

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS DA NATUREZA

GIOVANI LIMA DE SOUZA

APLICAÇÃO DE SENSORIAMENTO REMOTO NA
DELIMITAÇÃO DE ÁREAS ÚMIDAS: ANÁLISE DOS
MÉTODOS EMPREGADOS

GIOVANI LIMA DE SOUZA

APLICAÇÃO DE SENSORIAMENTO REMOTO NA DELIMITAÇÃO DE ÁREAS
ÚMIDAS: ANÁLISE DOS MÉTODOS EMPREGADOS

Trabalho de Conclusão de Curso
apresentado ao curso de graduação
em Engenharia Ambiental da
Universidade Federal de São Carlos,
para obtenção do título de bacharel
em Engenharia Ambiental.

Orientador: Paulo Guilherme Molin
Coorientador: Vinicius Moura Costa

FICHA CATALOGRÁFICA

Souza., Giovani Lima de

Aplicação de sensoriamento remoto na delimitação de áreas úmidas: análise dos métodos empregados / Giovani Lima de Souza. -- 2025.
81f.

TCC (Graduação) - Universidade Federal de São Carlos, campus Lagoa do Sino, Buri
Orientador (a): Paulo Guilherme Molin
Banca Examinadora: André Marcondes Andrade Toledo, Iuri Emmanuel de Paula Ferreira, Paulo Guilherme Molin
Bibliografia

1. Delimitação de áreas úmidas. 2. Revisão sistemática de literatura. 3. Sensoriamento remoto. I. Souza., Giovani Lima de. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)


DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Lissandra Pinhatelli de Britto - CRB/8 7539


UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS DA NATUREZA
CURSO DE GRADUAÇÃO EM ENGENHARIA AMBIENTAL

Folha de Aprovação


Assinatura dos membros da comissão examinadora que avaliou e aprovou a Defesa de Trabalho de Conclusão de Curso do(a) candidato(a) Giovani Lima de Souza, realizada em 11/11/2025:

Documento assinado digitalmente
 PAULO GUILHERME MOLIN
Data: 11/11/2025 11:04:15-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Paulo Guilherme Molin – Orientador(a)
Centro de Ciências da Natureza – UFSCar – Campus Lagoa do Sino.

Documento assinado digitalmente
 IURI EMMANUEL DE PAULA FERREIRA
Data: 11/11/2025 23:50:40-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Iuri Emmanuel de Paula Ferreira
Centro de Ciências da Natureza – UFSCar – Campus Lagoa do Sino.

Documento assinado digitalmente
 ANDRE MARCONDES ANDRADE TOLEDO
Data: 12/11/2025 11:14:18-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. André Marcondes Andrade Toledo
Centro de Ciências da Natureza – UFSCar – Campus Lagoa do Sino.

DEDICATÓRIA

Dedico este trabalho aos meus pais e à minha irmã, pessoas que me acompanharam nesta trajetória.

AGRADECIMENTO

Agradeço ao meu orientador, Paulo Guilherme Molin, e ao meu coorientador, Vinicius Moura Costa, pelo suporte e apoio durante a realização deste trabalho. Também agradeço à Universidade Federal de São Carlos pela oportunidade de cursar Engenharia Ambiental e ao Centro de Pesquisa e Extensão em Geotecnologias, o qual me possibilitou desenvolver habilidades voltadas ao sensoriamento remoto e geotecnologias. O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil. Processo nº 2021/11940-0.

RESUMO

As áreas úmidas são ecossistemas de extrema importância, tanto nacional quanto internacionalmente, mas muitas delas ainda não foram devidamente delineadas, o que dificulta seu monitoramento e proteção. Com o passar dos anos, vários foram os desenvolvimentos no campo de sensoriamento remoto e a aplicação desta prática em conjunto com o uso de inteligência artificial (machine learning, deep learning), permitindo que mapeamentos sejam realizados de forma remota e eficiente. Combinando estes fatores, o delineamento de áreas úmidas têm sido realizado em pesquisas, utilizando diferentes métodos. Esta Revisão Sistemática de Literatura teve como objetivo comparar essas metodologias e definir qual seria a mais adequada para a região do sudoeste paulista, além de discutir o papel da inteligência artificial nestes processos. A partir disso, foi definido que o melhor método seria a aplicação de fluxo híbrido, combinando dados multissensores, aprendizado profundo e segmentação orientada a objetos, sendo capazes de mapear os brejos, campos úmidos e veredas da região, além de destacar que o papel da inteligência artificial é auxiliar no processo, automatizando etapas e reduzindo o tempo necessário para o mapeamento.

Palavras-chave: geotecnologia, mapeamento, procedimento, revisão sistemática de literatura.

ABSTRACT

Wetlands are ecosystems of extreme importance, both nationally and internationally, but many of them have not yet been properly delineated, which hinders their monitoring and protection. Over the years, there have been several developments in the field of remote sensing and the application of this practice in conjunction with the use of artificial intelligence (machine learning, deep learning), allowing mappings to be carried out remotely and efficiently. Combining these factors, the delineation of wetlands has been conducted in research using different methods. This Systematic Literature Review aimed to compare these methodologies and define which would be the most suitable for the southwestern region of São Paulo, in addition to discussing the role of artificial intelligence in these processes. From this, it was determined that the best method would be the application of a hybrid workflow, combining multisensor data, deep learning, and object-based segmentation, being capable of mapping marshes, wet fields, and palm swamps in the region, as well as highlighting that the role of artificial intelligence is to assist in the process, automating stages and reducing the time required for mapping.

Keywords: geotechnology, mapping, procedure, systematic literature review.

LISTA DE ILUSTRAÇÕES

Figura 1: Cidades do Sudoeste Paulista	12
Figura 2: Fluxograma do esquema de filtragem	17
Figura 3: Distribuição de estudos por estado	21
Figura 4: artigos publicados e anos correspondentes	23
Tabela 1: Níveis de aderência para seleção de artigos	14
Tabela 2: Variáveis a serem analisadas	18
Tabela 3: títulos dos artigos	19
Tabela 4: tipos de fonte de dados (sensores) e seu número de aplicações	25
Tabela 5: Sensores e acurácias do mapeamento	25
Tabela 6: Acurácia Geral e resolução das imagens	27
Tabela 7: acurácia geral e método de classificação empregado	21

LISTA DE SIGLAS

CART - Classification And Regression Tree.

CNN - Convolutional Neural Network (rede neural convolucional).

ConvLSTM - Convolutional LSTM (modelo espaço-temporal).

DEM - Modelo Digital de Elevação (Digital Elevation Model).

DT - Decision Tree (árvore de decisão).

GEE - Google Earth Engine.

GEOBIA/OBIA - Geographic / Object-Based Image Analysis (análise orientada a objeto).

GNN - Graph Neural Network.

LiDAR - Light Detection and Ranging.

LPVN - Lei de Proteção da Vegetação Nativa.

MNDWI - Modified Normalized Difference Water Index.

NDVI - Normalized Difference Vegetation Index (Índice de Vegetação).

NDWI - Normalized Difference Water Index (Índice de Água).

PRISMA - Preferred Reporting Items for Systematic reviews and Meta-Analyses.

RF - Random Forest (classificador).

RADAR - Radio Detection And Ranging.

SAR - Synthetic Aperture Radar.

SAVI - Soil Adjusted Vegetation Index.

SIG - Sistemas de Informações Geográficas.

SVM - Support Vector Machine.

U-Net - arquitetura de CNN para segmentação semântica.

USDA NRCS - United States Department of Agriculture Natural Resources Conservation Service.

TWI - Topographic Wetness Index (Índice Topográfico de Umidade).

SUMÁRIO

1. INTRODUÇÃO	1
2. REVISÃO DE LITERATURA	3
2.1. ÁREAS ÚMIDAS	3
2.1.1. ÁREAS ÚMIDAS MUNDIAIS	3
2.1.2. ÁREAS ÚMIDAS DO BRASIL	4
2.1.3. ÁREAS ÚMIDAS DO ESTADO DE SÃO PAULO	5
2.2. SENSORIAMENTO REMOTO	7
2.2.1. SURGIMENTO, FÍSICA E APLICAÇÕES	7
2.2.2. EQUIPAMENTOS UTILIZADOS	8
2.2.3. MÉTODOS DE CLASSIFICAÇÃO	10
3. MATERIAIS E MÉTODOS	12
3.1. REVISÃO SISTEMÁTICA DE LITERATURA	13
3.2. ANÁLISE QUALITATIVA E QUANTITATIVA	18
4. RESULTADOS E DISCUSSÕES	20
4.1. ESTUDOS SELECIONADOS E DISTRIBUIÇÃO REGIONAL	20
4.2. ANÁLISE DOS DADOS	24
4.2.1. VARIAÇÃO CAUSADA DEVIDO AOS SENSORES E DADOS UTILIZADOS	26
4.2.2. RESOLUÇÃO ESPACIAL E ACURÁCIA	29
Tabela 6: Acurácia Geral e resolução das imagens	29
Fonte: autoria própria	30
4.2.3. VARIAÇÃO DA ACURÁCIA DE ACORDO COM O MÉTODO DE CLASSIFICAÇÃO	31
Fonte: autoria própria	32
4.3. APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA DELIMITAÇÃO DE ÁREAS ÚMIDAS	34
4.3.1. APLICAÇÕES OBSERVADAS NOS ESTUDOS SELECIONADOS	34
4.3.2. OUTRAS APLICAÇÕES POSSÍVEIS PARA DELIMITAÇÃO DE ÁREAS ÚMIDAS	35
4.4. DEFINIÇÃO DO MELHOR MÉTODO A SER UTILIZADO NA ÁREA DE INTERESSE	36
4.4.1. CONSIDERANDO APENAS DELIMITAÇÕES DE ÁREAS ÚMIDAS SEMELHANTES	36
4.4.2. CONSIDERANDO TODOS OS ESTUDOS SELECIONADOS	38
CONSIDERAÇÕES FINAIS	41
APÊNDICE A - INFORMAÇÕES SOBRE AS PESQUISAS SELECIONADAS	55
APÊNDICE B - LISTA DE ARTIGOS SELECIONADOS APÓS LEITURA DO TÍTULO E ABSTRACT	71

1. INTRODUÇÃO

Áreas úmidas são definidas como ecossistemas associados a solos temporariamente ou permanentemente saturados por água, apresentando composições vegetais e fisionomias distintas das áreas bem drenadas à sua volta. No Cerrado, por exemplo, os “campos úmidos” são diferenciados devido à sua vegetação herbácea e arbustiva distribuída de forma heterogênea, que se desenvolve por depressões de terrenos onde há excedente hídrico superficial e solos com pouca drenagem, como organossolos, caracterizando, assim, verdadeiros reservatórios de água e refúgios de biodiversidade em meio árido, abrigando enorme diversidade de fauna e flora, entre elas, espécies endêmicas (Sousa e Lombardi, 2016).

Apesar de toda sua importância ambiental, as áreas úmidas se encontram entre os ecossistemas mais ameaçados em todo o mundo. Durante os últimos anos, grandes empreendimentos agroindustriais, projetos de drenagem para agricultura, obras de infraestrutura civil e obras de hidrelétricas vêm causando a degradação desses sistemas, levando à degradação e redução destes ambientes. Por exemplo, houve a redução de 5,7% na extensão de áreas úmidas do Pantanal entre 1992 e 2022, o que comprometeu serviços hidrológicos, socioambientais, econômicos e bióticos (Justino *et al.*, 2025; Nunes da Cunha *et al.*, 2015).

Previamente à definição de programas de conservação ou manejo sustentável, é necessário que haja a delimitação das áreas úmidas, pois estabelece seus limites e sua conexão com outros corpos hídricos. Para este fim, ferramentas de geoprocessamento e o uso de Sistemas de Informações Geográficas (SIG) têm se tornado indispensáveis, pois permitem que a delimitação das áreas úmidas sejam feitas sem a necessidade de visita a campo, proporcionando economia financeira e de tempo (Guasselli *et al.*, 2020).

Plataformas de Sensoriamento Remoto, como os satélites *Landsat* e *Sentinel*, trabalhando em conjunto com Sistema de Informações Geográficas (SIG), possibilitam que mapeamentos multi-temporais sejam realizados, detectando alterações no uso e ocupação do solo e na dinâmica dos corpos d'água através dos anos. Técnicas de classificação supervisionada ou não-supervisionadas, utilizadas com dados *Radio Detection And Ranging* (RADAR) ou *Light Detection and Ranging* (LiDAR), podem definir de melhor forma os limites das áreas úmidas,

diferenciando-as de simples depressões com acúmulo de água ou manchas sazonais na vegetação (Silva *et al.*, 2020).

