map land use and land cover with emphasis on wetlands, Chatziantoniou et al. (2017) point out that the marsh class presented the lowest accuracy in the optical classification, but when using SAR data the results were improved due to texture and backscatter. In addition, the authors highlighted the GEOBIA high ability to discriminate rice crop and wetland areas by using the shape characteristic.

Figure 5 shows the different classes in the southern flank of BG. The potential of GEOBIA on recognizing shapes in the segmentation process was decisive for the good performance in the class discrimination, especially for RC. We highlight that this image was collected in December (12/11/2018), which is the final period of tillering in the rice areas. All shoots that grow after the initial parent shoot grows from a seed. Tillers are segmented, and each segment phase its own two-part leaf. From planting to harvest, rice passes by three stages (vegetative phase, reproduction phase and ripening phase). In this sense, we note that that date of the image may affect the reflectance values, given the structure of the crops and also physiological stress,



Fig. 5 Different types of vegetation within the Banhado Grande marsh

interfering in the classification results (Kuenzer and Knauer 2013).

In SAR images, Kuenzer and Knauer (2013) suggest that the final tillering period is ideal for separating rice from other classes, since the volume dispersion within the rice canopy and the interactions between plants and the surface of water result in an increase in the backscatter. Regarding polarization, we note that VV channels have higher backscatter coefficients than HH channels in the early stages of rice growth due to the physical structure of the plant, which consists mainly of short vertical leaves and stems during the early stages of rice growing (Kim et al. 2008). We found that the rice crop area within the BG ranges from 15.3% (k-NN) to 19% (RF), and is found mainly at the southern and northern limits of BG. However, the highest OA for RC areas (98.4%) were verified in the ANN method. This method estimated that 15.4% of the BG area in 1975 was currently occupied by RC.

Approximately 28% of the BG area is composed of *Cyperaceae* of the genus *Scirpus* sp. (Fig. 6). This vegetation type is common in freshwater marshes of southern Brazil and Argentina (Pratolongo et al. 2005). This vegetation is dense, ranging from 1.5 to 2.5 m above the surface water. In a study on vegetation dynamics in a marsh, Guasselli (2005) found that

there are no significant differences in reflectance of *Scirpus giganteus* during the year, given the high leaf turnover, with continuous growth and appearance of new green leaves even during the winter months (Pratolongo et al. 2005).

Regarding SAR images, Pope et al. (1994) point out that HH polarization allows to separate *Scirpus giganteus* from other aquatic vegetation types. The same is discussed by Bourgeau-Chavez et al. (2009), which found that HH/HV showed higher backscatter coefficients compared to wet meadow, for example. The models estimated that there are between 68.9% (CART) to 77.2% (ANN) of remaining natural vegetation within BG. The largest OA's found for IM areas were obtained by the RF and k-NN methods, with ~ 100% accuracy. Both methods estimated similar values of remnants of IM areas in BG, 68.9% (RF) and 71.9% (k-NN). The models also estimated that between 7.4% (ANN) and 12.8% (k-NN) of the BG area correspond to wet meadow areas. The k-NN was the method that presented the highest overall accuracy in the WM classification, of ~ 99% (Fig. 7). Ozesmi and Bauer (2002) highlight the high separability of WM from other vegetation types common in marshes areas, especially in the near infrared band. Chimner et al. (2019) used multi-sensor data (SAR and optical) to map Mountain Peatlands



Fig. 6 *Scirpus giganteus* in the Banhado Grande marsh



Fig. 7 Wet meadow in the Banhado Grande marsh

and wet meadows. The results showed that the wet meadow areas had the lowest overall accuracy ($\sim 79\%$), being confused mainly with grassland or shrubland. It is important to note that we aimed to map the total area of inland marshes; however, in order to reduce the classes of analysis we incorporated grassland or shrubland areas as WM areas. This fact may justify the higher overall accuracy found in our study, since the largest WM class errors in the study by Chimner et al. (2019) are associated with the grassland or shrubland areas.

Finally, our results showed a decrease of the BG natural area since its first mapping, in 1975 (Geographic Service Directorate 1975; Ramos et al. 2014). It should be noted that the 1975 mapping was performed by visual interpretation of an aerophotogrammetric image, that is, a different method than the one used in this study. We understand that it is interesting to bring this information so that we can quantify the area of marsh lost since the first accurate mapping carried out. By using the k-NN method, which showed the highest OA, we found that $\sim 15.3\%$ of the BG original area has been converted to agriculture. These results are important in terms of the development of more sustainable activities inn the

area surrounding the BG, which has a key role in the hydrological patterns in the region.

Conclusion

We conclude that the four models analyzed can be applied with high precision ($> 95.5\%$) to delineate inland marshes. The method that presented the highest overall accuracy to delineate inland marsh was k-NN (98.5%) accuracy, followed by RF (98.3%) accuracy. ANN presented a overall accuracy of 96%, and CART was the method that presented the lowest overall accuracy, of 95.5%.

For RF, the MNC 600 showed the highest accuracy and, for k-NN, the highest accuracy was found at MNC 200. It can be concluded that MNC values less than 600 allow high precision in marsh areas classification.

Regarding the importance of features, we conclude that SAR images are the most important in ANN and RF models. The greatest overall importance was found in the Alos Palsar I L-band VH channel, with 14.5% in the RF method, demonstrating the potential of SAR L-band images to delineate inland marshes. For the ANN method, the SAR channels HV, HV + VH and

VH presented the highest importance, both with 11.6%. Regarding the spectral indices, the feature BI_1 was more important in the CART model, 6.8%. The CART and ANN methods presented the largest variations of the accuracy in relation to the different parameters tested. For CART, we found that increasing the number of child nodes caused the production of trees with smaller overall accuracy, with a variation of $\sim 6\%$ in the overall accuracy, and the parameter with the best OA was found in Neurons in the hidden layer 33. Thus, we verified that different parameters can generate differences of $\sim 6\%$ in the final accuracy to delineate marshes in the CART and ANN methods.

For the RF, we did not obtain significant differences between the OA values by testing different parameters. We note that the OA values were similar between Maximum Depth 10 to 50 for all tree numbers except trees 5 and maximum depth 30. As in the RF method, the k-NN method showed little variation in OA values when testing different parameters. The values of k did not influence the OA results in the Chebyshev metric distance.

The method with the highest OA (k-NN) estimated that the BG area has decreased 28.1% since 1975, with 15.3% being converted to agricultural areas and 12.8% to wet meadow. This fact demonstrates the need for conservation strategies not only in BG, but in all wetlands of the state of Rio Grande do Sul.

We suggest, for further studies, the use of other data mining methods, as well as the use of both geomorphological attributes and land use temporal classification in the algorithms, as well as the evaluation of the results attributed to the use of different sets of images for the same classifier. We also recommend the application of these algorithms in other IM areas, including salt marshes, to verify the potential of the methods in different types of wetlands.

Acknowledgements This study was financed by the Coordination for the Improvement of Higher Education Personnel (CAPES) agency (Grant No: 88882.438941/2019-01).

References

- Augsteijn MF, Warrender CE (1998) Wetland classification using optical and radar data and neural network classification. *Int J Remote Sens* 19:1545–1560. <https://doi.org/10.1080/014311698215342>
- Baghdadi N, Bernier M, Gauthier R, Neeson I (2001) Evaluation of C-band SAR data for wetlands mapping. *Int J Remote Sens* 22:71–88. <https://doi.org/10.1080/014311601750038857>
- Baker C, Lawrence R, Montagne C, Patten D (2006) Mapping wetlands and riparian areas using Landsat ETM+ imagery and decision-tree-based models. *Wetlands* 26:465. [https://doi.org/10.1672/0277-5212\(2006\)26\[465:mwarau\]2.0.co;2](https://doi.org/10.1672/0277-5212(2006)26[465:mwarau]2.0.co;2)
- Bao Y, Ren J (2011) Wetland Landscape classification based on the BP neural network in DaLinor Lake Area. *Procedia Environ Sci* 10:2360–2366. <https://doi.org/10.1016/J.PROENV.2011.09.368>
- Behrens T, Scholten T (2007) A comparison of data mining techniques in predictive soil mapping. *Dev Soil Sci* 31:353–617. [https://doi.org/10.1016/S0166-2481\(06\)31025-2](https://doi.org/10.1016/S0166-2481(06)31025-2)
- Bellucci E, Camuffo M, Ferrari S et al (2006) Mapping salt-marsh vegetation by multispectral and hyperspectral remote sensing. *Remote Sens Environ* 105:54–67. <https://doi.org/10.1016/j.rse.2006.06.006>
- Blaschke T, Hay GJ, Kelly M et al (2014) Geographic object-based image analysis: towards a new paradigm. *ISPRS J Photogramm Remote Sens* 87:180–191. <https://doi.org/10.1016/j.isprsjprs.2013.09.014>
- Bourgeau-Chavez LL, Riordan K, Powell RB et al (2009) Improving wetland characterization with multi-sensor, multi-temporal SAR and optical/infrared data fusion. In: Jedlovec G (ed) Advances in geoscience and remote sensing, 1st edn. InTech, London
- Breiman L (2001) Random forests. *Mach Learn* 45:5–32. <https://doi.org/10.1023/A:1010933404324>
- Breiman L, Friedman J, Stone CJ, Olshen RA (1984) Classification and regression trees. Regression trees. Taylor & Francis, Oxfordshire
- Brenner V (2016) Methodological proposal for renaturation of rectified section of the Gravataí River. Federal University of Rio Grande do Sul
- Brock MA, Smith RGB, Jarman PJ (1999) Drain it, dam it: Alteration of water regime in shallow wetlands on the New England Tableland of New South Wales, Australia. *Wetl Ecol Manag* 7:37–46. <https://doi.org/10.1023/A:1008416925403>
- Chatziantoniou A, Psomiadis E, Petropoulos G (2017) Co-Orbital Sentinel 1 and 2 for LULC mapping with emphasis on wetlands in a mediterranean setting based on machine learning. *Remote Sens* 9:1259. <https://doi.org/10.3390/rs9121259>
- Chimner RA, Bourgeau-Chavez L, Grelak S et al (2019) Mapping mountain peatlands and wet meadows using multi-date, multi-sensor remote sensing in the Cordillera Blanca, Peru. *Wetlands*. <https://doi.org/10.1007/s13157-019-01134-1>
- Clevers JGPW, Leeuwen HJC Van, Sensing R, Verhoef W (1989) Estimating apar by means of vegetation indeces: a sensitivity analysis. In: XXIX ISPRS congr techcomm VII interpret photogr remote sens data, pp 691–698