Devido às diferentes ferramentas de geoprocessamento e métodos capazes de realizar o mapeamento de áreas úmidas, lacunas podem surgir, desta forma, a Revisão Sistemática de Literatura é um método de pesquisa adequado para se identificar essas lacunas, se caracterizando por ser um método estruturado de busca, seleção e análise crítica de estudos sobre um tema específico. O aumento do volume de publicações, o avanço das tecnologias de sensoriamento remoto e a crescente aplicação de técnicas de inteligência artificial (IA) na delimitação de áreas úmidas tornam pertinente a investigação da produção científica sobre estes tópicos no Brasil, realizando a avaliação sob enfoques tanto qualitativos quanto quantitativos (Jafarzadeh *et al.*, 2022).

A realização desta revisão tem como objetivo principal obter uma lista de melhores métodos de delimitação de áreas úmidas para o sudoeste paulista, além de discutir o papel da inteligência artificial nesses procedimentos. Para isso, serão analisados os tipos de sensores, aplicações, intervalo temporal e a acurácia obtida pelos estudos selecionados, buscando determinar as variáveis que afetam o resultado final. Será analisada a quantidade de artigos produzidos sobre esse tema durante os últimos dez anos (2015-2025) e seus resultados, com o intuito de analisá-los qualitativamente. A partir disso, será possível determinar qual combinação de sensores, métodos de classificação, acurácia obtida e demais variáveis é mais adequada para o contexto encontrado no sudoeste paulista. Perguntas como “qual o melhor método a ser utilizado na região sudoeste do Estado de São Paulo?”, “a inteligência artificial é utilizada? de qual forma?”, “como os diferentes tipos de sensores, métodos de classificação e demais variáveis afetam a acurácia obtida nos estudos?” tendem a ser respondidas a fim da obtenção dos melhores resultados.

2. REVISÃO DE LITERATURA

2.1. ÁREAS ÚMIDAS

2.1.1. ÁREAS ÚMIDAS MUNDIAIS

As áreas úmidas são ecossistemas em que a presença de água é o principal fator físico a determinar condições ambientais e a biota associada, sendo classificadas como pântanos, turfeiras, várzeas, veredas, manguezais, entre outras, uma vez que existem dezenas de tipos de áreas úmidas. A definição adotada pela Convenção de Ramsar é altamente ampla para abarcar a diversidade funcional e morfológica destes ecossistemas (Ramsar, 2016). Mundialmente, a conservação de áreas úmidas é tratada por mecanismos internacionais, como a própria Convenção de Ramsar, as quais promovem o uso racional e a inclusão de sítios de importância internacional. Esses ecossistemas fornecem serviços ecossistêmicos essenciais: regulação hídrica, habitat para aves migratórias e espécies endêmicas, proteção costeira e armazenamento de carbono (Ramsar, 2023).

De maneira geral, elas ocorrem próximas a cursos d'água, nascentes ou vales, onde o lençol freático permanece em nível raso ou aflora, tornando o solo saturado permanentemente ou temporariamente, havendo diferentes tipos de áreas úmidas de acordo com sua localização geográfica (INAU, 2024). Nestas condições, há o desenvolvimento de processos naturais, como a redução do oxigênio, restringindo o ambiente a somente espécies com adaptações morfofisiológicas específicas, capazes de sobreviver ao excedente hídrico e aos processos de anóxia e hipóxia (Ribeiro e Walter, 1998).

No quesito caracterização florística e estrutural, as áreas úmidas exibem comunidades formadas por vegetação herbácea, com estrato subarbustivo pouco desenvolvido em regiões como o cerrado, e apresentam formações florestais para áreas de manguezais, por exemplo (Durigan *et al.*, 2022). Estas áreas possuem o papel de hotspots de diversidade, abrigando rica diversidade de fauna e flora e apresentando baixa similaridade florística ao se comparar com outros sítios, até mesmo entre aqueles geograficamente próximos. Além disso, tipos e distribuição de solo, flutuações do nível do lençol freático e variação topográfica influenciam diretamente nas dinâmicas sazonais de floração, brotamento e frutificação, além de influenciar na distribuição espacial das espécies (Tannus, 2007).

Sítios Ramsar são locais com presença de áreas úmidas de importância internacional designada sob a Convenção de Ramsar, tratado que busca a conservação e uso sustentável e racional destes ecossistemas, firmado em 1971. Existem milhares de sítios Ramsar designados no planeta, possuindo variadas extensões entre eles, sendo de poucos a milhares de hectares, o que ilustra tanto a grandeza quanto a fragmentação espacial das áreas úmidas de valor internacional (Ramsar, 2023). Mesmo com todo seu valor, as áreas úmidas enfrentam ameaças antrópicas: poluição difusa e pontual; drenagem e conversão para agricultura e infraestrutura e pressões antrópicas costeiras, entre outras. Essas pressões podem levar à perda de conectividade hidrológica e declínio dos serviços ecossistêmicos, necessitando de políticas integradas de gestão da água e do uso e conservação do solo (Ramsar, 2016).

2.1.2. ÁREAS ÚMIDAS DO BRASIL

O Brasil possui uma enorme variedade de áreas úmidas costeiras e continentais, sendo elas: Pantanal, veredas, brejos, várzeas, banhados, campos úmidos, turfeiras, manguezais e restingas. Juntas ocupam uma parcela significativa da extensão territorial nacional e oferecem serviços fundamentais, sendo indicadas por inventários recentes como ocupantes de 20% do território nacional com alta necessidade de proteção e que ainda não apresentam delimitação adequada em sua maior parte (INAU, 2024). Em relação ao reconhecimento internacional, o Brasil detém dezenas de sítios Ramsar e suas designações ajudam a colocar regiões sensíveis no radar de políticas públicas, mesmo assim, apenas uma pequena fração de das áreas úmidas brasileiras está formalmente protegida ou com planos de manejo integrados, o que torna prioritária a ampliação do reconhecimento técnico e legal (Brasil, 2018; Ribeiro *et al.*, 2020).

No país, a delimitação de Sítios Ramsar é fundamental para a promoção de visibilidade de áreas úmidas ameaçadas e sua proteção, fazendo parte das categorias de unidades de conservação nacionais. Entretanto, apenas parte das áreas úmidas brasileiras fazem parte desta designação, tornando evidente a necessidade de ampliação no reconhecimento destas áreas e a necessidade de se fortalecer os mecanismos de gestão e monitoramento (Ribeiro *et al.*, 2020; Durigan *et al.*, 2022).

O Inventário de Áreas Úmidas Brasileiras reforça que cerca de 20% do território nacional abriga áreas úmidas, com grande parte delas distribuídas nos biomas Cerrado, Pantanal e Amazônia (INAU, 2024). Entretanto, a maior parte destas áreas não possui delimitação sistemática ou diretrizes de manejo adequadas, o que possibilita sua conversão para usos agropecuários e facilita a contaminação por resíduos domésticos e industriais (INAU, 2024). O país conta com 27 Sítios Ramsar, abrangendo 268.944 km² e sendo o país que possui maior representatividade de zonas úmidas com o selo Ramsar, sendo o Sítio Ramsar Rio Negro um dos maiores do mundo, possuindo 12 milhões de hectares (Brasil, 2018).

Uma vez delimitadas, as áreas úmidas podem ser caracterizadas de acordo com sua fisiografia e o atual uso do solo onde se encontra, identificando medidas a serem tomadas para garantir sua proteção e manutenção ecossistêmica. No Cerrado ao norte do país, a análise do uso e ocupação do solo feita através do uso de SIG combinada com a aplicação do Sistema Brasileiro de Classificação de Áreas Úmidas possibilitou a identificação de oito macro-habitats diferenciados, sendo suscetíveis à pressão de atividades agrícolas em seu entorno e necessitando de proteção (Oliveira e Bayer; 2024).

2.1.3. ÁREAS ÚMIDAS DO ESTADO DE SÃO PAULO

A macrorregião sudoeste paulista é composta pelas cidades de Apiaí, Barão de Antonina, Barra do Chapéu, Bom Sucesso de Itararé, Buri, Campina do Monte Alegre, Capão Bonito, entre outras (Diretório Estadual, 2025). A região se localiza sobre uma faixa de transição geomorfológica onde pequenas depressões topográficas e relevo levemente ondulado condicionam a ocorrência de áreas úmidas de cabeceira e brejos, os quais possuem dinâmica hidrológica fortemente influenciada por fluxos subsuperficiais e contribuições superficiais ininterruptas. Para o monitoramento adequado deste tipo de área é necessário o uso de sensoriamento remoto, utilizando imagens multi-temporais para a delimitação correta, devido à essas dinâmicas sazonais (Furlan *et al.*, 2023).

Tratando-se de um olhar ecológico, áreas úmidas de menor escala no interior do estado apresentam solos hidromórficos e acúmulo de matéria orgânica e possui vegetação caracterizada por graminóides e briófitas adaptadas a alteração no regime hidrológico e à saturação hídrica. A resistência destas áreas é limitada, sendo afetadas por atividades como drenagens, assoreamento, conversão para

lavoura e compactação para uso como pasto reduzem drasticamente a conectividade hidrológica e a integridade ambiental. Devido a isto, inventários de campo são indispensáveis às análises remotas, pois fornecem cobertura espacial e série temporal necessárias para extrapolar padrões detectados em campo e monitorar mudanças ao longo das datas (Sousa e Lombardi, 2016).

No sudoeste paulista as áreas úmidas mais frequentes são campos úmidos isolados e brejos de cabeceira, os quais ocorrem em depressões onde o lençol freático aflora para a superfície, possuindo mantos menos permeáveis e apresentando retenção hídrica entre o permanente e o sazonal. A contribuição subsuperficial é frequentemente relevante, afetando diretamente as estratégias de proteção e restauração que não considerem apenas a drenagem superficial (Casagrande *et al.*, 2021).

Várzeas de baixa ordem e faixas ripárias também fazem parte das áreas úmidas encontradas na região. Mesmo quando se tratam de faixas estreitas, matas ciliares e várzeas associadas a córregos e riachos do sudoeste paulista funcionam como corredores de conectividade entre os corpos hídricos, além de auxiliarem na manutenção da dinâmica ecossistêmica, porém, devido à atividades antrópicas, estas áreas também têm corrido riscos, uma vez que práticas como desmatamento, pisoteio de gado e drenagem são realizadas, alterando a vegetação de margem, logo, reforça-se a prioridade dessas faixas em políticas de conservação (Sanchez *et al.*, 2012).

As áreas úmidas consistem em ecossistemas onde a presença persistente ou recorrente de água na superfície e no perfil do solo determina condições edáficas, hidrológicas e fitofisionômicas particulares que as distinguem das paisagens vizinhas. Essa especificidade funcional e estrutural torna o reconhecimento cartográfico uma condição necessária para identificar unidades ecologicamente relevantes, compreender sua conectividade hidrológica e estimar a capacidade de prestação de serviços como retenção de sedimentos, regulação hídrica e suporte à biodiversidade (Ribeiro e Walter, 1998).

A exigência de delimitação técnica assume contornos legais com a Lei de Proteção da Vegetação Nativa (LPVN), que redefine parâmetros para Áreas de Preservação Permanente (APP) e Reserva Legal, impondo a necessidade de produtos cartográficos precisos para a aplicação de restrições, definição de medidas compensatórias e tomada de decisões administrativas relativas a uso e recuperação

do solo. Além disso, áreas úmidas podem ser definidas como nascentes difusas, ou seja, de acordo com a LPVN, ela precisa de APP ao seu redor para manter sua integridade (Brasil, 2012).

Diante desse enquadramento normativo, é urgente produzir mapas de áreas úmidas que sejam simultaneamente cientificamente robustos e juridicamente aceitos, pois apenas informações espaciais reproduzíveis e auditáveis permitem que órgãos ambientais e proprietários identifiquem limites de preservação, planejem intervenções, monitorem alterações e apliquem instrumentos de gestão e priorização para conservação ou restauração (INAU, 2024).

2.2. SENSORIAMENTO REMOTO

2.2.1. SURGIMENTO, FÍSICA E APLICAÇÕES

O surgimento do sensoriamento remoto parte da fotografia aérea do século XIX e à utilização de plataformas aéreas de observação, como pipas, pombos-correio e balões, seguido de aviões após as guerras mundiais, uma vez que técnicas fotográficas e radares começaram a ser utilizadas sistematicamente para mapeamento e reconhecimento. O sensoriamento remoto consolidou-se com o advento de satélites meteorológicos e de observação terrestre nas décadas de 1960-1970, posteriormente passando por ciclos de rápida evolução tecnológica e computacional que tornaram possível o uso operacional de imagens hiperespectrais e multiespectrais em larga escala (Moore, 1979).