- Cowardin LM, Carter V, Golet FC, LaRoe ET (1979) Classification of wetlands and deepwater habitats of the United States. Washington
- Craft C, Craft C (2016) Inland marshes. In: *Creat restoring wetl*, pp 95–127. <https://doi.org/10.1016/B978-0-12-407232-9.00005-1>
- Dabboor M, Brisco B (2018) Wetland monitoring and mapping using synthetic aperture radar. In: *Wetlands management: assessing risk and sustainable solutions*. Intechopen, London, p 13
- Deering DW (1975) Measuring forage production of grazing units from landsat MSS data. In: *Proc 10th int symp remote sens environ*, pp 1169–1178
- Delegido J, Verrelst J, Alonso L, Moreno J (2011) Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. *Sensors* 11:7063–7081
- de França FRS, Amaral HCDJ (2013) Aplicação de Técnicas de Mineração de Dados para o Mapeamento do Conhecimento na Aprendizagem de Programação: Uma Estratégia Baseada na Taxonomia de Bloom. In: *Congresso Brasileiro de Informática na Educação*. UNICAMP, Campinas, pp 759–768
- Dronova I (2015) Object-based image analysis in wetland research: a review. *Remote Sens*.
- Dubeau P, King DJ, Unbushe DG, Rebelo LM (2017) Mapping the Dabus Wetlands, Ethiopia, using random forest classification of Landsat PALSAR and topographic data. *Remote Sens*. <https://doi.org/10.3390/rs9101056>
- Escadafal R (1989) Remote sensing of arid soil surface color with Landsat thematic mapper. *Adv Space Res* 9:159–163
- Evans TL, Costa M, Telmer K, Silva TSFF (2010) Using ALOS/ PALSAR and RADARSAT-2 to map land cover and seasonal inundation in the Brazilian Pantanal. *IEEE J Sel Top Appl Earth Obs Remote Sens* 3:560–575. <https://doi.org/10.1109/JSTARS.2010.2089042>
- Evans TL, Costa M, Tomas WM, Camilo AR (2014) Large-scale habitat mapping of the Brazilian Pantanal wetland: a synthetic aperture radar approach. *Remote Sens Environ* 155:89–108. <https://doi.org/10.1016/j.rse.2013.08.051>
- Fantin-Cruz I, Pedrollo O, Castro NMR et al (2011) Historical reconstruction of floodplain inundation in the Pantanal (Brazil) using neural networks. *J Hydrol* 399:376–384. <https://doi.org/10.1016/j.jhydrol.2011.01.014>
- Ferreira-Ferreira J, Silva TSF, Streher AS et al (2015) Combining ALOS/PALSAR derived vegetation structure and inundation patterns to characterize major vegetation types in the Mamirauá Sustainable Development Reserve, Central Amazon floodplain, Brazil. *Wetl Ecol Manag* 23:41–59. <https://doi.org/10.1007/s11273-014-9359-1>
- Franklin S, Ahmed O (2017) Object-based Wetland Characterization Using Radarsat-2 Quad-Polarimetric SAR Data, Landsat-8 OLI Imagery, and Airborne Lidar-Derived Geomorphometric Variables. *Photogramm Eng Remote Sens* 83:27–36. <https://doi.org/10.14358/PERS.83.1.27>
- Furtado LF, Silva TSF, Novo EML (2016) Dual-season and full-polarimetric C band SAR assessment for vegetation mapping in the Amazon várzea wetlands. *Remote Sens Environ* 174:212–222. <https://doi.org/10.1016/J.RSE.2015.12.013>
- Gao B (1996) NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens Environ* 58:257–266
- Gayol MP, Morandeira NS, Kandus P (2019) Dynamics of shallow lake cover types in relation to Paraná River flood pulses: assessment with multitemporal Landsat data. *Hydrobiologia* 833:9–24. <https://doi.org/10.1007/s10750-018-3847-x>
- Geographic Service Directorate (1975) Topographic chart. In: Brazilian Army. https://www.quoos.com.br/carta1dl/1dl_ASX139santoantonio_da_patrulha.jpg. Accessed 26 Aug 2019
- Ghedira H, Bernier M, Ouarda TBMJ (2000) Application of neural networks for wetland classification in RADARSAT SAR imagery. In: *IGARSS 2000. IEEE 2000 International Geoscience and Remote Sensing Symposium*. IEEE, pp 675–677
- Girolamo Neto CN (2014) Potencial de técnicas de mineração de dados para o mapeamento de áreas cafeeiras. Instituto Nacional de Pesquisas Espaciais
- Gitelson AA, Kaufman YJ, Merzlyak MN (1996) Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sens Environ* 58:289–298
- Grimson R, Gayol MP, Grimson R, et al (2019) Freshwater marsh classification in the Lower Paraná River floodplain: an object-based approach on multitemporal X-band COSMO-SkyMed data. <https://doi.org/10.1111/1.JRS.13.014531>
- Guasselli L a. (2005) Dinâmica da vegetação no banhado do Taim, RS
- Guo G, Wang H, Bell D et al (2003) KNN model-based approach in classification. Springer, Berlin, Heidelberg, pp 986–996
- Gurney K (1997) An introduction to neural networks, 1st edn. Routledge, New York
- Han J, Kamber M, Pei J (2012) Data mining: concepts and techniques, 3rd edn. Elsevier, Waltham
- Hand DJ (2007) Principles of data mining. Drug Saf 30:621–622. <https://doi.org/10.2165/00002018-20073007-00010>
- Happ PN, Feitosa RQ, Bentes C, Farias R (2013) Um algoritmo de segmentação por crescimento de regiões para GPUs. *Bol Ciencias Geod* 19:208–226. <https://doi.org/10.1590/S1982-21702013000200004>
- Huete AR (1988) A soil-adjusted vegetation index (SAVI). *Remote Sens Environ* 25:295–309
- Jahncke R, Leblon B, Bush P, LaRocque A (2018) Mapping wetlands in Nova Scotia with multi-beam RADARSAT-2 Polarimetric SAR, optical satellite imagery, and Lidar data. *Int J Appl Earth Obs Geoinf* 68:139–156. <https://doi.org/10.1016/J.JAG.2018.01.012>
- Jones T, Marzen L, Mitra C, Barbour M (2018) Identification and classification of geographically isolated wetlands in North Alabama using geographic object based image analysis (GeOBIA). *Geocarto Int* 6049:1–16. <https://doi.org/10.1080/10106049.2018.1438527>
- Junk WJ, Piedade MTF, Lourival R et al (2014) Brazilian wetlands: Their definition, delineation, and classification for research, sustainable management, and protection. *Aquat Conserv Mar Freshw Ecosyst* 24:5–22. <https://doi.org/10.1002/aqc.2386>
- Kamal M, Phinn S (2011) Hyperspectral data for mangrove species mapping: A comparison of pixel-based and object-

- based approach. *Remote Sens* 3:2222–2242. <https://doi.org/10.3390/rs3102222>
- Kandus P, Minotti PG, Morandeira NS et al (2018) Remote sensing of wetlands in South America: Status and challenges. *Int J Remote Sens* 39:993–1016. <https://doi.org/10.1080/01431161.2017.1395971>
- Kaplan G, Avdan U (2017) Mapping and Monitoring Wetlands Using SENTINEL-2 Satellite Imagery. *ISPRS Ann Photogramm Remote Sens Spat Inf Sci* 4:271–277
- Karlson M, Gålfalk M, Crill P et al (2019) Delineating northern peatlands using Sentinel-1 time series and terrain indices from local and regional digital elevation models. *Remote Sens Environ* 231:111252. <https://doi.org/10.1016/J.RSE.2019.111252>
- Kaufman YJ, Tanre D (1992) Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. *IEEE Trans Geosci Remote Sens* 30:261–270. <https://doi.org/10.1109/36.134076>
- Keddy P (2008) Freshwater marshes. *Encycl Ecol*. <https://doi.org/10.1016/B978-008045405-4.00338-4>
- Kim YH, Hong SY, Lee H (2008) Radar backscattering measurement of a paddy rice field using multi-frequency(l, c and x) and full-polarization. *Int Geosci Remote Sens Symp* 4:553–556. <https://doi.org/10.1109/IGARSS.2008.4779781>
- Kuenzer C, Knauer K (2013) Remote sensing of rice crop areas. *Int J Remote Sens* 34:2101–2139. <https://doi.org/10.1080/01431161.2012.738946>
- Lacaux JP, Tourre YM, Vignalles C, Ndione JA, Lafaye M (2007) Classification of ponds from high-spatial resolution remote sensing: application to Rift valley fever epidemics in Senegal. *Remote Sens Environ* 106:66–74
- Lawrence RL, Wright A (2001) Rule-Based Classification Systems Using Classification and Regression Tree (CART) Analysis. *Photogramm Eng Remote Sens* 67:1137–1142. [https://doi.org/10.1016/S0034-4257\(01\)00247-4](https://doi.org/10.1016/S0034-4257(01)00247-4)
- Leite MG, Guasselli LA (2013) Spatio-temporal dynamics of aquatic macrophytes in Banhado Grande, Gravataí River basin. *Para Onde* 7:17–24
- Macrì-Pellizzeri T, Oliver CJ, Lombardo P (2002) Segmentation-based joint classification of SAR and optical images. *IEEE Proc Radar Sonar Navig* 149:281–296. <https://doi.org/10.1049/ip-rsn:20020714>
- Mahdianpari M, Salehi B, Mohammadimanesh F, Motagh M (2017) Random forest wetland classification using ALOS-2 L-band, RADARSAT-2 C-band, and TerraSAR-X imagery. *ISPRS J Photogramm Remote Sens* 130:13–31. <https://doi.org/10.1016/j.isprsjprs.2017.05.010>
- Maimon O, Rokach L (2005) Introduction to knowledge discovery in databases. In: Maimon O, Rokach L (eds) *Data mining and knowledge discovery handbook*. Springer, New York, pp 1–15
- Mazzillo JRCA, Anzanello MJ (2015) Sistemática de seleção de variáveis para classificação de produtos em categorias de modelos de reposição. *Gest Prod* 22:201–212. <https://doi.org/10.1590/0104-530X1052-13>
- McFeeters SK (2007) The use of the normalized difference water index (NDWI) in the delineation of open water features. *Int J Remote Sens* 17:1425–1432
- Millard K, Richardson M (2013) Wetland mapping with LiDAR derivatives, SAR polarimetric decompositions, and LiDAR-SAR fusion using a random forest classifier. *Can J Remote Sens* 39:290–307. <https://doi.org/10.5589/m13-038>
- Mitsch WJ, Bernal B, Nahlik AM et al (2013) Wetlands, carbon, and climate change. *Landsc Ecol* 28:583–597. <https://doi.org/10.1007/s10980-012-9758-8>
- Mleczko M, Mróz M (2018) Wetland mapping using SAR Data from the Sentinel-1A and TanDEM-X missions: a comparative study in the Biebrza Floodplain (Poland). *Remote Sens* 10:78. <https://doi.org/10.3390/rs10010078>
- Morandeira N, Grings F, Facchinetti C et al (2016) Mapping plant functional types in floodplain wetlands: an analysis of C-band polarimetric SAR data from RADARSAT-2. *Remote Sens* 8:174. <https://doi.org/10.3390/rs8030174>
- Mui A, He Y, Weng Q (2015) An object-based approach to delineate wetlands across landscapes of varied disturbance with high spatial resolution satellite imagery. *ISPRS J Photogramm Remote Sens* 109:30–46. <https://doi.org/10.1016/j.isprsjprs.2015.08.005>
- Na XD, Zang SY, Wu CS, Li WL (2015) Mapping forested wetlands in the Great Zhan River Basin through integrating optical, radar, and topographical data classification techniques. *Environ Monit Assess* 187:696. <https://doi.org/10.1007/s10661-015-4914-7>
- Neiff JJ, Patino CA, Neiff ASP et al (2002) Response of a natural marsh to chemical and biological inputs of eutrophic waters (Saladas, Corrientes, Argentina). *Rev Bras Recur Hídricos* 7:53–62. <https://doi.org/10.21168/rbrh.v7n3.p53-62>
- Neves AK (2015) O Uso de Séries Temporais e Mineração de Dados no Mapeamento de Cobertura do Solo e seus Padrões São José dos Campos. Instituto Nacional de Pesquisas Espaciais
- Oliveira GG, Pedrollo OC, Castro NMR (2015) Simplifying artificial neural network models of river basin behaviour by an automated procedure for input variable selection. *Eng Appl Artif Intell* 40:47–61. <https://doi.org/10.1016/j.engappai.2015.01.001>
- Ozesmi SL, Bauer ME (2002) Satellite remote sensing of wetlands. *Wetl Ecol Manag* 10:381–402. <https://doi.org/10.1023/A:1020908432489>
- Pantaleoni E, Wynne RH, Galbraith JM, Campbell JB (2009) Mapping wetlands using ASTER data: a comparison between classification trees and logistic regression. *Int J Remote Sens* 30:3423–3440. <https://doi.org/10.1080/01431160802562214>
- Pearson RL, Miller LD (1972) Remote mapping of standing crop biomass for estimation of the productivity of the shortgrass Prairie. *Remote Sens Environ* 8:1355
- Pereira L, Furtado L, Novo E et al (2018) Multifrequency and Full-Polarimetric SAR assessment for estimating above ground biomass and leaf area index in the Amazon Várzea Wetlands. *Remote Sens* 10:1355. <https://doi.org/10.3390/rs10091355>
- Pontius RG, Millones M (2011) Death to kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. *Int J Remote Sens* 32:4407–4429. <https://doi.org/10.1080/01431161.2011.552923>
- Pope KO, Rey-Benayas JM, Paris JF (1994) Radar remote sensing of forest and wetland ecosystems in the Central

- American tropics. *Remote Sens Environ* 48:205–219. [https://doi.org/10.1016/0034-4257\(94\)90142-2](https://doi.org/10.1016/0034-4257(94)90142-2)
- Pratolongo P, Vicari R, Kandus P, Malvárez I (2005) A new method for evaluating Net Aboveground Primary Production (NAPP) of *Scirpus giganteus* (Kunth). *Wetlands* 25:228–232. [https://doi.org/10.1672/0277-5212\(2005\)025\[0228:ANMFEN\]2.0.CO;2](https://doi.org/10.1672/0277-5212(2005)025[0228:ANMFEN]2.0.CO;2)
- Ramos RA, Pasqualetto AI, Balbuena RA, et al (2014) Mapeamento e diagnóstico de áreas úmidas no Rio Grande do Sul, com o uso de ferramentas de geoprocessamento. In: Anais do Simposio de Áreas Protegidas. Viçosa, pp 17–21
- Richardson AJ, Wiegand CL (1977) Distinguishing vegetation from soil background information. *Photogramm Eng Remote Sens* 43:1541–1552
- Rokach L, Maimon O (2005) Decision trees. Data mining and knowledge discovery handbook, 1st edn. Springer, Berlin, pp 165–192
- Rouse JW, Hass RH, Schell JA, Deering DW (1973) Monitoring vegetation systems in the great plains with ERTS. In: Third earth resour technol satell symp, vol 1, pp 309–317. <https://doi.org/citeulike-article-id:12009708>
- Ruiz LF (2019) Proposed object-based classification and post-classification of land cover and use by unmanned aerial vehicle images. Federal University of Rio Grande do Sul
- Rumelhart DE, Hinton GE, Williams RJ (1986) © Learning representations by back-propagating errors. *Nature* 323:264–265. <https://doi.org/10.1038/324227a0>
- Sánchez-espinosa A, Schröder C (2019) Land use and land cover mapping in wetlands one step closer to the ground : Sentinel-2 versus landsat 8. *J Environ Manage* 247:484–498. <https://doi.org/10.1016/j.jenvman.2019.06.084>
- Sasser CE, Evers-Hebert E, Holm GO et al (2017) Relationships of marsh soil strength to belowground vegetation biomass in Louisiana coastal marshes. *Wetlands*. <https://doi.org/10.1007/s13157-017-0977-2>
- Silva RC da (2016) Estudo da dinâmica da fragilidade ambiental na Bacia Hidrográfica do Rio Gravataí, RS. Universidade Federal da Bahia
- Silva TSF, Costa MPF, Melack JM (2010) Spatial and temporal variability of macrophyte cover and productivity in the eastern Amazon floodplain: a remote sensing approach. *Remote Sens Environ* 114:1998–2010. <https://doi.org/10.1016/j.rse.2010.04.007>
- Simioni J, Guasselli L, Etchelar C (2017) Connectivity among Wetlands of EPA of Banhado Grande, RS Conetividade entre Áreas Úmidas, APA do Banhado Grande, RS. *Braz J Water Resour.* <https://doi.org/10.1590/2318-0331.011716096>
- Simioni JPD, Guasselli LA, Nascimento VF et al (2019) 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. *Environ Dev Sustain*. <https://doi.org/10.1007/s10668-019-00442-0>
- Simioni JPD, Nascimento VF, Guasselli LA et al (2018) Small inner marsh area delimitation using remote sensing spectral indexes and decision tree method in southern Brazil. *Rev Teledetectación*. <https://doi.org/10.4995/raet.2018.10366>
- Şimşek ÇK, Ödül H (2018) Investigation of the effects of wetlands on micro-climate. *Appl Geogr*. <https://doi.org/10.1016/j.apgeog.2018.05.018>
- Story M, Congalton RG (1986) Remote sensing brief accuracy assessment: a user's perspective. *Photogramm Eng Remote Sens* 52:397–399
- Van Beijma S, Comber A, Lamb A (2014) Random forest classification of salt marsh vegetation habitats using quad-polarimetric airborne SAR, elevation and optical RS data. *Remote Sens Environ*. <https://doi.org/10.1016/j.rse.2014.04.010>
- Waheed T, Bonnell RB, Prasher SO, Paulet E (2006) Measuring performance in precision agriculture: CART-A decision tree approach. *Agric Water Manag* 84:173–185. <https://doi.org/10.1016/j.agwat.2005.12.003>
- Walsh N, Bhattacharji N, Chay F (2014) Mapping Tidal Salt Marshes
- Wang X, Gao X, Zhang Y et al (2019) Land-cover classification of coastal wetlands using the RF algorithm for worldview-2 and Landsat 8 images. *Remote Sens* 11:1927. <https://doi.org/10.3390/rs11161927>
- Webb GI, Sammut C, Perlich C et al (2011) Lazy Learning. Encyclopedia of Machine Learning. Springer, US, Boston, MA, pp 571–572
- Wester SJ, Grimson R, Minotti PG et al (2018) Hydrodynamic modelling of a tidal delta wetland using an enhanced quasi-2D model. *J Hydrol* 559:315–326. <https://doi.org/10.1016/j.jhydrol.2018.02.014>
- Wettschereck D, Aha DW, Mohri T (1997) A review and empirical evaluation of feature weighting methods for a class of lazy learning algorithms. *Artif Intell Rev* 11:273–314. <https://doi.org/10.1023/A:1006593614256>
- White L, Brisco B, Daboor M et al (2015) A collection of SAR methodologies for monitoring wetlands. *Remote Sens* 7:7615–7645. <https://doi.org/10.3390/rs70607615>
- Xu H (2007) Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *Int J Remote Sens* 27:3025–3033
- Zhou Q, Jing Z, Jiang S (2003) Remote sensing image fusion for different spectral and spatial resolutions with bilinear resampling wavelet transform. In: Proceedings of the 2003 IEEE International Conference on Intelligent Transportation Systems. IEEE, Shanghai, pp 1206–1213

Publisher's Note Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.