Seu funcionamento físico baseia-se na detecção da energia eletromagnética emitida ou refletida pelos alvos terrestres. Sensores ativos (RADAR/SAR, LiDAR) emitem sua própria energia e registram o retorno, permitindo observação independente da iluminação solar, enquanto sensores passivos (câmeras multiespectrais/hiperespectrais, radiômetros) medem radiação solar refletida ou emissão térmica. A interação entre a onda eletromagnética e a superfície (absorção, reflexão, transmissão, espalhamento) é governada por propriedades como composição, textura e umidade, o que torna possível discriminar tipos de cobertura e estados fenológicos a partir de assinaturas espectrais e características de espalhamento (NASA EARTHDATA, 2025).

Os principais tipos de sensores utilizados atualmente incluem imagens ópticas multiespectrais, sensores hiperespectrais que capturam centenas de bandas para análise espectral fina, LiDAR que mede topografia e estrutura vertical por

tempo de voo e pulsos a laser e radares de abertura sintética (SAR) detectam espalhamento em microestrutura e umidade do solo. Cada uma dessas tecnologias possui suas vantagens e limitações, logo, a combinação multi-sensor tem se tornado prática comum na identificação de propriedades hidrológicas e estruturais em áreas úmidas e outros alvos (Lang, Mccarty; 2014).

Nas últimas décadas, avanços metodológicos e computacionais transformaram o processamento de dados de sensoriamento remoto: algoritmos de classificação baseados em aprendizado de máquina e redes neurais profundas melhoraram a precisão e automação. Além disso, plataformas de processamento em nuvem, como Google Earth Engine, democratizaram o acesso a séries temporais históricas e processamento em escala mundial, tornando viáveis análises multitemporais robustas e detecção de mudanças (Gorelick *et al.*, 2017; Jafarzadeh *et al.*, 2022). As aplicações de sensoriamento remoto são muitas: mapeamento e monitoramento de áreas úmidas, inventários florestais e de biomassa, detecção de alterações no uso e ocupação do solo, monitoramento agrícola, apoio a políticas ambientais e planejamento territorial (Rapinel *et al.*, 2023; Jafarzadeh *et al.*, 2022).

Alguns softwares utilizados nestes processos são livres, ou seja, podem ser utilizados gratuitamente por toda população e contam com complementos que possibilitam diferentes processos. O Water Plugin, complemento do software QGIS, é um exemplo de ferramenta de extração automática de zonas alagáveis, podendo ser utilizada para obtenção de mapas precisos e dinâmicos. A partir disto, áreas com risco de inundação ou degradação pertencentes às áreas úmidas são definidas e servem como informação para diagnósticos ambientais, aplicação de métodos de conservação e licenciamento ambiental (Santos Filho *et al.*, 2021).

2.2.2. EQUIPAMENTOS UTILIZADOS

O sensoriamento remoto conta com uma série de equipamentos, como satélites (constelações e missões singulares), sensores fixos ou móveis em campo e aeronaves tripuladas e não tripuladas (UAV/UAS). Satélites como *Landsat*, missões Sentinel e constelações comerciais (*Planet*, *RapidEye*) carregam sensores multiespectrais e oferecem cobertura sistemática e séries temporais que viabilizam o monitoramento regional e global. Aeronaves e UAS possuem a capacidade de carregar sensores semelhantes em altitudes mais baixas, permitindo aumento da

resolução espacial e maior flexibilidade operacional em estudos locais e em missões de validação de campo. (Gorelick *et al.*, 2017; Pricope *et al.*, 2020).

Sensores ópticos capturam radiação solar refletida em bandas discretas, desde multiespectrais e hiperespectrais até pancromáticas, e são comumente embarcados em plataformas de satélites (*Landsat OLI/TIRS*, *Sentinel-2*, constelações *Planet/RapidEye*, sensores de alta resolução como *WorldView*) ou em câmeras em UAV. Esses sensores possibilitam a derivação de índices espectrais (NDVI, NDWI/MNDWI) e mapeamento de uso do solo. Sua limitação principal é a sensibilidade à presença de nuvens e iluminação, razão pela qual as escolhas de sensor e janela temporal são determinantes críticas para estudo de áreas úmidas, por exemplo (USGS/Landsat, 2025; Phiri, 2020; Heumann, 2011).

Os sensores SAR (radar de abertura sintética) são equipamentos ativos, os quais emitem microondas e medem o sinal de retorno, sendo capazes de operar sem depender da cobertura de nuvens ou da luz solar. Variantes em bandas e modos de polarização (VV, VH, HH, HV) conferem diferentes sensibilidades à umidade, presença de água ou inundações e estrutura da vegetação, além de possibilitar análises temporais por intensidade e coerência (InSAR) para detecção de inundação e variabilidade hidrológica. Desta forma, podemos definir os equipamentos SAR como ferramentas essenciais em regiões tropicais e em períodos chuvosos (Canisius *et al.*, 2019; Rapinel *et al.*, 2020).

O LiDAR (*Light Detection And Ranging*) e derivados altimétricos constituem um conjunto de equipamentos fundamentais para caracterizar a estrutura vertical da vegetação e microfotografias. Sistemas aerotransportados (LiDAR aéreo) ou embarcados em UAS geram nuvens de pontos que, após processamento para georreferenciamento, permitem produzir DEMs/DTMs precisos, derivar índices topográficos e estimar batimetria rasa em certos cenários, os quais são fundamentais para delimitar áreas úmidas e modelar sua conectividade hidrológica (Lang; Mccarty, 2014; Pricope *et al.*, 2020).

Recentemente, Korb *et al.* (2025) aplicaram índices espectrais e análise de componentes principais para avaliação da variação hidrogeomorfológica em zonas úmidas costeiras no Parque Nacional de Lagoa do Peixe (RS). Foram identificados padrões de degradação associados à intensificação de eventos extremos, como secas e enchentes, e destacadas áreas com mudanças marcantes através das estações, destacando a importância do monitoramento contínuo por sensoriamento

remoto e estratégias de manejo adaptativo para se garantir a resiliência ecossistêmica (Korb *et al.*, 2025).

Em termos operacionais, o sensoriamento remoto fornece a capacidade de geração de dados em escala e com recorrência temporal necessária para inventários e monitoramento de áreas úmidas: séries multitemporais de imagens ópticas possibilitam o cálculo de índices espectrais e a análise fenológica que distinguem superfícies permanentemente encharcadas de áreas sazonalmente inundadas, contribuindo para a caracterização temporal e espacial das feições úmidas (Guasselli *et al.*, 2020).

Contudo, limitações inerentes ao sensoriamento óptico, sobretudo a dependência de condições atmosféricas favoráveis, demandam a integração com observações de radar de abertura sintética. O *Synthetic Aperture Radar* (SAR) é um sistema de radar que utiliza ondas de rádio para criar imagens detalhadas da superfície terrestre, fornecendo dados confiáveis. A fusão entre óptico e SAR explora complementaridades essenciais, como o óptico que identifica sinais espectrais de vegetação e água exposta, enquanto o SAR acrescenta sensibilidade à umidade e à estrutura superficial, resultando em etapas de processamento multissensoriais que reduzem erros e elevam métricas de acurácia na delimitação de manchas úmidas (Simioni *et al.*, 2020).

A precisão do delineamento também é fortemente influenciada por preditores altimétricos que revelam microrrelevos, depressões e padrões de acumulação de água: modelos digitais de elevação e dados LiDAR permitem identificar linhas de convergência de fluxo e variações de cota que controlam a hidrologia local, sobretudo em cenários onde diferenças de poucos centímetros determinam transições ecológicas; apesar do custo e da cobertura limitada, o emprego pontual de LiDAR eleva substancialmente a qualidade das fronteiras mapeadas (USDA NRCS, 2014; Furlan *et al.*, 2023).

2.2.3. MÉTODOS DE CLASSIFICAÇÃO

Métodos de classificação são procedimentos, baseados em regras ou algoritmos, que transformam dados de sensoriamento remoto em mapas temáticos, atribuindo classes a objetos ou pixels. Dividem-se em supervisionados, não supervisionados e baseados em regras, os quais a escolha depende do objetivo da pesquisa, da resolução dos sensores e da disponibilidade das amostras de campo.

Para feições com forma e contexto espacial específicos, GEOBIA, a qual segmenta a imagem em regiões homogêneas (objetos), que possuem forma, textura, contexto e relações espaciais e usa essas características para fazer a classificação, costuma superar abordagens *pixel-based* (quando os pixels são classificados de acordo com seus valores), mas quando a série temporal é o foco, classificadores *pixel-based* robustos, como Random Forest ou Decision Tree, exibem resultados satisfatórios e são menos exigentes em qualidade de dados (Dronova, 2015; Lu; Weng, 2007).

No uso de GEOBIA, o fluxo é de extrema importância, sendo dividida em segmentação (criação dos objetos) e classificação dos atributos dos objetos. A parametrização da segmentação é essencial, pois escalas inadequadas comprometem os resultados, seguida da aplicação de classificadores guiados por campo (*k-NN*, *decision trees*, *Random Forest*) que utilizam atributos geométricos, espectrais e texturais, entregando boa acurácia quando as amostras são representativas (Heumann, 2011; Zhou *et al.*, 2021).

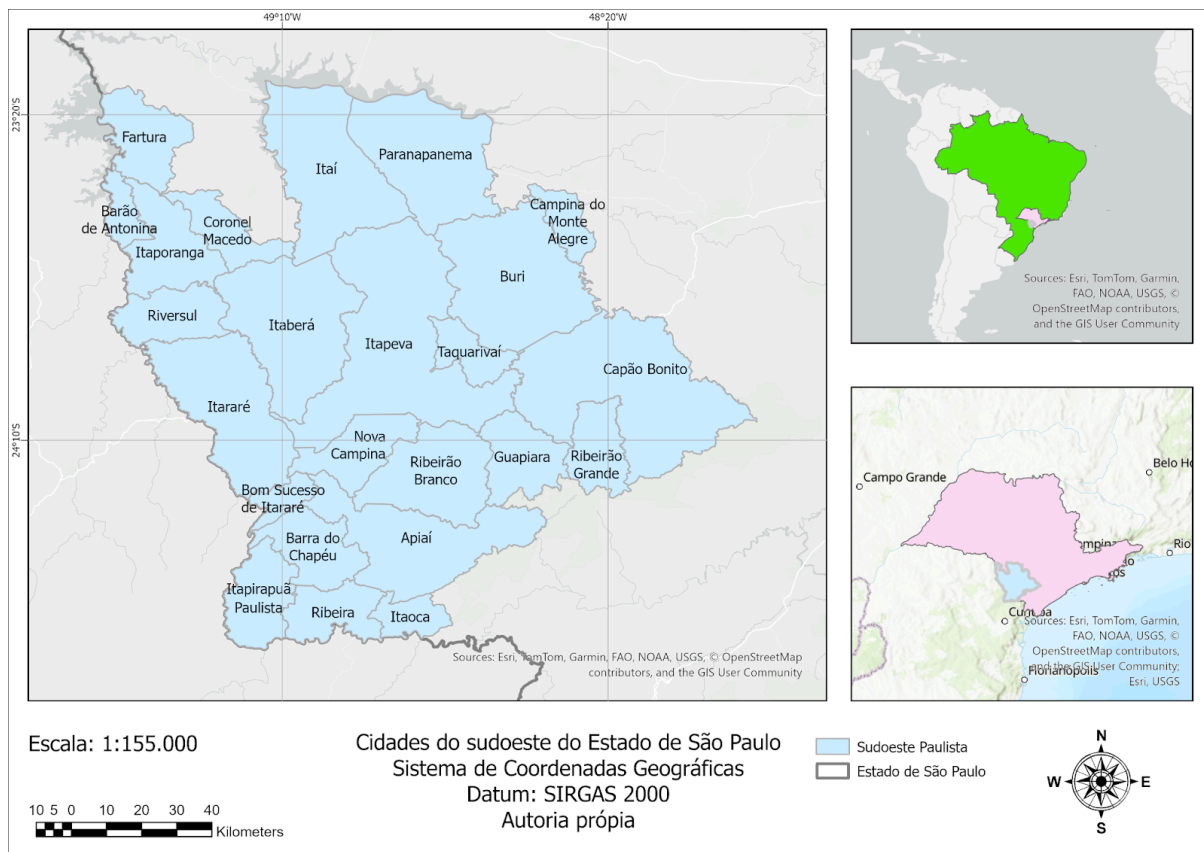
Em fluxo *pixel-based*, *Decision Tree* (CART), *K-means* e *Random Forest* continuam úteis, combinado com estratégias rápidas que incluem *thresholding* sobre estatísticas temporais para detectar presença de água, tende a apresentar resultados satisfatórios. A fusão de OBIA e *data-mining* e a incorporação de variáveis auxiliares, como DEM (Modelos Digitais de Elevação), índices espectrais ou derivadas SAR, reduzem falsos positivos e melhoram a robustez em ambientes hidrológicos dinâmicos. (Jafarzadeh *et al.*, 2022; Rapinel *et al.*, 2020; Guasselli *et al.*, 2020). A combinação entre GEOBIA e *Random Forest* extraem padrões espaciais complexos e tendem a maior precisão em alta resolução, mas exigem muitos rótulos e poder computacional (Ronneberger *et al.*, 2015).