8 CONCLUSÕES E CONSIDERAÇÕES FINAIS

O objetivo geral de tese foi comparar métodos baseados em sensoriamento remoto (ativo e passivo) e *machine learning* para delinear áreas de Banhados. Nossos resultados demonstraram o potencial para delinear e classificar área de Banhados a partir da integração de imagens obtidas de sensores ativos e passivos e *machine learning*. Os bons resultados obtidos a partir do uso de *machine learning*, estão relacionados à sua capacidade de incorporar diversas camadas no modelo, quer sejam, índices espectrais, canais polarimétricos, bandas espectrais, entre outros.

Utilizando apenas imagens ópticas do Sentinel 2A e *machine learning*, obtivemos acurácia entre 77,9% e 95,9%, no inverno e verão, respectivamente. Essa variação de acurácia conforme a estação do ano pode estar relacionada ao período de plantio de arroz nos meses de verão e/ou período de oscilação do nível da água no inverno. Podemos inferir que, apesar dos índices espectrais de sensoriamento remoto não serem desenvolvidos especificamente para tal fim, eles apresentaram altas acurácia no delineamento e classificação.

Utilizando apenas imagens SAR, em polarizações duplas e quádruplas, bandas C e L, respectivamente, verificamos que a banda C, proveniente de imagens Sentinel 1 apresentou baixo potencial para delineamento e classificação, com uma acurácia de 56,1%. Utilizando a banda L do Alos Palsar I a acurácia foi de 71%. A integração de imagens em bandas C e L não alterou significativamente a acurácia final, ficando em 72,9%. Esse resultado demonstra que, as imagens Sentinel 1 não são indicadas para o delineamento de Banhados, o que pode ser verificado na análise das importâncias das camadas. As três camadas mais importantes no modelo foram obtidas na banda L, são elas HV+VH com 29% e HV e VH, ambas com 28% de importância no algoritmo CART para delineamento e classificação de Banhados.

A aplicação de análise multisensor e GEOBIA apresentaram as maiores acurácia no delineamento de Banhados, com 95,5% no modelo CART, 96% nas RNAs, 98,5% no RF e 98,3% usando o k-NN. Esses resultados demonstram que esses algoritmos podem ser aplicados com sucesso no delineamento e classificação de Banhados.

Destaca-se que ao serem aplicados isoladamente, ou com outras imagens SAR, o sensoriamento remoto ativo apresentou menor potencial no delineamento e classificação, com acuráncias inferiores à 75%. Porém, ao integrar imagens SAR e imagens ópticas as acuráncias foram maiores que 95,5%. As camadas SAR HV, VH e HV+VH foram as que apresentaram as maiores importâncias no modelo. Esses resultados demonstram que as imagens SAR quando utilizadas isoladamente não apresentam bons resultados no delineamento e classificação de Banhados, mas possuem alto potencial ao serem integradas com imagens ópticas.

Esta tese utilizou como área de estudo de caso o Banhado Grande. Entendemos que, devido as semelhanças estruturais, hidrológicas e espectrais, as metodologias abordadas nessa Tese podem ser aplicadas com precisão em outras áreas de Banhados.

Espera-se, com esta tese, contribuir com o delineamento, classificação e inventário destes importantes ecossistemas úmidos. O entendimento da dinâmica desses ambientes, pode contribuir na sua gestão, conservação e efetiva proteção legal. Corre-se o risco de as áreas de Banhados serem apenas histórias contadas às futuras gerações, dadas as pressões antrópicas e a histórica conversão desses ambientes em áreas urbanas, agrícolas e industriais.

Para trabalhos futuros, sugerimos explorar a aplicação de análises de séries temporais de imagens de satélite de modo a avaliar o comportamento sazonal desses ambientes. Recomendamos, a utilização do Google Earth Engine, utilizando as metodologias aplicadas nessa tese. Utilizar variáveis geomorfológicas e hidrológicas, pode aumentar a confiabilidade da classificação, e também imagens de melhores resoluções espaciais, espectrais e radiométricas.

FINANCIAMENTO

Esta tese foi financiada pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), através do Programa de Demanda Social nº 88882.438941/2019-01.

REFERENCIAS

- ACCORDI, I. A.; HARTZ, M. Spatial and seasonal distribution of avifauna in a coastal wetland. **Revista Brasileira de Ornitologia**, v. 14, n. 2, p. 117–135, 2006.
- AMANI, M. et al. Spectral Analysis of Wetlands in Newfoundland Using Sentinel 2a and Landsat 8 Imagery. In: IMAGING AND GEOSPATIAL TECHNOLOGY FORUM, 2017, Baltimore. **Anais...** Baltimore: ASPRS, 2017. p. 1–9.
- AMARAL, E. Bombeiros tentam conter incêndio na Área de Proteção Ambiental do Banhado Grande. **Correio do Povo**, Porto Alegre, 17 abr. 2020. p. 1–1. Disponível em: <https://www.correiodopovo.com.br/noticias/cidades/bombeiros-tentam-conter-incendio-na-area-de-protecao-ambiental-do-banhado-grande-1.413698>. Acesso em: 30 ago. 2020.
- AUGUSTEIJN, M. F.; WARRENDER, C. E. Wetland classification using optical and radar data and neural network classification. **International Journal of Remote Sensing**, v. 19, n. 8, p. 1545-1560, 1998. Disponível em: <https://doi.org/10.1080/014311698215342>. Acesso em: 24 set. 2018.
- BAKER, C. et al. Mapping wetlands and riparian areas using landsat etm+ imagery and decision tree based models. **Wetlands**, v. 26, n. 2, p. 465-474, 2006. Disponível em: [https://doi.org/10.1672/0277-5212\(2006\)26\[465:mwarau\]2.0.co;2](https://doi.org/10.1672/0277-5212(2006)26[465:mwarau]2.0.co;2). Acesso em: 23 abr. 2018.
- BAO, Y. H.; REN, J. Wetland landscape classification based on the BP neural network in DaLinor Lake area. **Procedia Environmental Sciences**, v. 10, p. 2360-2366, 2011. Disponível em: <https://doi.org/10.1016/j.proenv.2011.09.368>. Acesso em: 15 jan. 2019.
- BEHRENS, T.; SCHOLTEN, T. A Comparison of Data Mining Techniques in Predictive Soil Mapping. **Developments in Soil Science**, v. 31, p. 353-617, 2007. Disponível em: [https://doi.org/https://doi.org/10.1016/S0166-2481\(06\)31025-2](https://doi.org/https://doi.org/10.1016/S0166-2481(06)31025-2)
- BITTENCOURT, D. Z.; GUASSELLI, L. A. Dinâmica de Inundação do Banhado a partir do índice NDPI, Reserva Biológica de São Donato – RS. **Geography Department University of Sao Paulo**, v. 33, p. 85, 2017. Disponível em: <https://doi.org/10.11606/rdg.v33i0.125834>
- BITTENCOURT, H. R.; CLARKE, R. T. Use of Classification and Regression Trees (CART) to classify remotely-sensed digital images. In: 2003 IEEE INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM. **Anais...** Toulouse: IEEE, 2003. Disponível em: <https://doi.org/10.1109/IGARSS.2003.1295258>.
- BORGES JUNIOR, R. S. **Sensebles – uma abordagem para melhorar a qualidade das correspondências de instâncias disjuntas em estudos observacionais explorando características idênticas e ensembles de regressores**. (Tese de Doutorado) Programa de Pós-Graduação em Ciência da Computação, Universidade Federal de São Carlos. 189 f. 2016. São Carlos: UFSCar, 2016.

BOURGEAU-CHAVEZ, L. L. et al. Improving Wetland Characterization with Multi-Sensor, Multi-Temporal SAR and Optical/Infrared Data Fusion. In: JEDLOVEC, G. (org.). **Advances in Geoscience and Remote Sensing**. London: InTech, 2009. Disponível em: <https://doi.org/10.5772/8327>. Acesso em: 27 ago. 2019.

BRASIL. **Lei n. 9.985 de 18 de julho de 2000**. Brasília: Planalto, 2000. p. 5. Disponível em: http://www.planalto.gov.br/ccivil_03/leis/l9985.htm. Acesso em: 18 jun. 2019.

BREIMAN, L. et al. **Classification and regression trees Regression trees**. Oxfordshire: Taylor & Francis, 1984. Disponível em: <https://doi.org/10.1002/widm.8>. Acesso em: 13 abr. 2018.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 2001. Disponível em: <https://doi.org/10.1023/A:1010933404324>

BRENNER, V. **Methodological proposal for renaturation of rectified section of the Gravataí River**. (Mestrado em Geografia) Programa de Pós-Graduação em geografia, Universidade Federal do Rio Grande do Sul. Porto Alegre: UFRGS, 2016. 94 f.

BRINSON, M. M. **A Hydrogeomorphic Classification for Wetlands**. Greenville: U.S. Army Corps of Engineers, 1993. Disponível em: <https://doi.org/10.2134/agronj2001.931131x>.

BRINSON, M. M. Wetlands classification. In: LEPAGE, B. (org.). **Wetlands: integrating multidisciplinary concept**. New York: Springer, 2011. p. 95–113.

BRONSHTEIN, A. **A Quick Introduction to K-Nearest Neighbors Algorithm**. 2017. Disponível em: <https://medium.com/@adi.bronshtein/a-quick-introduction-to-k-nearest-neighbors-algorithm-62214cea29c7>. Acesso em: 15 jan. 2019.

BURGER, M. I. **Situação e ações prioritárias para a conservação de banhados e áreas úmidas costeiras**. Porto Alegre: FZB, 2000. Disponível em: http://rodadas.anp.gov.br/arquivos/Round7/arquivos_r7/SISMICA_R7/refere/Banhados.pdf.

CALIFORNIA WETLAND AND RIPARIAN AREA PROTECTION POLICY. **Wetland Definition**. Technical Memorandum n. 2. São Francisco: CWRAPP, 2009.