No plano metodológico, fluxos que combinam segmentação orientada a objetos e classificadores *ensemble* têm se mostrado eficazes para preservar coerência ecológica e reduzir ruído espacial: a abordagem orientada a objetos agrega pixels em unidades morfologicamente e espectralmente coerentes, permitindo o uso de atributos geométricos e texturais, enquanto classificadores como RF asseguram robustez frente a preditores correlacionados; redes neurais profundas podem oferecer refinamentos onde existe base rotulada abundante e capacidade computacional apropriada (Dronova, 2015).

Em relação ao uso de sensoriamento remoto na delimitação de áreas úmidas, apesar dos avanços metodológicos, persistem lacunas relevantes: há carência de

protocolos padronizados de validação multitemporal que capturem sazonalidade e pequenas manchas, dificuldades na transferência de modelos entre bacias hidrográficas distintas, escassez de bases rotuladas que inviabiliza o emprego pleno de arquiteturas profundas e cobertura restrita de LiDAR em larga escala; essas limitações evidenciam a necessidade de fluxos integrados: fusão óptico/SAR/topografia, estratégias de transferência de aprendizado e protocolos de validação estratificados; para produzir produtos de delineamento robustos, reproduzíveis e aptos a sustentar as exigências da LPVN (Mahdianpari *et al.*, 2020; Simioni *et al.*, 2020). A figura 1 destaca o sudoeste paulista e as cidades que o compõem.

Figura 1: Cidades do Sudoeste Paulista



Fonte: autoria própria

3. MATERIAIS E MÉTODOS

Este trabalho foi desenvolvido através de duas etapas, a revisão sistemática de literatura, para a seleção dos artigos utilizados como referencial teórico e a análise quantitativa e qualitativa dos artigos escolhidos.

3.1. REVISÃO SISTEMÁTICA DE LITERATURA

A revisão sistemática de literatura se trata de uma metodologia de pesquisa utilizada tanto para pesquisas qualitativas quanto para pesquisas quantitativas. Este método científico é utilizado para o desenvolvimento de pesquisas de uma determinada área, se destacando por seu rigor metodológico, por sua transparência e por permitir rastreabilidade (Ramos *et al.*, 2014).

O planejamento busca guiar a pesquisa para que sejam obtidos resultados adequados ao que se propõe. Para auxílio nesta etapa, foi seguida a recomendação PRISMA (*Preferred Reporting Items for Systematic reviews and Meta-Analyses*), apresentando um checklist a ser preenchido, do qual os itens de interesse para esta pesquisa são: objetivo de pesquisa, recorte temporal, tipo de fonte considerada e critérios de inclusão/exclusão. A recomendação PRISMA também disponibiliza um fluxograma para preenchimento ao se realizar novas revisões sistemáticas, sendo dividida em identificação, triagem, elegibilidade e incluídos, etapas que devem ser seguidas até o final da revisão sistemática (Taveira *et al.*, 2018; Moher *et al.*, 2015). Para esta pesquisa, foi gerado um fluxograma adaptado.

O levantamento bibliométrico foi realizado por meio de testes de aderência e combinações de palavras-chave, como: *remote sensing*, *wetlands*, *deep learning*, *mangrove*, *satellite data* e *artificial intelligence*. Foram selecionados artigos que abordam pesquisas realizadas no Brasil. Este procedimento tem como objetivo a avaliação dos resultados obtidos e a pertinência dos termos utilizados, mensurando o retorno das palavras utilizadas e suas combinações nas bases de dados *Web of Science* e *Scopus*, selecionando os artigos manualmente e organizando em planilha. O teste de aderência tem como objetivo a eliminação das palavras que não apresentam relação direta com o tema ou não apresentam resultados satisfatórios. Todas as etapas serão organizadas em planilhas do Google Sheets.

Em relação à seleção do corpus, é necessário que haja filtragem dos artigos que o compõe, iniciando-se pela exclusão dos artigos duplicados e seguido pela leitura dinâmica do material encontrado, focado na análise de elementos textuais como título, palavras-chave, resumo e, quando pertinente, os resultados. Este momento tem como propósito realizar a triagem inicial, permitindo a identificação dos documentos que possuem aderência direta aos objetivos da pesquisa. Artigos que possuam alinhamento com a temática proposta serão selecionados a fazerem

parte do referencial teórico, principalmente aqueles cujo autores possuem maior relevância na área de estudo.

Como apoio à seleção dos artigos, foi utilizado o método multicritério adaptado de Basílio *et al.*, 2022, que considera quatro níveis de aderência para os artigos analisados, como pode ser observado na tabela 1:

Tabela 1: Níveis de aderência para seleção de artigos

Nível de aderência	Definição
0	artigo que utiliza uma ou mais das palavras-chave, mas não se relaciona com os objetivos deste trabalho.
1	artigo que apresenta informações interessantes à pesquisa, mas não aborda o tema de forma completa
2	artigo que supre critérios de desempate: citações, fator de impacto, ano de publicação e relevância dos autores
3	artigo que apresenta relação de ao menos dois dos conceitos centrais (palavras-chave)

Fonte: adaptado de Basílio *et al.*, 2022.

Artigos que possuem aderência 3 foram incluídos no corpus da pesquisa, artigos de aderência 2 também foram incluídos, de acordo com sua relevância para o estudo. Os artigos de aderência 1 foram selecionados para servir como fontes de informações pontuais, enquanto aqueles que possuem aderência 0 foram descartados. O corpus dinâmico é composto por artigos produzidos no intervalo de dez anos (2015-2025), artigos de anos anteriores fazem parte do corpus estático, formado por publicações previamente consolidadas na literatura científica. Inicialmente, o número de citações seria um dos fatores considerados, porém, o número de artigos retornados e que se enquadravam no tema era baixo, logo, este critério se tornou redundante.

Além das palavras-chave determinadas inicialmente, mais palavras chaves foram adicionadas a partir do aprofundamento da pesquisa e testes utilizando *query* em ambas as bases de dados citadas anteriormente. Após rigorosa execução das etapas previamente delimitadas, a pesquisa conta com um referencial teórico sólido e criteriosamente selecionado. Isso assegura não apenas a profundidade e

consistência da fundamentação conceitual, mas também a transparência do processo investigativo. Com base em critérios de inclusão e exclusão devidamente justificados e em protocolos claros, foi possível avaliar de forma confiável as evidências disponíveis. Desta forma, espera-se que os resultados obtidos reflitam fielmente o estado da arte sobre o tema.

Para realizar esta pesquisa, foram utilizados dois *queries*, os quais podem ser observados posteriormente, sendo um para *Web of Science* e outro para *Scopus*, obtendo 670 e 941 artigos como resultado, respectivamente. Como pode ser examinado na figura 1, a seleção dos artigos ocorreu através de quatro passos: pesquisa utilizando os *queries*, obtendo 1611 artigos no total; leitura dos títulos e, quando necessário, dos resumos, resultando em 73 artigos; seguido da remoção dos artigos duplicados, o que resultou em 57 artigos; por fim, foi feita a leitura dinâmica da metodologia e resultados dos artigos em que havia dúvidas se realmente se encaixavam no objetivo do estudo, resultando em 16 artigos, os quais foram utilizados como base para esta pesquisa. Como o objetivo desta pesquisa envolve o mapeamento de áreas úmidas, todos os artigos que não apresentavam esta etapa foram desconsiderados, inclusive aqueles que faziam somente a classificação da tipologia das áreas úmidas, sem realizar mapeamento/delimitação.

Para *Web of Science*:

TS= (*wetland** OR *marsh** OR *peat** OR "wet meadow*" OR *fen** OR *bog** OR *swamp** OR *floodplain** OR *Mire** OR *Mudflat** OR *mangrove* OR "Tidal flat" OR *lacustrine* OR *riverine* OR *palustrine* OR *estuarine* OR *marine* OR *vernal* OR *ephemeral* OR *seasonal* OR *temporary* OR *slob** *bottom** OR *carr** OR *muskeg*)

AND

TS= ("remote sensing" OR "satellite imag*" OR "Machine learning" OR "deep learning" OR "Artificial intelligence" OR "satellite data" OR "earth observation" OR *NDVI* OR *NDWI* OR "vegetation index" OR *EVI* OR *NDRI* OR "aerial imag*" OR *geospatial* OR *GIS* OR "geographic information system*" OR *multispectral* OR *hyperspectral* OR *Landsat* OR *Sentinel* OR *MODIS* OR *LiDAR* OR *Radar* OR *photogrammetry* OR *drone* OR *RPAS* OR *UAV* OR *UAS* OR *RPA* OR "remotely piloted aircraft" OR "unmanned aerial vehicle" OR "unmanned aerial system" OR "Earth Observation" OR "Satellite Imagery" OR "Satellite Remote Sensing" OR "Aerial Remote Sensing" OR "Geospatial Sensing" OR "Spaceborne Observation" OR "Airborne Observation" OR "Geospatial Remote Sensing" OR "Remote Observation" OR "Imaging from Afar" OR "Earth Monitoring via Satellites" OR "Spectral Sensing" OR "Remote Data Acquisition")

AND

TS= (zoning OR zone OR "site selection" OR "area selection" OR map* OR identificat* OR target* OR "spatial planning" OR delimitat*)*

AND

TS= Brazil

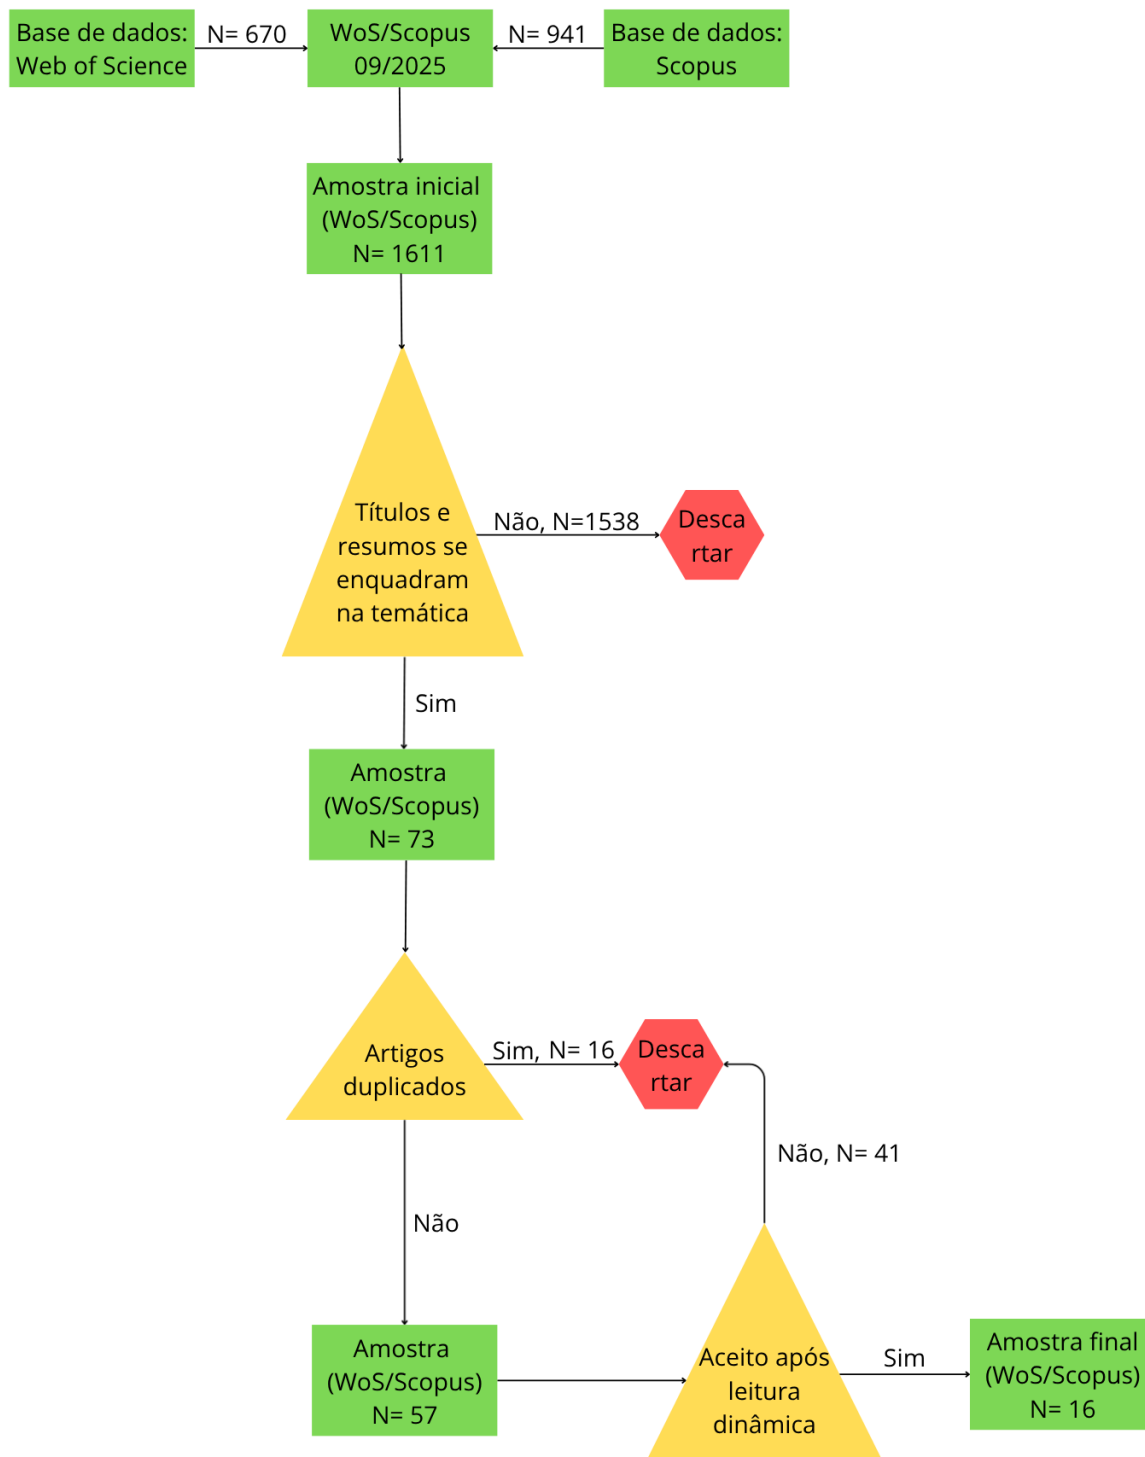
Data: 15 set. 2025.

Para Scopus:

(TITLE-ABS-KEY(wetland OR marsh* OR peat* OR "wet meadow*" OR fen* OR bog* OR swamp* OR floodplain* OR mire OR mudflat* OR mangrove OR "tidal flat" OR lacustrine OR riverine OR palustrine OR estuarine OR marine OR vernal OR ephemeral OR seasonal OR temporary OR slob* OR bottom* OR carr* OR muskeg) AND TITLE-ABS-KEY("remote sensing" OR "satellite imagery" OR "machine learning" OR "deep learning" OR "artificial intelligence" OR "satellite data" OR "earth observation" OR NDVI OR NDWI OR "vegetation index" OR EVI OR NDRI OR "aerial imag*" OR geospatial OR GIS OR "geographic information system*" OR multispectral OR hyperspectral OR Landsat OR Sentinel OR MODIS OR LiDAR OR RADAR OR photogrammetry OR drone OR RPAS OR UAV OR UAS OR RPA OR "remotely piloted aircraft" OR "unmanned aerial vehicle" OR "unmanned aerial system" OR "satellite remote sensing" OR "aerial remote sensing" OR "geospatial sensing" OR "spaceborne observation" OR "airborne observation" OR "geospatial remote sensing" OR "remote observation" OR "imaging from afar" OR "earth monitoring via satellites" OR "spectral sensing" OR "remote data acquisition") AND TITLE-ABS-KEY(zoning OR zone* OR "site selection" OR "area selection" OR map* OR identif* OR target* OR "spatial planning" OR delimit*) AND TITLE-ABS-KEY(brazil))*

Data: 16 set. 2025.

A figura 2 apresenta o fluxograma da filtragem realizada nesta pesquisa:

Figura 2: Fluxograma do esquema de filtragem

Fonte: autoria própria

3.2. ANÁLISE QUALITATIVA E QUANTITATIVA

Baseando-se na metodologia de Mahdianpari *et al.* (2020), foi realizada a análise quantitativa e qualitativa dos dados extraídos dos artigos selecionados através da revisão sistemática de literatura. Tendências temporais foram avaliadas, ao se correlacionar o ano de publicação e o número de estudos. Foram tabelados dados dos artigos de interesse, como: sensores utilizados, métodos de classificação, resolução das imagens e tipos de dados. Esses dados foram analisados com base na acurácia global dos estudos, buscando entender quais das variáveis influenciam significativamente na precisão dos resultados finais. Estudos que não apresentavam acurácia global ou qualquer outro dado indispensável para a discussão, foram excluídos dessa análise. Estas análises comparativas indicam lacunas na literatura e fornecem um panorama dos padrões de desempenho, o que auxilia em investigações futuras (Mahdianpari *et al.*, 2020).

Além disso, examinou-se a influência das técnicas de inteligência artificial, especialmente as abordagens de deep learning e machine learning no aprimoramento de processos de classificação e na delimitação de áreas úmidas, uma vez que tem se mostrado como ferramenta muito útil na atualidade, ao se automatizar e agilizar processos. A tabela 2 exibe as variáveis a serem analisadas através desta pesquisa.

Tabela 2: Variáveis a serem analisadas

Variável	Categoria
Título	
Autores	
Ano de publicação	
Número de citações	
Local do estudo	País, estado e cidade
Tipo de dados	LiDAR; Radar; Optical
Sensor	WorldView; Landsat; Sentinel; CBERS; entre outros
Série temporal	Multi Temporal; Data Única
Tipo de amostragem	Amostragem Estratificada; Amostragem Aleatória Simples; Amostragem sistemática
Unidade de processamento	Pixel Based, Object Based
Feição	Bandas originais, NDVI, NDWI, SAVI, SAR, entre outros
Número de feições	
Método de classificação	Supervisionada, não-supervisionada
Classificador	Random Forest (RF); Decision Tree (DT); Thresholding; Support Vector Machine (SVM); entre outros
Índices de validação	Coeficiente Kappa; Acurácia média; F1-Score; acurácia do usuário
Acurácia	
Resolução das imagens	
Extensão da área	

Fonte: adaptado de Mahdianpari *et al.*, 2020.

4. RESULTADOS E DISCUSSÕES

4.1. ESTUDOS SELECIONADOS E DISTRIBUIÇÃO REGIONAL

Dezesseis estudos foram selecionados após a filtragem, abrangendo diversos estados do Brasil. A tabela 3 exibe os títulos dos artigos selecionados para esta pesquisa e a figura 3 destaca os Estados onde os estudos foram realizados.