CANADIAN WETLAND INVENTORY TECHNICAL GROUP. **Canadian Wetland Inventory**. Ottawa: Ducks, 1997. Disponível em: https://www.ducks.ca/assets/2017/01/CWIDMv7_01_E.pdf. Acesso em: 28 jan. 2019.

CANADIAN WETLAND INVENTORY TECHNICAL GROUP. **Canadian Wetland Inventory (Data Model)**. Stonewall: CWI, 2016. Disponível em: http://www.ducks.ca/assets/2017/01/CWIDMv7_01_E.pdf.

CANEVARI, P. et al. **Los humedales de la Argentina : clasificación, situación actual, conservación y legislación**. Buenos Aires: IAC, 1999.

CAZALS, C. et al. Mapping and characterization of hydrological dynamics in a

coastal marsh using high temporal resolution Sentinel-1A images. **Remote Sensing**, v. 8, n. 7, 2016. Disponível em: <https://doi.org/10.3390/rs8070570>

CLEMENTS, F. E. **Research Methods in Ecology**. Nova Iorque: University Publishing Company, 1905.

CLEWLEY, D. et al. Evaluation of ALOS PALSAR Data for High-Resolution Mapping of Vegetated Wetlands in Alaska. **Remote Sensing**, v. 7, n. 6, p. 7272–7297, 2015. Disponível em: <https://doi.org/10.3390/rs70607272>. Acesso em: 7 fev. 2019.

CLIFTON, C. **Data mining**. 2009. Disponível em: <https://academic-eb-britannica.ez45.periodicos.capes.gov.br/levels/collegiate/article/data-mining/437561#>. Acesso em: 6 dez. 2018.

COMITÊ GRAVATAHY. **Plano de Recursos Hídricos da Bacia Hidrográfica do Rio Gravataí**. Gravataí: Comitê Gravatahy, 2013. Disponível em: <http://www.comitegravatahy.com.br/index.php/plano-da-bacia>

CORCORAN, J. et al. The integration of optical, topographic, and radar data for wetland mapping in northern Minnesota. **Canadian Journal of Remote Sensing**, v. 37, n. 5, p. 564–582, 2012. Disponível em: <https://doi.org/10.5589/m11-067>. Acesso em: 7 fev. 2019.

CORDEIRO, C. L. de O.; ROSSETTI, D. de F. Mapping vegetation in a late Quaternary landform of the Amazonian wetlands using object-based image analysis and decision tree classification. **International Journal of Remote Sensing**, v. 36, n. 13, p. 3397–3422, 2015. Disponível em: <https://doi.org/10.1080/01431161.2015.1060644>. Acesso em: 15 jan. 2019.

CORTES, C.; VAPNIK, V. Support-vector networks. **Mach Learn.**, vol. 20, pp. 273-297, 1995.

COTA, A. M. P.; BAPTISTA, G. M. de M. Detecção de foco de incêndio subterrâneo em turfa por câmera portátil termal. **Revista Brasileira de Geomática**, v. 3, n. 2, p. 48, 2015. Disponível em: <https://doi.org/10.3895/rbgeo.v3n2.5465>

COWARDIN, L. M. et al. **Classification of wetlands and deepwater habitats of the United States**. 2 ed. Washington: FWS, 1979. Disponível em: <https://doi.org/FWS/OBS-79/31>.

CUNHA, C. N.; PIEDADE, M. T. F.; JUNK, W. J. **Classificação e Delineamento das Áreas Úmidas Brasileiras e de seus Macrohabitats**. Cuiabá: EDUFMT, 2015. Disponível em: <https://doi.org/10.1017/CBO9781107415324.004>

DI MAIO, A. et al. **Sensoriamento remoto**. 1. ed. São José dos Campos: Agência Espacial Brasileira, 2008.

DRONOVA, I. Object-based image analysis in wetland research: A review. **Remote Sensing**, vol. 7, p.6380-6413, 2015. Disponível em: <https://doi.org/10.3390/rs70506380>

DRUSCH, M. et al. Sentinel-2: ESA's Optical High-Resolution Mission for GMES

Operational Services. **Remote Sensing of Environment**, v. 120, p. 25–36, 2012. Disponível em: <https://doi.org/10.1016/J.RSE.2011.11.026>. Acesso em: 14 jan. 2019.

DURANDU, P. et al. Une typologie hydrologique des petites zones humides ripariennes. **Étude et Gestian des Soß**, v. 7, n. 3, p. 207–218, 2000. Disponível em: http://www.forum-zones-humides.org/iso_album/durand_et_al_-_2000_-_une_typologie_hydrologique_des_petites_zones_humides_ripariennes.pdf. Acesso em: 14 fev. 2019.

ENVIRONMENTAL PROTECTION AGENCY. **Functions and Values of Wetlands**. Washington: EPA, 2001. Disponível em: <https://www.epa.gov/sites/production/files/2016-02/documents/wetlandfunctionsvalues.pdf>.

ETCHELAR, C. B. **Erosive Processes in Wetlands**. (Mestrado em Sensoriamento Remoto) Programa de Pós-Graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul: Porto Alegre, UFRGS, 2017. Disponível em: <https://www.lume.ufrgs.br/bitstream/handle/10183/171041/001054625.pdf?sequence=1>

EVANS, T. L. et al. Large-scale habitat mapping of the Brazilian Pantanal wetland: A synthetic aperture radar approach. **Remote Sensing of Environment**, v. 155, p. 89–108. Disponível em: <https://doi.org/10.1016/j.rse.2013.08.051>

EVANS, T. L. et al. Using ALOS/PALSAR and RADARSAT-2 to Map Land Cover and Seasonal Inundation in the Brazilian Pantanal. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 3, n. 4, p. 560–575, 2010. Disponível em: <https://doi.org/10.1109/JSTARS.2010.2089042>. Acesso em: 7 fev. 2019.

FANG, X.; SHENG, O. R. L.; GOES, P. When Is the Right Time to Refresh Knowledge Discovered from Data? **Operations Research**, v. 61, n. 1, p. 32–44, 2013. Disponível em: <https://doi.org/10.3892/or.2017.5437>

FERREIRA, W. T. S.; LETÍCIA, L.; RABELO, A. P. C. Análise da distribuição espaço-temporal dos focos de incêndio no Pantanal (2000-2016). In: SIMPÓSIO DE GEOTECNOLOGIAS NO PANTANAL, 2018, Jardim. **Anais...** Jardim: Embrapa Informática Agropecuária/INPE, 2018. p. 563–573.

FRANKLIN, S. E. et al. Wetland classification using Radarsat-2 SAR quad-polarization and Landsat-8 OLI spectral response data: a case study in the Hudson Bay Lowlands Ecoregion. **International Journal of Remote Sensing**, v. 39, n. 6, p. 1615–1627, 2018. Disponível em: <https://doi.org/10.1080/01431161.2017.1410295>. Acesso em: 13 mar. 2019.

FU, B. et al. 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. Disponível em: <https://doi.org/10.1016/J.ECOLIND.2016.09.029>. Acesso em: 17 jan. 2019.

FURTADO, L. F. de A.; SILVA, T. S. F.; NOVO, E. M. L. de M. Dual-season and full-

polarimetric C band SAR assessment for vegetation mapping in the Amazon várzea wetlands. **Remote Sensing of Environment**, v. 174, p. 212–222, 2016. Disponível em: <https://doi.org/10.1016/J.RSE.2015.12.013>. Acesso em: 19 abr. 2018.

GALLANT, A. L. The challenges of remote monitoring of wetlands. **Remote Sensing**, v. 7, n. 8, p. 10938–10950, 2015. Disponível em: <https://doi.org/10.3390/rs70810938>

GERBEAUX, P.; MAX FINLAYSON, C.; VAN DAM, A. A. Wetland classification: Overview. In: FINLAYSON, M. C. et al. **The Wetland Book: Structure and Function, Management, and Methods**. Springer Netherlands, 2018. p. 1461–1468. Disponível em: https://doi.org/10.1007/978-90-481-9659-3_329. Acesso em: 2 fev. 2021.

GINZBURG, R. et al. Los Humedales del Chaco : Clasificación , Inventario y Mapeo a Escala Regional. **INSUGEO - Miscelânea**, v. 14, n. 1, p. 121–138, 2005.

GOMES, C. S. **Bases teórico-conceituais e subsídios para a classificação hidrogeomorfológica das áreas úmidas em Minas Gerais**. (Mestrado em Geografia) Programa de Pós-Graduação em Geografia, Universidade Federal de Minas Gerais. Belo Horizonte: UFMG, 2017.

GOMES, C. S.; MAGALHAES JR, A. P. M. Hydrogeomorphic wetland classes in Minas Gerais. **Revista Brasileira de Geomorfologia**, v. 2, n. 21, p. 1–15, 2020. Disponível em: <https://doi.org/http://dx.doi.org/10.20502/rbg.v2i2.1794>

GOMES, D. F. **Uso de imagens Sentinel-2 na identificação de áreas com infestação do capim-annoni-2 no complexo eólico Cerro Chato**. (Mestrado em Sensoriamento Remoto) Programa de Pós-Graduação em Sensoriamento Remoto, Universidade Federal do Rio Grande do Sul. Porto Alegre: UFRGS, 2017.

GONZÁLEZ TRILLA, G. et al. Relating biophysical parameters of coastal marshes to hyperspectral reflectance data in the bahia blanca estuary, Argentina. **Journal of Coastal Research**, v. 29, n. 1, p. 231–238, 2013. Disponível em: <https://doi.org/10.2112/JCOASTRES-D-11-00214.1>

GRIMSON, R. et al. Freshwater marsh classification in the Lower Paraná River floodplain : an object-based approach on multitemporal X-band COSMO- SkyMed data. **Journal of Applied Remote Sensing**, v. 13, n. 1, 2019. Disponível em: <https://doi.org/10.1117/1.JRS.13.014531>

GRINGS, F. et al. Exploring the capacity of radar remote sensing to estimate wetland marshes water storage. **Journal of Environmental Management**, v. 90, n. 7, p. 2189–2198, 2009. Disponível em: <https://doi.org/10.1016/j.jenvman.2007.06.029>

GUASSELLI, L. A. Dinâmica da vegetação no banhado do Taim, RS. (Tese de Doutorado) Programa de Pós-Graduação em Recursos Hídricos, Universidade Federal do Rio Grande do Sul. Porto Alegre: UFRGS, 2005.