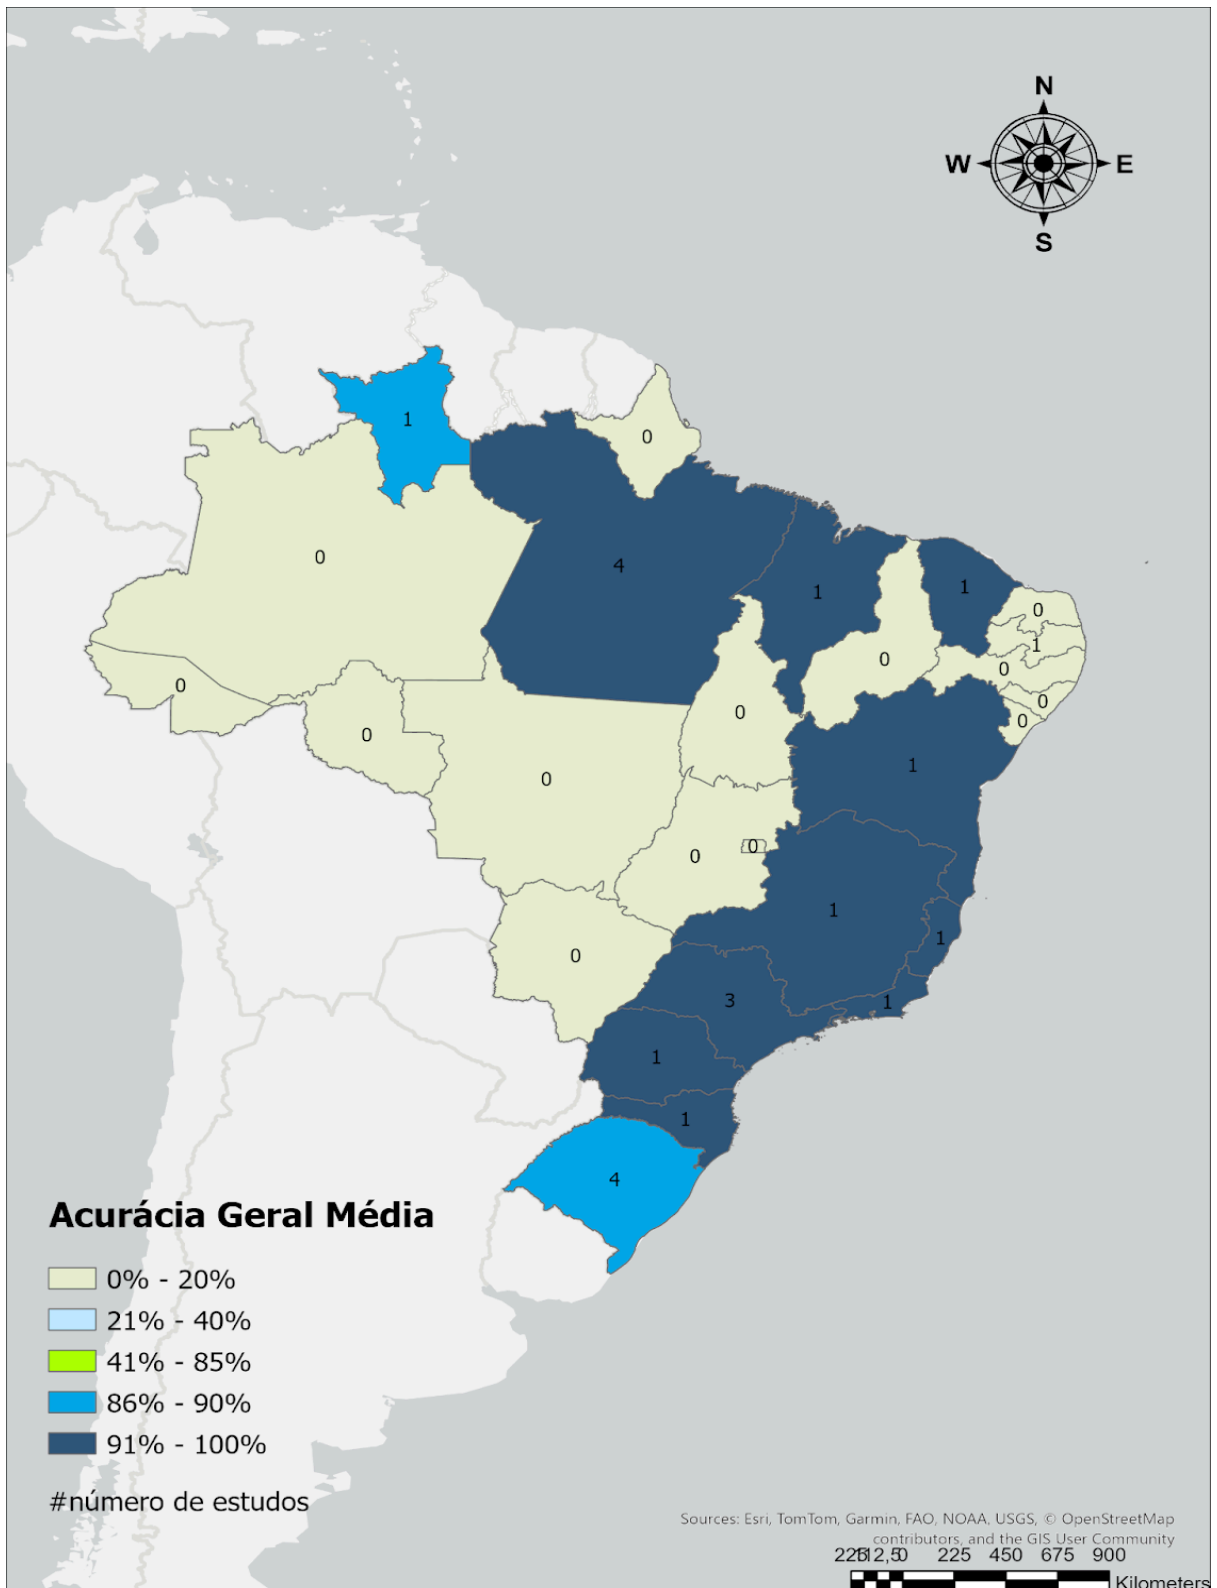
Tabela 3: títulos dos artigos

Título do artigo	Número
Spatiotemporal dynamics of mangrove forest and association with strandings of Antillean manatee (<i>Trichechus manatus</i>) calves in Paraíba, Brazil	28
Mangrove Typology: A Proposal for Mapping based on HighSpatial Resolution Orbital Remote Sensing	9
SPATIO TEMPORAL DYNAMICS (1986-2020) OF MANGROVES FROM RESEX OF THE MOUTH OF THE PARÁ RIVER (EASTERN AMAZON, BRAZIL)	30
A comparison of data mining techniques and multi-sensor analysis for inland marshes delineation.	29
Status of mangroves land use on the Brazilian Amazon coast from RapidEye imagery and GEOBIA approach.	32
Detection of changes in mangroves along the Coreaú River Estuary, Northeastern Brazil from object-oriented classification in orbital images.	10
Mangrove changes over the past decade in South and Southeast Brazil using spaceborne optical and SAR imagery.	26
Small inner marsh area delimitation using remote sensing spectral indexes and decision tree method in southern Brazil.	15
Wetland mapping with multitemporal Sentinel radar remote sensing in the southeast region of Brazil.	37
Exploring a Deep Convolutional Neural Network and GEOBIA for Automatic Recognition of Brazilian Palm	52

Swamps (Veredas) Using Sentinel-2 Optical Data.	
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.	39
Mapping vegetation in a late Quaternary landform of the Amazonian wetlands using object-based image analysis and decision tree classification.	68
SAR Backscatter and InSAR Coherence for Monitoring Wetland Extent, Flood Pulse and Vegetation: A Study of the Amazon Lowland.	35
Geographic Object-Oriented Analysis of UAV Multispectral Images for Tree Distribution Mapping in Mangroves.	48
A Multiscale Approach Indicates a Severe Reduction in Atlantic Forest Wetlands and Highlights that São Paulo Marsh Antwren Is on the Brink of Extinction.	21
Mapping and classification of wetlands using Topographic Wetness Index (TWI) from Digital Elevation Models of the Gravataí River Basin — Rio Grande do Sul State (RS), Brazil).	6

Fonte: autoria própria

Figura 3: Distribuição de estudos por estado



Fonte: autoria própria.

Como pode ser observado no mapa, os estudos analisados se concentraram principalmente nos estados de São Paulo, Pará e Rio Grande do Sul, refletindo os estados onde há grande número de áreas úmidas de interesse. São locais que possuem agenda de pesquisa mais ativa, prioridades de conservação e que tendem a aparecer em inventários e revisões nacionais sobre áreas úmidas, as quais têm papel fundamental na hidrologia regional e em serviços ecossistêmicos como depósitos de carbono, retenção de sedimentos e habitat para inúmeras espécies. Desta forma, estas áreas tendem a receber mais financiamentos e projetos de mapeamento e monitoramento (INAU, 2024).

O elevado número de estudos presentes no estado do Pará relaciona-se à grande extensão e complexidade das várzeas amazônicas e mosaicos alagáveis, cujo papel biogeoquímico e hidrológico tem grande interesse socioambiental e interesse científico. Além do grande território, a Amazônia concentra grandes projetos de sensoriamento remoto e centro de pesquisas nacionais e internacionais que investigam a silagem do carbono, as inundações sazonais e a conectividade fluvial, o que favorece aplicações de delimitações e publicações metodológicas. Em muitos estudos há a combinação de séries temporais e observações de campo para separar padrões de variação sazonal de alterações antrópicas (Furlan *et al.*, 2023).


No Rio Grande do Sul, o alto número de pesquisas está relacionado às extensas planícies costeiras e sistemas lagunares, como a Lagoa do Peixe, as quais apresentam alto valor para a fauna presente, principalmente para as aves migratórias, além de ser base para pesca e regulação costeira, enfrentando pressões como assoreamento e conversão do uso de solo. Nestes estudos destaca-se a área conhecida como Banhado Grande, a qual funciona como importante refúgio de biodiversidade local, contribuindo para a conectividade entre sistemas lagunares e áreas de repouso e alimentação para aves. Sua conservação é de interesse ambiental devido à sua importância para a manutenção de populações migratórias quanto para a provisão de serviços ecossistêmicos ligados ao controle de cheias e retenção de sedimentos. A existência de grupos acadêmicos e institutos regionais dedicados ao estudo dessas planícies facilita a produção científica local, a qual costuma abordar desde a delimitação espacial das feições úmidas até avaliações de impactos antrópicos e propostas de manejo, consolidando um corpo de literatura consistente sobre classificação e monitoramento dessas áreas (Guasselli *et al.*, 2020).

Em São Paulo, há concentração de pólos de pesquisa tanto na costa, apresentando manguezais e zonas estuarinas; quanto em regiões interiores, apresentando brejos e campos úmidos. Ambas as áreas possuem reconhecido valor ambiental, grupos universitários ativos e instrumentos de proteção local, o que faz com que estudos deste Estado abordem diferentes escalas, desde a avaliação de estoques de carbono até a delimitação de brejos de cabeceira em paisagens agrícolas, resultando em pesquisas aplicadas que subsidiam políticas estaduais, produtos cartográficos regionais e planejamento (Rovai *et al.*, 2021).

Logo, pode-se observar uma relação direta entre o número de estudos realizados e as condições socioeconômicas e ambientais de cada região. Áreas úmidas que apresentam maior relevância ecológica, maior vulnerabilidade e elevada biodiversidade tendem a atrair mais interesse científico. Fatores como a disponibilidade de financiamento, acesso a equipamentos e existência de instituições e universidades consolidadas influenciam na capacidade de pesquisa. Alguns estados possuem ambos os fatores citados, o que possibilita a condução de pesquisas mais robustas e realizadas de forma contínua, favorecendo a produção de dados e avanço de estudos voltados à essa área (Goulart *et al.*, 2022).

4.2. ANÁLISE DOS DADOS

As informações obtidas foram distribuídas em gráficos e tabelas, visando a melhor visualização e interpretação dos dados. A figura 4 demonstra a produção de artigos sobre o tema através dos últimos anos, de acordo com as publicações nas bases de dados consultadas.

Figura 4: artigos publicados e anos correspondentes

Fonte: autoria própria

A distribuição anual pode ser explicada por possíveis mudanças metodológicas e pela disponibilidade de ferramentas e dados que afetam a forma como as pesquisas são realizadas. Avanços em sensoriamento remoto costumam provocar variações no número de publicações à medida que pesquisadores adotam novas fontes e fluxos de trabalho, mas essas variações nem sempre influenciam de forma homogênea o cenário, gerando períodos de baixa produção seguidos por picos quando um novo conjunto de métodos possibilitam a realização de novos estudos simultâneos. Os estudos voltados ao delineamento de áreas úmidas comumente utilizam métodos que se baseiam em dados multitemporais e multissensoriais, desta forma, são mais viáveis com plataformas recentes, tendendo a concentrar estudos em janelas temporais específicas (Mahdianpari *et al.*, 2020).

Haddaway e Bayliss (2015) nos introduzem a ideia de literatura cinzenta, a qual é definida como a publicação de informação ou pesquisa fora de canais acadêmicos, é um dos possíveis motivos para a distribuição destes estudos, além da dinâmica dos ciclos institucionais e de financiamento. Muitos mapeamentos de áreas úmidas são produzidos como estudos de licenciamento, relatórios técnicos, dissertações e trabalhos realizados por órgãos gestores e consultorias, fontes que normalmente não constam nas bases de dados utilizadas para esta pesquisa, desta

forma, estudos baseados somente nessas bases podem ser limitados (Haddaway; Bayliss, 2015; Parron *et al.*, 2019).

Embora os trabalhos em campo tenham diminuído em 2020 devido à pandemia, houve aumento em pesquisas baseadas exclusivamente em dados remotos e análises secundárias que não exigem deslocamento ou atividade de campo, além de possíveis concentrações de submissões de trabalho e publicações em função de adiamentos. Eventos conjunturais e o pequeno número de estudos retornado pela pesquisa tornam qualquer flutuação anual passível de discussão, desta forma, é preciso interpretar o padrão com cautela e, quando possível e de interesse da pesquisa, complementar a análise com buscas em literatura cinzenta e em bases nacionais (Corlett *et al.*, 2020; Bramer *et al.*, 2018).

4.2.1. VARIAÇÃO CAUSADA DEVIDO AOS SENSORES E DADOS UTILIZADOS

Os sensores e tipos de dados utilizados são variáveis que podem alterar a precisão dos resultados do mapeamento, como pode ser observado nas tabelas 4 e 5.

Tabela 4: tipos de fonte de dados (sensores) e seu número de aplicações

Tipos de dados	Número de artigos
Óptico	8
RADAR	2
Óptico + LiDAR ou DEM	3
RADAR+LiDAR ou DEM	1
Óptico + RADAR + LiDAR ou dem	2

Fonte: autoria própria

Tabela 5: Sensores e acurácias do mapeamento

Nº do artigo	Sensor	Acurácia Geral (%)	Índice Kappa	F1 - Score	Índice de Proporção Correta
37	Sentinel-1	81,9	0,71		
32	RapidEye	95,12	0,92		

35	RADARSAT -2	86	0,83	
52	Sentinel-2	93		0,63
21	Landsat	100	1	
6	ALOS I			75,1
29	ALOS I ; Sentinel-1; Sentinel-2; WorldView- 2	98,5	0,98	
26	Landsat, ALOS-1 , ALOS-2; LiDAR	93	0,86	
10	Landsat e LISS-3	97	0,94	
39	ALOS-I, Sentinel-1			72,9
9	LiDAR	94	0,91	
68	ASTER, ALOS I	88	0,86	
15	Sentinel - 2A			95,9

Fonte: autoria própria

O índice Kappa e o F1-score são métricas amplamente utilizadas para avaliar classificações, uma vez que fornecem análise mais confiável do desempenho real do modelo. O índice Kappa mede o quanto o classificador acerta além do que acertaria por acaso, sendo fundamental em cenários com classes desbalanceadas, onde a acurácia simples pode ser enganosa. Já o F1-score combina precisão e *recall* em um único valor, permitindo avaliar o equilíbrio entre acertos verdadeiros e erros críticos em classes específicas, especialmente aquelas de menor representatividade. Ambos são considerados confiáveis porque corrigem limitações

da acurácia tradicional: o Kappa ajusta os resultados ao acaso e o F1 reflete o desempenho real em classes importantes, oferecendo uma visão mais robusta e realista da qualidade da classificação. (Belgiu, Dragut; 2016).

Na delimitação de áreas úmidas, considerar métricas como índice Kappa e F1-score é essencial porque esses ambientes possuem forte heterogeneidade e classes desbalanceadas, o que pode ser necessário a ser avaliado em conjunto com a acurácia geral. O F1-score avalia especificamente o desempenho da classe “área úmida”, indicando se o modelo realmente a detecta sem muitos erros. Já o índice Kappa corrige a avaliação considerando o acaso, evitando interpretações enganosas em paisagens dominadas por classes majoritárias. Assim, essas métricas garantem mapas mais confiáveis e suportam decisões ambientais com menor incerteza (Belgiu, Dragut; 2016).

O índice de proporção correta mede a fração de amostras corretamente classificadas e foi usado nesses estudos por oferecer uma avaliação simples, direta e comparável do desempenho dos métodos de delimitação de áreas úmidas. Ele indica, de forma objetiva, o quanto os classificadores baseados em SAR, índices espectrais ou TWI acertaram em relação ao total de referências. Apesar de não corrigir o acaso, continua sendo um indicador padrão e amplamente aceito de acurácia em sensoriamento remoto (Simioni *et al.*, 2018). Alguns estudos utilizam matriz de confusão, mas não apresentam acurácia geral, logo, foi utilizado o índice de proporção correta como forma de avaliação da acurácia destes estudos em específico.