GUASSELLI, L. A.; SIMIONI, J. P. D.; LAURENT, F. Mapeamento e classificação de áreas úmidas usando Topographic Wetness Index (TWI) a partir de modelos digitais de elevação, na bacia hidrográfica do rio Gravataí - Rio Grande Do Sul, Brasil. **Revista Brasileira de Geomorfologia**, v. 21, n. 3, 2020. Disponível em:

<https://doi.org/10.20502/rbg.v21i3.1714>

GUO, M. et al. A review of wetland remote sensing. **Sensors (Switzerland)**, v. 17, n. 4, p. 1–36, 2017. Disponível em: <https://doi.org/10.3390/s17040777>

HAND, D. J. Principles of data mining. **Drug Safety**, v. 30, n. 7, p. 621–622, 2007. Disponível em: <https://doi.org/10.2165/00002018-200730070-00010>

HENDERSON, F. M.; LEWIS, A. J. Radar detection of wetland ecosystems: a review. **International Journal of Remote Sensing**, v. 29, n. 20, p. 5809–5835, 2008. Disponível em: <https://doi.org/10.1080/01431160801958405>. Acesso em: 23 abr. 2018.

HOOK, D. Wetlands: history, current status and future. **Environmental Toxicology and Chemistry**, v. 12, p. 2157–2166, 1993. Disponível em: <https://doi.org/10.1002/0730-7268/93>

HU, L.-Y. et al. The distance function effect on k-nearest neighbor classification for medical datasets. **SpringerPlus**, v. 5, n. 1, p. 1304, 2016. Disponível em: <https://doi.org/10.1186/s40064-016-2941-7>. Acesso em: 15 jan. 2019.

HU, S.; NIU, Z.; CHEN, Y. Global Wetland Datasets: a Review. **Wetlands**, v. 37, n. 5, p. 807–817, 2017. Disponível em: <https://doi.org/10.1007/s13157-017-0927-z>

INSTITUTO HUMBOLDT. **Colombia Anfibia**: Un país de humedales. Bogotá: Inst. Humboldt, 2015. Disponível em: <https://doi.org/10.1017/CBO9781107415324.004>

IRGANG, B. E.; GASTAL JR, C. V. **Macrófitas aquáticas da planície costeira do RS**. Porto Alegre: CPG Botânica/UFRGS, 1996.

IRGANG, B. E.; PEDRALLI, G.; WAECHTER, J. L. Macrófitas aquáticas da estação ecológica do Taim, Rio Grande do Sul, Brasil. **Roesslériá**, v. 6, n. 1, p. 395–404, 1984.

JAHNCKE, R. et al. Mapping wetlands in Nova Scotia with multi-beam RADARSAT-2 Polarimetric SAR, optical satellite imagery, and Lidar data. **International Journal of Applied Earth Observation and Geoinformation**, v. 68, p. 139–156, 2018. Disponível em: <https://doi.org/10.1016/J.JAG.2018.01.012>. Acesso em: 19 abr. 2018.

JENSEN, J. R. **Remote sensing of the environment : an earth resource perspective**. Denver: Pearson Prentice Hall, 2007.

JI, L. et al. Improving wetland mapping by using multi-source data sets. In: **INTERNATIONAL SYMPOSIUM ON IMAGE AND DATA FUSION**, 2009, Yunnan. **Anais...** Yunnan: IEEE, 2009, p. 2–5. Disponível em: <https://doi.org/10.1109/ISIDF.2011.6024285>

JUNK, W. J. et al. Brazilian wetlands: Their definition, delineation, and classification for research, sustainable management, and protection. **Aquatic Conservation: Marine and Freshwater Ecosystems**, v. 24, n. 1, p. 5–22, 2014. Disponível em: <https://doi.org/10.1002/aqc.2386>

JUNK, W. J. et al. **Definição e Classificação das Áreas Úmidas (AUs) Brasileiras: Base Científica para uma Nova Política de Proteção e Manejo Sustentável.** Campo Grande: Centro de Pesquisa do Pantanal, 2014.

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**, vol. 106, p.110-127, 1989.

KANDUS, P. et al. Remote sensing of wetlands in South America: Status and challenges. **International Journal of Remote Sensing**, v. 39, n. 4, p. 993–1016, 2018. Disponível em: <https://doi.org/10.1080/01431161.2017.1395971>. Acesso em: 13 fev. 2019.

KANDUS, P.; MINOTTI, P.; MALVÁREZ, A. I. Distribution of wetlands in Argentina estimated from soil charts. **Acta Scientiarum - Biological Sciences**, v. 30, n. 4, p. 403–409, 2008. Disponível em: <https://doi.org/10.4025/actascibiolsci.v30i4.5870>

KAPLAN, G.; AVDAN, U. Mapping and Monitoring Wetlands Using SENTINEL-2 Satellite Imagery. In: ISPRS ANNALS OF PHOTOGRAMMETRY, REMOTE SENSING AND SPATIAL INFORMATION SCIENCES, IV. Karabuk, ISPRS, 2017. p. 271–277.

KOTZE, D. C. The effects of fire on wetland structure and functioning. **African Journal of Aquatic Science**, v. 38, n. 3, p. 237–247, 2013. Disponível em: <https://doi.org/10.2989/16085914.2013.828008>

LAROCQUE, A. et al. Use of Radarsat-2 and ALOS-PALSAR SAR images for wetland mapping in New Brunswick. In: INTERNATIONAL GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2014, Quebec City. **Anais...** Quebec City: IEEE, 2014. p. 1226–1229. Disponível em: <https://doi.org/10.1109/IGARSS.2014.6946653>

LAROCQUE, A. et al. Wetland mapping with landsat 8 OLI, Sentinel-1, ALOS-1 PALSAR, and LiDAR data in Southern New Brunswick, Canada. **Remote Sensing**, v. 12, n. 13, p. 1–30, 2020. Disponível em: <https://doi.org/10.3390/rs12132095>

LEITE, M. G.; GUASSELLI, L. A. Spatio-temporal dynamics of aquatic macrophytes in Banhado Grande, Gravataí River basin,. **Para Onde!?**, v. 7, n. 1, p. 17–24, 2013.

LI, B. et al. Analysis of the factors affecting the long-term distribution changes of wetlands in the Jing-Jin-Ji region, China. **Ecological Indicators**, v. 124, p. 1–11, 2021. Disponível em: <https://doi.org/10.1016/j.ecolind.2021.107413>

LI, L. et al. Super-resolution mapping of wetland inundation from remote sensing imagery based on integration of back-propagation neural network and genetic algorithm. **Remote Sensing of Environment**, v. 164, p. 142–154, 2015. Disponível em: <https://doi.org/10.1016/j.rse.2015.04.009>

LIN, S. et al. Systematic assessments of tidal wetlands loss and degradation in Shanghai, China: From the perspectives of area, composition and quality. **Global Ecology and Conservation**, v. 25, p. e01450, 2021. Disponível em:

<https://doi.org/10.1016/j.gecco.2020.e01450>

LIU, K. et al. Monitoring mangrove forest changes using remote sensing and GIS data with decision-tree learning. **Wetlands**, v. 28, n. 2, p. 336–346, 2008. Disponível em: <https://doi.org/10.1672/06-91.1>. Acesso em: 13 abr. 2018.

LOUPPE, G. Understanding Random Forests: From Theory to Practice. (Tese de Doutorado) Department of Electrical Engineering & Computer Science, University of Liège. Liege: UL, 2014. Disponível em: <https://doi.org/10.13140/2.1.1570.5928>

MAHDIANPARI, M. et al. Random forest wetland classification using ALOS-2 L-band, RADARSAT-2 C-band, and TerraSAR-X imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 130, p. 13–31, 2017. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2017.05.010>. Acesso em: 27 abr. 2018.

MAHDIANPARI, M. et al. The Second Generation Canadian Wetland Inventory Map at 10 Meters Resolution Using Google Earth Engine. **Canadian Journal of Remote Sensing**, v. 46, n. 3, p. 360–375, 2020. Disponível em: <https://doi.org/10.1080/07038992.2020.1802584>

MAIMON, O.; ROKACH, L. Introduction to knowledge discovery in databases. In: MAIMON, O.; ROKACH, L. (org.). **Data mining and knowledge discovery handbook**. New York: Springer US, 2005. p. 1–15. Disponível em: <https://doi.org/10.1007/978-0-387-09823-4>. Acesso em: 7 jun. 2018.

MALTCHIK et al. Wetlands of Rio Grande do Sul, Brazil: a classification with emphasis on plant communities. **Acta Limnol. Bras**, v. 16, n. 2, p. 137–151, 2004. Disponível em: [http://www.ablimno.org.br/acta/pdf/acta_limnologica_contents1602E_files/Art4_16\(2\).pdf](http://www.ablimno.org.br/acta/pdf/acta_limnologica_contents1602E_files/Art4_16(2).pdf). Acesso em: 13 mar. 2019.

MATICH, D. J. **Matich-Redesneuronales**. Rosario: GIAIQ, 2001.

MATTHEWS, G. V. T. **The Ramsar Convention on Wetlands**: its History and Development Ramsar Convention. Glan: CWI, 1993.

MEDDE, G. S. **Enveloppes des milieux potentiellement humides de la France métropolitaine**. Paris: Programme de modélisation des milieux potentiellement humides de France, 2014.

MELLO, L. P. **Percepção da paisagem e conservação ambiental no Banhado Grande do Rio Gravataí (RS)**. (Tese de Doutorado) Programa de Pós-Graduação em Geografia Física, Universidade de São Paulo. São Paulo: USP, 1998.

MELVILLE, B.; LUCIEER, A.; ARYAL, J. Object-based random forest classification of Landsat ETM+ and WorldView-2 satellite imagery for mapping lowland native grassland communities in Tasmania, Australia. **International Journal of Applied Earth Observation and Geoinformation**, v. 66, p. 46–55, 2018. Disponível em: <https://doi.org/10.1016/J.JAG.2017.11.006>. Acesso em: 15 jan. 2019.

MEROT, P. et al. A Method for Improving the Management of Controversial Wetland.

Environmental Management, v. 37, n. 2, p. 258–270, 2006. Disponível em: <https://doi.org/10.1007/s00267-004-0391-4>. Acesso em: 14 fev. 2019.

MILLARD, K.; RICHARDSON, M. Wetland mapping with LiDAR derivatives, SAR polarimetric decompositions, and LiDAR-SAR fusion using a random forest classifier. **Canadian Journal of Remote Sensing**, v. 39, n. 4, p. 290–307, 2013. Disponível em: <https://doi.org/10.5589/m13-038>

MITSCH, W. J.; GOSELINK, J. G. **Wetlands**. 2. ed. Nova Iorque: Van Nostrand Reinhold, 1993.

MLECZKO, M.; MRÓZ, M. Wetland Mapping Using SAR Data from the Sentinel-1A and TanDEM-X Missions: A Comparative Study in the Biebrza Floodplain (Poland). **Remote Sensing**, v. 10, n. 2, p. 78, 2018. Disponível em: <https://doi.org/10.3390/rs10010078>. Acesso em: 19 abr. 2018.

MOFFETT, K. B.; GORELICK, S. M. Distinguishing wetland vegetation and channel features with object-based image segmentation. **International Journal of Remote Sensing**, v. 34, n. 4, p. 1332–1354, 2013. Disponível em: <https://doi.org/10.1080/01431161.2012.718463>. Acesso em: 13 mar. 2019.

MORANDEIRA, N. *et al.* Mapping Plant Functional Types in Floodplain Wetlands: An Analysis of C-Band Polarimetric SAR Data from RADARSAT-2. **Remote Sensing**, v. 8, n. 3, p. 174, 2016. Disponível em: <https://doi.org/10.3390/rs8030174>. Acesso em: 8 abr. 2019.

MURO, J. *et al.* Short-Term Change Detection in Wetlands Using Sentinel-1 Time Series. **remote sensing Article**, v. 8, n. 775, p. 1–14, 2016. Disponível em: <https://doi.org/10.3390/rs8100795>. Acesso em: 23 abr. 2018.

MYERS, R. L. **Convivendo com o Fogo**: Manutenção dos Ecossistemas & Subsistência com o Manejo Integrado do Fogo. Tallahassee: The Nature Conservancy, 2006.

NA, X. D. *et al.* Mapping forested wetlands in the Great Zhan River Basin through integrating optical, radar, and topographical data classification techniques. **Environmental Monitoring and Assessment**, v. 187, n. 11, p. 696, 2015. Disponível em: <https://doi.org/10.1007/s10661-015-4914-7>. Acesso em: 17 jan. 2019.

NAQA, E. I.; MURPHY M. J. What Is Machine Learning?. In: NAQA, E. I.; MURPHY, M. J.(eds) **Machine Learning in Radiation Oncology**. Cham: Springer,. 2015. Disponível em: https://doi.org/10.1007/978-3-319-18305-3_1. Acesso em 16 de mai. 2021.

NEIFF, J J; IRONDO, M. H.; CARNAN, R. Large tropical South American wetlands: an overview. In: THE ECOLOGY AND MANAGEMENT OF AQUATIC-TERRESTRIAL ECOTONES, 1994, Seattle. **Anais...** Seattle: University of Washington, 1994. p. 156–165.

NEIFF, J. J. Planícies de inundação são ecótonos? In: HENRY, R. (org.). **Ecótonos nas Interfaces dos Ecossistemas Aquáticos**. São Carlos: RIMA, 2003. p. 31–47.

NEIFF, J. J. et al. Response of a Natural Marsh to Chemical and Biological Inputs of Eutrophic Waters (Saladas, Corrientes, Argentina). **RBRH - Revista Brasileira de Recursos Hídricos**, v. 7, n. 3, p. 53–62, 2002. Disponível em:
<https://doi.org/10.21168/rbrh.v7n3.p53-62>

NOVO, E. M. L. de M.; PONZONI, F. J. **Introdução ao Sensoriamento remoto**. São José dos Campos: INPE, 2001.

OLLIS, D. et al. **Classification System for Wetlands and Other Aquatic Ecosystems in South Africa**. SANBI Biomed. Pretoria: South African National Biodiversity Institute, 2013. Disponível em:
<https://doi.org/10.2989/10220119.2015.1025843>

OSHIRO, T. M. **Uma abordagem para a construção de uma única árvore a partir de uma Random Forest para classificação de bases de expressão gênica**. (Dissertação de Mestrado), Programa de Pós-Graduação em Ciência da Computação, Universidade de São Paulo, 2013.

OZESMI, S. L.; BAUER, M. E. Satellite remote sensing of wetlands. **Wetlands Ecology and Management**, v. 10, n. 5, p. 381–402, 2002. Disponível em:
<https://doi.org/10.1023/A:1020908432489>. Acesso em: 23 abr. 2018.

PALMER, P.; MONTAÑO, M. ¿ Qué son las redes neuronales artificiales? Aplicaciones realizadas en el ámbito de las adicciones. **Adicciones**, v. 11, n. 3, p. 243–256, 1999. Disponível em:
<http://disi.unal.edu.co/~lctorress/RedNeu/LiRna001.pdf>

PARMUCHI, M. G.; KARSZENBAUM, H.; KANDUS, P. Mapping wetlands using multi-temporal RADARSAT-1 data and a decision-based classifier. **Canadian Journal of Remote Sensing**, v. 28, n. 2, p. 175–186, 2002. Disponível em:
<https://doi.org/10.5589/m02-014>. Acesso em: 15 jan. 2019.

PHAM-DUC, B. et al. Surface Water Monitoring within Cambodia and the Vietnamese Mekong Delta over a Year, with Sentinel-1 SAR Observations. **Water**, v. 9, n. 6, p. 366, 2017. Disponível em: <https://doi.org/10.3390/w9060366>. Acesso em: 8 fev. 2019.

POI DE NEIFF, A.; CARIGNAN, R. Macroinvertebrates on Eichhornia crassipes roots in two lakes of the a River floodplain DS. **Hydrobiologia**, v. 345, n. 1990, p. 185–196, 1997. Disponível em: <https://doi.org/10.1023/A>

PONTIUS, R. G.; MILLONES, M. Death to Kappa: Birth of quantity disagreement and allocation disagreement for accuracy assessment. **International Journal of Remote Sensing**, v. 32, n. 15, p. 4407–4429, 2011. Disponível em:
<https://doi.org/10.1080/01431161.2011.552923>

PONZONI, F. J.; SHIMABUKURO, Y. O.; KUPLICH, T. M. **Sensoriamento Remoto da vegetação**. 2 ed. São Paulo: Oficina das Letras, 2015.

PUJARI, A. **Data Mining: techniques**. Hyderabad: Universisties Press, 2008.

RAMOS, R. A. et al. Mapeamento e diagnóstico de áreas úmidas no Rio Grande do Sul, com o uso de ferramentas de geoprocessamento. In: ANAIS DO SIMPOSIO DE ÁREAS PROTEGIDAS, 2014, Viçosa. Anais...Viçosa: SAP, 2014. p. 17–21.

RAMSAR. **Convention on Wetlands of International Importance especially as Waterfowl Habitat**. Ramsar: Ramsar Convention, 1971. Disponível em: https://www.ramsar.org/sites/default/files/documents/pdf/res/key_res_vi.18e.pdf.

RAMSAR. **Directory of Wetlands of International Importance**. Gland: IUCN, 1990. Disponível em: <https://portals.iucn.org/library/sites/library/files/documents/1980-Carp-001.pdf>. Acesso em: 6 fev. 2019.

RAPINEL, S. et al. Evaluation of Sentinel-2 time-series for mapping floodplain grassland plant communities. **Remote Sensing of Environment**, v. 223, p. 115–129, 2019. Disponível em: <https://doi.org/10.1016/J.RSE.2019.01.018>. Acesso em: 8 fev. 2019.

RAPINEL, S. et al. SAR analysis of wetland ecosystems: Effects of band frequency, polarization mode and acquisition dates. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 170, p. 103–113, 2020. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2020.10.007>

RIO GRANDE DO SUL. **Código Estadual do Meio Ambiente do Estado do Rio Grande do Sul**. Porto Alegre: Assembléia Legislativa, 2020. p. 64. Disponível em: <https://www.legisweb.com.br/legislacao/?id=388665>

RIO GRANDE DO SUL. **Decreto nº 38.971**. Porto Alegre: Piratini, 1998.

RIO GRANDE DO SUL. **Implementa o Cadastro Ambiental Rural e define conceitos e procedimentos para a aplicação da Lei Federal nº 12.651**. Porto Alegre: Assembléia Legislativa, 2015. p. 6. Disponível em: <http://www.al.rs.gov.br/legis>. Acesso em: 8 fev. 2019.

RIO GRANDE DO SUL. **Lei 11.520 - Código Estadual do Meio Ambiente do Estado do Rio Grande do Sul**. Porto Alegre: Piratini, 2000.

ROBERTSON, L. D. et al. Object-based image analysis of optical and radar variables for wetland evaluation. **International Journal of Remote Sensing**, v. 36, n. 26, p. 5811–5841, 2015. Disponível em: <https://doi.org/10.1080/01431161.2015.1109727>

ROKACH, L.; MAIMON, O. Decision trees. In: ROKACH, L.; MAIMON, O. Z. **Data mining and knowledge discovery handbook**. Berlim: Springer, 2005. p. 165–192.

ROLON, A. S. Áreas úmidas artificiais – As lavouras de arroz no Rio Grande do Sul. **Humanitas - IHU On-Line**, v. 433, p. 1–12, 2013. Disponível em: <http://www.ihuonline.unisinos.br/artigo/5294-ana-silvia-rolon>. Acesso em: 2 fev. 2021.