Observa-se predominância de estudos que se baseiam em dados ópticos e altos valores de acurácia associados a sensores ópticos (*RapidEye*, *Landsat*, *Sentinel*, entre outros) refletindo o uso intensivo de séries longas e gratuitas de sensores ópticos para monitoramento de áreas úmidas e facilidade de aplicação de índices espectrais, como NDWI e NDVI, além do uso de técnicas multitemporais que melhoram a diferenciação entre classes úmidas e não-úmidas. Relatórios e revisões sobre monitoramento de áreas úmidas utilizando *Landsat* e outras séries ópticas mostram que a longa continuidade temporal e a robustez de dados pré-processados tornam os fluxos de trabalho óptico atrativos para estudos que necessitam de séries históricas e validação consistente (Demarquet, 2023; Morphum Enviromental, 2021).

Em relação aos sensores SAR, embora sejam essenciais para detecção de inundações e umidade em condições de nuvens e em períodos de chuva, possuem

acurácia média nos estudos analisados, comumente inferiores às soluções ópticas quando usados isoladamente na amostra. Os dados SAR exigem pré-processamento específico, como interpretação polarimétrica, correção radiométrica e *despeckle*, o que melhora seu desempenho consideravelmente ao ser integrado a dados ópticos ou quando aplicado em conjunto a técnicas orientadas a objeto, o que explica o fato de que fusões multissensoriais comumente superam abordagens mono-sensor (Rapinel, 2020).

A inclusão de variáveis altimétricas como DEM ou LiDAR de alta resolução nas fusões estão correlacionadas às maiores acurácias reportadas na amostra, o que é consistente com estudos que mostram como dados LiDAR melhoram a identificação de características hidrológicas e topográficas, as quais são cruciais para delimitação dos limites das áreas úmidas, especialmente em contextos ambientais complexos. Porém, a cobertura espacial limitada deste sensor e custos elevados de aquisição/processamento explicam o porquê de seu uso ser mais frequente em pesquisas que cobrem áreas menores e possuem financiamento disponível (Pricope *et al.*, 2020).

Em relação ao estudo 21, Random Forest atingiu 100% de acurácia devido ao fato de ter sido treinado com poucos dados e com pseudo-ausências (locais onde a espécie não foi confirmada ausente) ambientalmente muito diferentes, o que facilitou a delimitação perfeita das classes. As variáveis ambientais utilizadas também definiram muito bem a área de interesse permitindo a alta acurácia. Foi utilizado o modelo de distribuição de espécies BIOMOD, o que não garantiu independência espacial, afetando nos resultados. O resultado de 100% de acurácia geral e índice Kappa vem do overfitting, o que não espelhou a realidade, uma vez que erros de comissão foram pontuados após validação de campo. Ou seja, o resultado real obtido foi inferior, além de ser um método que utiliza a distribuição de espécies como indicador de área úmida, método que se torna pouco viável em diferentes situações (Del-Rio *et al.*, 2015).

4.2.2. RESOLUÇÃO ESPACIAL E ACURÁCIA

A tabela 6 apresenta a resolução dos dados utilizados e a acurácia obtida pelo estudo correspondente.

Tabela 6: Acurácia Geral e resolução das imagens

Nº do artigo	Resolução das imagens (m)	Acurácia Geral (%)	Índice de Proporção Correta
9	0,4	94	
29	12,5	98,5	
32	5	95,12	
10	30	97	
26	15, 10, 30	93	
15	10		95,9
37	10	81,9	
52	10	93	
39	10		72,9
68	15, 30	88	
35	2,5	86	
21	15, 30	100	
6	12,5; 30, 90		75,1

Fonte: autoria própria

Analisando a tabela que correlaciona as resoluções das imagens e a acurácia geral, pode-se determinar que, mesmo com dados de mesmas resoluções, as acurácias obtidas variam, o que indica que o processamento destes dados e demais métodos envolvidos influenciam diretamente nos resultados obtidos, ou seja, mesmo com ótimas resoluções, resultados com acurácia global mediana podem ser obtidos; o contrário também é verdade, uma vez que procedimentos que usam resoluções medianas podem gerar resultados de alta acurácia global.

4.2.3. VARIAÇÃO DA ACURÁCIA DE ACORDO COM O MÉTODO DE CLASSIFICAÇÃO

O método de classificação é mais uma das variáveis a serem consideradas durante as delimitações, uma vez que afetam diretamente na acurácia obtida. A tabela 7 apresenta os métodos de classificação e a acurácia dos resultados obtidos.

Tabela 7: acurácia geral e método de classificação empregado

Nº do artigo	Método de classificação	Acurácia Geral (%)	Índice de Proporção Correta
9	GEOBIA, classificação guiada por dados de campo e interpretação baseada em atributos espectrais e estruturais para definir a tipologia dos manguezais	94	
29	GEOBIA utilizando k-NN	98,5	
32	GEOBIA com segmentação e extração de atributos para mapear o uso do solo em manguezais	95,12	
10	GEOBIA + decision tree	97	
26	GEOBIA sem uso explícito de classificadores	93	
15	Decision Tree (CART)		95,9

37	K-means (unsupervised clustering)	81,9	
52	Comparação direta entre: (a) GEOBIA com Random Forest aplicado aos objetos (segmentos) e (b) Deep CNN (U-Net) para segmentação semântica (treinada com chips)	93	
39	Decision Tree (CART)		72,9
68	OBIA + data-mining (Decision Tree)	88	
35	Extração de produtos estatísticos temporais de intensidade e coerência (stack statistics) + thresholding / regras empíricas	86	
21	Random Forest	100	
6	Cálculo de TWI a partir de DEMs + aplicação de limiares		75,1

Fonte: autoria própria

Ao analisar a tabela, observa-se que métodos baseados em análise orientada a objetos (GEOBIA/OBIA) alcançam maiores acurácias, enquanto métodos que utilizam algoritmos não supervisionados, como *K-means*, apresentaram

desempenho inferior. Isso também é observado na literatura clássica: a segmentação orientada a objetos reduz o fenômeno conhecido como “*salt-and-pepper*” típico de classificações *pixel-pixel*, o que permite a exploração de variáveis de forma, textura e contextos além da assinatura espectral pura, sendo vantajoso em ambientes heterogêneos, como as áreas úmidas. Por outro lado, métodos não supervisionados dependem da separabilidade natural dos clusters no espaço e tendem a confundir as classes espectrais próximas caso não receba treinamento adequado (Macqueen, 1967).

Classificadores baseados em árvores, como *Decision Tree* e CART; e métodos de conjunto, como RF, apresentam ótimas acurácias, acima de 90%; abordagens baseadas em *deep learning* (*U-Net* para segmentação semântica) também apresentam ótimo desempenho, atingindo acurácias na mesma faixa de porcentagem. Isto reflete algumas propriedades metodológicas já conhecidas: RF oferece robustez contra sobre ajustes e possui performance adequada mesmo com entradas multivariadas e ruído; redes convolucionais (*U-Net*) extraem automaticamente características espaciais e contextuais de alta qualidade quando há quantidade e qualidade adequadas de amostras e *Decision Trees* são interpretáveis e eficientes dados heterogêneos. A decisão entre esses métodos costuma depender da disponibilidade de dados de treino e do custo computacional. Um classificador baseado em árvores divide os dados em sucessivos nós de decisão, criando uma estrutura hierárquica que separa as classes por regras simples. Ele aprende essas regras automaticamente, escolhendo os atributos que melhor separam as amostras em cada etapa (Belgiu; Dragut, 2016; Ronneberger *et al.*, 2015).

Alguns estudos apresentaram acurácia modesta, como nas aplicações puras de limiares sobre índices topográficos como o *Topographic Wetness Index* (TWI) com aproximadamente 75%, evidenciando limitações inerentes a métodos empíricos simples: o TWI representa como a topografia da área estudada auxilia na manutenção da umidade, mas não captura variações da cobertura vegetal, regimes sazonais de inundação e nem mesmo pequenas depressões sob dossel, o que implica no fato de que, ao ser utilizado de forma isolada, tende a não abordar toda a complexidade ecológica das áreas úmidas. Alguns outros fatores também influenciam diretamente nos resultados, como a metodologia aplicada e pré-processamento do DEM, escala de análise e estratégia de validação. Desta

forma, a literatura recomenda empregar o TWI como variável em fusões multissensoriais e multitemporais, combinando classificadores robustos a abordagens orientadas a objeto, resultando em maior acurácia na delimitação de áreas úmidas (Dronova, 2015; Ronneberger *et al.*, 2015).

4.3. APLICAÇÃO DE INTELIGÊNCIA ARTIFICIAL NA DELIMITAÇÃO DE ÁREAS ÚMIDAS

4.3.1. APLICAÇÕES OBSERVADAS NOS ESTUDOS SELECIONADOS

Um avanço técnico importante pode ser observado através da recorrente presença de algoritmos de aprendizado de máquina durante a pesquisa: a possibilidade de integração de grande variedade de atributos, como bandas espectrais, métricas temporais, texturas, entre outras; em modelos que aprendem dinâmicas complexas de dados sem a necessidade de regras extensas. Este tipo de fluxo de trabalho facilita a experimentação metodológica em diferentes cenários e reduz o tempo de desenvolvimento de classificadores ao se comparar com abordagens manuais, especialmente quando há amostras satisfatórias para treino (Belgiu; Dragut, 2016).

Quando a base de dados de treinamento são amplas e bem distribuídas, técnicas baseadas em redes neurais convolucionais apresentam alta capacidade de captura de padrões espaciais e contextuais, beneficiando a segmentação detalhada de feições úmidas, como bordas de lagoas, corredores ripários e manchas herbáceas. Esse tipo de ganho pode ser melhor observado em imagens de alta resolução e em projetos que utilizam estratégias de aumento de dados e validação espacial para evitar sobreposição, evidenciando que o uso de deep learning pode ser uma ferramenta de alto potencial quando a base de dados utilizada também é de alta qualidade (Ronneberger *et al.*, 2015).

Uma abordagem recorrente e prática nos estudos foi a de combinação dos métodos: uso de segmentação orientada a objeto para diminuir o ruído espacial, aplicação de classificador robusto, como RF para rotulação de objetos e, quando necessário, refinamento com uso de redes profundas. Pontos fortes dos diferentes métodos são combinados, como a sensibilidade espacial da OBIA e a capacidade de modelagem não linear das CNNs, produzindo fluxos de trabalho adaptáveis e flexíveis aos objetos de mapeamento (Dronova, 2015).

A democratização de plataformas e ferramentas, sejam ambientes em nuvem ou bibliotecas open-source, tem ampliado o acesso às técnicas de IA e favorecido práticas e métodos reprodutíveis, como scripts padronizados de pré-processamento e compartilhamento de amostras de validação. Isto promove comparações metodológicas entre equipes com diferentes níveis de infraestrutura, sendo pontos positivos para o avanço no mapeamento de áreas úmidas (Gorelick *et al.*, 2017).

Deve-se destacar que o machine learning é o melhoramento contínuo das máquinas através de treinamentos, usando algoritmos capazes de extrair padrões e fazer previsões de dados. O deep learning é um subcampo desta área da tecnologia e que se baseia em redes neurais profundas, aprendendo representações em níveis crescentes de abstração e que, nas últimas décadas, impulsionou avanços em várias áreas, como detecção e classificação de objetos, reconhecimento de fala, biomedicina e descoberta de fármacos (Lecun *et al.*, 2015).

4.3.2. OUTRAS APLICAÇÕES POSSÍVEIS PARA DELIMITAÇÃO DE ÁREAS ÚMIDAS

Dentre métodos que utilizam IA e não foram observados dentro dos estudos da pesquisa, o método de domain adaptation/transfer learning é um dos mais eficazes, sendo utilizado quando modelos treinados em uma região ou época não funcionam de maneira adequada em outra devido às diferenças espectrais ou de demais condições, pois permitem a adaptação das representações e classificadores ao novo contexto, mesmo se apresentar poucos dados rotulados adicionais. Para delimitamento de áreas úmidas, isso demonstra que é possível reaproveitar classificadores bem treinados em regiões bem amostradas e adequá-los para biomas diferentes, reduzindo o tempo e custo que seria investido em coletas de campo (Tuia *et al.*, 2016).

O *active learning* pode ser utilizado para a geração artificial de amostras, pois prioriza quais pontos de campo ou quais chips de imagem devem ser rotulados para maximizar o ganho de acurácia com o menor esforço possível. Integrações mais recentes combinam o uso de *active learning* com a geração de dados artificiais para redução da necessidade de rotulagem manual, mantendo a representatividade de classes raras, como trechos ripários e manchas de brejo. Mapeamentos de área úmida com recursos financeiros limitados tendem a ser mais viáveis ao se utilizar

este método, já que permitem construir treinamentos eficientes e iterativos, úteis em áreas heterogêneas ou que variam sazonalmente (Fonseca *et al.*, 2021).