ROSENQVIST, A. et al. ALOS PALSAR: A Pathfinder Mission for Global-Scale Monitoring of the Environment. **IEEE Transactions on Geoscience and Remote Sensing**, v. 45, n. 11, p. 3307–3316, 2007. Disponível em: <https://doi.org/10.1109/TGRS.2007.901027>. Acesso em: 14 jan. 2019.

ROYIMANI, L. et al. Distribution of Parthenium hysterophorus L. with variation in rainfall using multi-year SPOT data and random forest classification. **Remote Sensing Applications: Society and Environment**, v. 13, p. 215–223, 2019. Disponível em: <https://doi.org/10.1016/J.RSASE.2018.11.007>. Acesso em: 15 jan. 2019.

RUBBO, M. **Análise do potencial hidrogeológico do aquífero cenozóico da bacia hidrográfica do rio Gravataí - RS**. (Tese de Doutorado) Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental, Universidade Federal do Rio Grande do Sul. Porto Alegre: UFRGS, 2004. Disponível em: <https://lume.ufrgs.br/handle/10183/5373>. Acesso em: 18 jun. 2019.

RUIZ, L. F. C. et al. Object-based classification of vegetation species in a subtropical wetland using Sentinel-1 and Sentinel-2A images. **Science of Remote Sensing**, p. 102560, 2021. Disponível em: <https://doi.org/10.1016/j.srs.2021.100017>

SALAS, R. **Redes Neuronales Artificiales**. Valparaiso: Amazonaws, 2005.

Disponível em:

https://s3.amazonaws.com/academia.edu.documents/37429671/Redes_Neuronales_Artificiales.pdf?AWSAccessKeyId=AKIAIWOWYYGZ2Y53UL3A&Expires=1537897673&Signature=tBaB3m07AliOYssYIL9iPcMIGO0%3D&response-content-disposition=inline%3B filename%3DRedes_Neuronales_A.

SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM: J Res Dev.**, vol. 3, pp. 210-229, 1959.

SANTOS, E. M. dos. **Análise de imagens do satélite ALOS PALSAR (Banda L, modo polarimétrico) para discriminação de coberturas de terras do Distrito Federal**. (Dissertação de Mestrado) Programa de Pós-Graduação em Geociências, Universidade de Brasília. Brasília: UnB: 2010. Disponível em: <https://doi.org/10.1590/S0102-261X2010000100014>

SARTORI, L. R. et al. Mapping Macrophyte Species in the Amazon Floodplain Wetlands Using Fully Polarimetric ALOS/PALSAR Data. **IEEE Transactions on Geoscience and Remote Sensing**, v. 49, n. 12, p. 4717–4728, 2011. Disponível em: <https://doi.org/10.1109/TGRS.2011.2157972>

SAYURI, F. et al. Classificação da vegetação de áreas úmidas baseada em redes neurais artificiais : estudo de caso da planície fluvial do alto rio Paraná. In: SIMPOSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XIV, 2009. **Anais...** Natal: INPE, 2009. p. 5515–5522.

SCHIKOWSKI, A. N. A. B. **Estimativa do volume e da forma do fuste utilizando técnicas de aprendizado de máquina**. (Dissertação de Mestrado) Programa de Pós-Graduação em Engenharia Florestal, Universidade Federal Do Paraná. Curitiba: UFPR, 2016.

SCHULZ, U. H. et al. **Guia de identificação de banhados**. 1. ed. São Leopoldo: Casa Leiria, 2021.

SCOTT, D A; JONES, T. A. **Classification and inventory of wetlands: A global**

overview. Kluwer Academic Publishers, 1995. Disponível em:
<https://link.springer.com/content/pdf/10.1007%2FBF00045186.pdf>. Acesso em: 6 fev. 2019.

SCOTT, D. A. **A preliminary inventory of wetlands of international importance for waterfowl in West Europe and Northwest Africa.** 1. ed. Cambridge: International Waterfowl Research Bureau, 1980.

SIMAN, G. C.; MAGALHAES JÚNIOR, A. P. Wetlands Classification Systems in Brazil and the World: Current Overview and the Importance of Hydrogeomorphological Parameters. **GEO UERJ**, n. 33, p. e34519, 2018. Disponível em: <https://doi.org/10.12957/geouerj.2018.34519>

SIMIONI, J. P. D.; GUASSELLI, L. A. Banhados: Abordagem Conceitual. **Boletim Geográfico do Rio Grande do Sul**, n. 30, p. 33–47, 2017.

SIMIONI, J. P. D.; GUASSELLI, L. A. Simulation of changes in land-use/land cover on wetlands through CA-Markov model. **Revista Brasileira de Geografia Física**, v. 11, n. 6, p. 2057–2066, 2018. Disponível em:
<https://doi.org/10.26848/rbgf.v11.6.p2057-2066>

SIMIONI, J. P. D.; GUASSELLI, L. A.; ETCHELAR, C. B. Connectivity among Wetlands of EPA of Banhado Grande, RS. **RBRH**, v. 22, n. 0, 2017. Disponível em:
<https://doi.org/10.1590/2318-0331.011716096>. Acesso em: 6 ago. 2019.

SOUZA, C. M. et al. Reconstructing three decades of land use and land cover changes in brazilian biomes with landsat archive and earth engine. **Remote Sensing**, v. 12, n. 17, 2020. Disponível em: <https://doi.org/10.3390/RS12172735>

STORY, M.; CONGALTON, R. G. Remote Sensing Brief Accuracy Assessment: A User's Perspective. **Photogrammetric engineering and remote sensing**, v. 52, n. 3, p. 397–399, 1986. Disponível em: https://www.asprs.org/wp-content/uploads/pers/1986journal/mar/1986_mar_397-399.pdf. Acesso em: 12 jun. 2018.

TANG, Y. et al. A multiple-point spatially weighted k-NN method for object-based classification. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 263–274, 2016. Disponível em:
<https://doi.org/10.1016/J.JAG.2016.06.017>. Acesso em: 15 jan. 2019.

TIAN, S. et al. 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. Disponível em: <https://doi.org/10.3390/rs8110954>. Acesso em: 17 jan. 2019.

TORRES, R. et al. GMES Sentinel-1 mission. **Remote Sensing of Environment**, v. 120, p. 9–24, 2012. Disponível em: <https://doi.org/10.1016/J.RSE.2011.05.028>. Acesso em: 14 jan. 2019.

UNL. **Los incendios vuelven con fuerza en medio de la pandemia**. 2020. Disponível em:

https://www.unl.edu.ar/noticias/news/view/los_incendios_vuelven_con_fuerza_en_medio_de_la_pandemia#.X0w353IKjIV. Acesso em: 30 ago. 2020.

UUSI-LUOMALATHI, J. Classification of Wetland Vegetation Based on TerraSAR-X Data: Comparison of Methods. (Tese de Doutorado) Département Scientifique Environnements et Sociétés, Tampere University of Technology, 2016. Disponível em: <https://dspace.cc.tut.fi/dpub/bitstream/handle/123456789/24373/uusi-luomalahti.pdf?sequence=1>. Acesso em: 23 jan. 2019.

VAN BEIJMA, S.; COMBER, A.; LAMB, A. Random forest classification of salt marsh vegetation habitats using quad-polarimetric airborne SAR, elevation and optical RS data. **Remote Sensing of Environment**, v. 149, p. 118–129, 2014. Disponível em: <https://doi.org/10.1016/j.rse.2014.04.010>

VIANA, S. N. Análise de Imagens do Satélite ALOS PALSAR para Discriminar Fitofisionomias do Bioma Cerrado: Estudo de Caso no Parque Nacional da Chapada dos Veadeiros. (Dissertação de Mestrado) Instituto de Geociências, Universidade de Brasília. Brasília: UnB: 2012. Disponível em: http://repositorio.unb.br/bitstream/10482/12211/1/2012_SilviaNascimentoViana.pdf. Acesso em: 14 jan. 2019.

VILLWOCK, J. A.; TOMAZELLI, L. J. **Geologia costeira do Rio Grande do Sul**. 1. ed. Porto Alegre: Centro de Estudos de Geologia Costeira e Oceânica, 1995. v. 8

VISSEER, J. M.; SASSER, C. E. Marsh Vegetation of the Mississippi River Deltaic Plain. **Estuaries**, v. 21, n. 4B, p. 818–828, 1999.

WEN, L. Algorithms : A Comparative Study of Bagging , Boosting and Stacking Techniques. **Remote Sensing**, v. 12, n. 10, p. 1683, 2020.

WERBOS, P. J. Beyond regression: new tools for prediction and analysis in the behavioral sciences. (Tese de Doutorado). Universidade de Harvard. Washington: Um. Harvard, 1974.

WHITE, L. *et al.* A collection of SAR methodologies for monitoring wetlands. **Remote Sensing**, vol. 7, n. 6, 2015. Disponível em: <https://doi.org/10.3390/rs70607615>. Acesso em: 23 abr. 2018.

XANG, X. Machine learning. In: ZANG, X. **A Matrix Algebra Approach to Artificial Intelligence**. Singapura: Springer, 2020. Disponível em: https://doi.org/10.1007/978-981-15-2770-8_6. Acesso em 16 de mai. 2021.

ZAÏANE, O. **Principles of Knowledge Discovery in Databases**. 1999.

ZHOU, Q.; JING, Z.; JIANG, S. Remote sensing image fusion for different spectral and spatial resolutions with bilinear resampling wavelet transform. In: PROCEEDINGS OF THE 2003 IEEE INTERNATIONAL CONFERENCE ON INTELLIGENT TRANSPORTATION SYSTEMS, 2003, Shanghai. **Anais...** Shanghai: IEEE, 2003. p. 1206–1213. Disponível em: <https://doi.org/10.1109/ITSC.2003.1252676>. Acesso em: 18 abr. 2018.

ZHU, P.; GONG, P. Suitability mapping of global wetland areas and validation with

remotely sensed data. **Science China Earth Sciences**, v. 57, n. 10, p. 2283–2292, 2014. Disponível em: <https://doi.org/10.1007/s11430-014-4925-1>