Já o método *self-supervised* serve para treinamento de redes em grandes volumes de imagens sem rótulos, aprendendo representações úteis que serão refinadas com um pequeno número de rótulos locais. No contexto de delimitação de áreas úmidas, a aplicação disto se daria ao pré-treinamento de modelos em séries multiespectrais globais, seguido de ajustes para particularidades locais (manguezais, várzeas, brejos) o que melhora a robustez e transferibilidade quando os rótulos são escassos. Estas abordagens demonstram ganhos expressivos em tarefas com poucos exemplos rotulados e tendem a ser promissoras no cenário nacional (Wang, 2022).

Há também modelos espaços-temporais e grafos (GNN / ConvLSTM) que podem ser utilizados para o mapeamento, uma vez que a dinâmica temporal e a conectividade espacial são temas centrais para estes estudos. Modelos que combinam extração espacial com módulos temporais (ConvLSTM, RNNs) ou que representam objetos/segmentos como os nós de um grafo e usam *Graph Neural Networks* para agregar contexto temporal e espacial, oferecendo enorme potencial. Com isso, se torna possível a classificação dos segmentos considerando seu histórico temporal e de sua vizinhança, levando a delineamentos que respeitam a continuidade ecológica e padrões de inundação, o que é de interesse para mapas dinâmicos de áreas úmidas (Kavran *et al.*, 2023).

4.4. DEFINIÇÃO DO MELHOR MÉTODO A SER UTILIZADO NA ÁREA DE INTERESSE

4.4.1. CONSIDERANDO APENAS DELIMITAÇÕES DE ÁREAS ÚMIDAS SEMELHANTES

As áreas úmidas presentes no sudoeste paulista são brejos, veredas e campos úmidos, possuindo características distintas entre si. Devido a isto, é necessária a combinação de metodologias. O trabalho de Simioni *et al.* (2020), “*a comparison of data mining techniques and multi-sensor analysis for inland marshes delineation*”, demonstrou que técnicas clássicas de mineração de dados, como RF e kNN, quando aplicadas a dados multissensores, geram resultados significativos no mapeamento de brejos e áreas alagáveis interiores. O artigo evidenciou que a combinação de dados SAR e imagens ópticas potencializa a detecção de áreas

encharcadas, mesmo em condições onde há muita cobertura de nuvens, um fator relevante em regiões tropicais e subtropicais. A incorporação de índices espectrais de umidade, como MNDWI e NDWI, e métricas texturais, permitiu maior robustez em relação à heterogeneidade espacial típica de áreas úmidas. Para o sudoeste paulista, onde brejos frequentemente se intercalam com campos úmidos e fragmentos do Cerrado, esse tipo de integração tende a capturar eficientemente as variações de reflectância associadas à saturação hídrica e à biomassa emergente (Simioni *et al.*, 2020).

O estudo de Bendini *et al.* (2021), “*Exploring a Deep Convolutional Neural Network and GEOBIA for Automatic Recognition of Brazilian Palm Swamps (Veredas) Using Sentinel-2 Optical Data*”, apresentou um avanço significativo ao integrar GEOBIA e redes neurais convolucionais (CNN). Essa combinação demonstrou alto desempenho no mapeamento automático de veredas, ambiente cuja delimitação é complexa graças a transição gradual entre campo úmido, buritizal e o Cerrado ao entorno. O modelo mostrou que a CNN é capaz de aprender padrões texturais e espectrais sutis, como a assinatura espectral do buriti (*mauritia flexuosa*) e a variação estrutural das zonas circundantes. A etapa GEOBIA contribuiu para preservar a coerência espacial das feições mapeadas, minimizando os erros de fragmentação e confusão com pastagens e áreas agrícolas. Esta metodologia faz com que seja possível distinguir com precisão os gradientes fisionômicos internos e bordas hidromórficas, ou seja, é aplicável para mapeamento de veredas e brejos (Bendini *et al.*, 2021).

Já o estudo de Del-Rio *et al.* (2015) , “*A Multiscale Approach Indicates a Severe Reduction in Atlantic Forest Wetlands and Highlights that São Paulo Marsh Antwren Is on Brink of Extinction*”, reforçou a relevância da adoção da abordagem multiescalar para análise e monitoramento de áreas úmidas inseridas na Mata Atlântica. Ficou evidente que a acurácia na detecção de pequenas manchas úmidas depende tanto da resolução das imagens quanto da escala de análise e da calibração local dos classificadores (Del-Rio *et al.*, 2015).

As abordagens híbridas, que associam dados multissensores (SAR e ópticos), aprendizado profundo (CNN) e segmentação orientada a objetos (GEOBIA) apresentam desempenho superior, conciliando robustez espectral, sensibilidade fisionômica e coerência espacial. Essa abordagem permite segmentar com precisão veredas com dossel de buritis, brejos dominados por macrófitas emergentes e

campos úmidos sujeitos à inundação sazonal, compondo um complexo mosaico. Logo, o método mais eficaz, considerando estes três estudos que apresentam áreas úmidas semelhantes àsquelas encontradas no sudoeste paulista, consiste na integração entre GEOBIA, dados multissensores e CNN, operados em ambiente multiescalar e fazendo uso de imagens multitemporais. Essa abordagem tende a atender às demandas de precisão espacial e ecológica, permitindo representar adequadamente a heterogeneidade e morfologia dos ambientes úmidos regionais, reduzindo erros de comissão e omissão, fornecendo uma base técnica sólida para a conservação, monitoramento e planejamento ambiental de ecossistemas hidromórficos.

4.4.2. CONSIDERANDO TODOS OS ESTUDOS SELECIONADOS

Este tipo de delimitação, para ser realizada no Estado de São Paulo, precisa da conciliação entre a sensibilidade a sinais biofísicos, custo e viabilidade. Características locais, como brejos pontuais, veredas e pequenas manchas de *marsh*; impõem desafios de escala que tornam necessária a adoção de fluxos de trabalho híbridos. Abordagens que combinam sensores ativos e dados ópticos multitemporais, em conjunto com procedimentos orientados a objeto e classificadores robustos, oferecem ótimo equilíbrio entre sensibilidade ecológica e aplicabilidade prática em contextos semelhantes àquelas encontrados no Sudoeste do Estado (Simioni *et al.*, 2020).

A integração de sensores, principalmente a fusão *Sentinel-1* (SAR) e *Sentinel-2* (óptico) em janelas multitemporais, reduz limitações encontradas em fontes isoladas, pois dados ópticos capturam variação fenológica e diferenças espectrais entre água e vegetação, enquanto o SAR fornece informações sobre estrutura vegetacional e umidade, independente da cobertura de nuvens. A combinação de índices espectrais, como NDVI, NDWI e MNDWI, com atributos SAR e texturais, diminui omissões e comissões em áreas úmidas de pequena extensão, favorecendo a detecção de manchas sazonais e permanentes, as quais são típicas em veredas e brejos (Del-Rio *et al.*, 2015; Simioni *et al.*, 2020).

O NDWI (Normalized Difference Water Index) é utilizado na identificação de água exposta e solos saturados por água, pois aumenta o contraste entre a água e superfícies com pouca ou nenhuma umidade. Em mapeamentos multitemporais é utilizado para filtrar corpos d'água temporários e delimitar planícies alagáveis

quando combinado a segmentação de objetos, reduzindo falsos positivos causados por sombras ou nuvens nas imagens ópticas (Miura *et al.*, 2025).

O NDVI (Normalized Difference Vegetation Index), por outro lado, auxilia na delimitação de áreas úmidas ao realçar a presença e vigor da vegetação emergente, diferenciando-as da vegetação presente em solo seco. Em mapeamentos atuais, o NDVI costuma ser aplicado em conjunto com NDWI, dados topográficos e variáveis temporais em modelos de classificação, aumentando a capacidade de separação de áreas úmidas com vegetação densa e áreas alagadas somente para cultivo, por exemplo (Tholo *et al.*, 2025). Este uso em conjunto possibilita mapeamentos de áreas úmidas mais precisos, além de possibilitar também a separação dos tipos de áreas úmidas de acordo com a vegetação e excedente hídrico.

Nos estudos 68 e 48 é observado o uso de NDVI, o qual foi utilizado como indicador de densidade e vigor da vegetação, permitindo diferenciar áreas úmidas, as quais tendem a apresentar vegetação hidrófila com assinaturas espectrais específicas, de superfícies não inundáveis. Ao analisar os valores do índice, foi possível identificar gradientes de biomassa, mapear transições entre zonas secas e encharcadas e auxiliar a classificação automática do ambiente, servindo como uma variável-chave para delimitar e compreender a dinâmica da vegetação associada às áreas úmidas (Tholo *et al.*, 2025).

A segmentação orientada a objeto (GEOBIA/OBIA) é um dos passos metodológicos críticos em paisagens lineares e fragmentadas: ao se agrupar pixels em objetos coerentes de acordo com atributos espectrais, geométricos e texturais, a GEOBIA permite atribuir forma, vizinhança e compacidade como evidências ecológicas, reduzindo o típico ruído de classificações *pixel-based* e possibilitando regras pós-classificação que aumentam a coerência ecológica dos polígonos gerados. Estudos realizados em manguezais e zonas úmidas costeiras reforçam o ganho de legibilidade cartográfica e a melhoria na consistência espacial das delimitações (Heumann, 2011; Zhang *et al.*, 2023).

Em relação aos algoritmos, o RF apresenta a melhor relação custo benefício para delimitações regionais, pois apresenta bom processamento com preditores correlacionados, exige parametrização moderada e alcança acurácias elevadas ao receber conjuntos diversificados de preditores espectrais, topográficos e texturais. Mesmo que redes convolucionais profundas (CNNs) superem RF em padrões espaciais mais complexos quando há maior número de imagens de alta resolução e

rótulos, seu custo computacional e demanda por anotações extensas as tornam menos práticas para projetos com tempo e orçamento limitados, logo, indica-se RF como método primário e CNNs como alternativa experimental para subáreas de teste com dados rotulados suficientes (Simioni, 2018; Bendini *et al.*, 2021).

O uso de dados altimétricos de alta resolução, como LiDAR e DEM de alta precisão, representa uma melhora na metodologia quando o objetivo é separar depressões e microrrelevos responsáveis pela retenção hídrica sazonal ou permanente, o que é uma das características principais para a identificação de veredas. Derivadas de LiDAR refinam as bordas e melhoram a inferência sobre conectividade hídrica, porém, a aquisição LiDAR possui alto custo, de modo que sua aplicação deve ser priorizada em áreas de alto valor de gestão ou em trechos onde a precisão topográfica é imprescindível (USDA NRCS, 2014; Govil *et al.*, 2022).

Para a validação é necessário que haja protocolo estratificado por objeto que identifique variabilidade espacial e sazonal, sendo a amostragem estratificada a recomendada para treino e teste independentes, *F1-score*, relatório de matriz de confusão por classe e índices de omissão/comissão específicos para áreas úmidas de menor extensão. A validação temporal, utilizando tanto imagens da época chuvosa quanto da seca, é necessária para garantir que as dinâmicas hidrológicas sejam observadas após a delimitação de áreas úmidas, aumentando sua precisão e correspondendo com a realidade. O uso de amostras coletadas em campo em conjunto com uso de imagens de alta resolução também colaboram para o aumento de precisão (Simioni *et al.*, 2020; Simioni, 2018).

Em relação ao delineamento de áreas úmidas no Sudoeste Paulista, o fluxo de trabalho mais eficiente combina dados gratuitos, como *Sentinel-1* e *Sentinel-2*, com o uso de GEOBIA e RF para produção inicial do mapa, com refinamentos pontuais utilizando-se LiDAR em áreas prioritárias. Essa organização assegura que alta resolução seja obtida, sem alto custo inicial, além de permitir escalonamento conforme as demandas de gestão, disponibilidade orçamentária e necessidade de precisão topográfica. A adoção de fluxos de trabalho de fácil interpretação e reprodutíveis, como aqueles em Google Earth Engine, e a realização de testes de transferência de modelos entre regiões de menor porte são passos indicados para aumento da aplicabilidade operacional (Del-Rio *et al.*, 2015; Zhang *et al.*, 2023).

Para realização deste tipo de metodologia, exige-se equipe técnica multidisciplinar, com experiência em sensoriamento remoto, geoprocessamento,

ecologia e hidrologia. Seu núcleo principal deve ser composto por: analista de sensoriamento remoto responsável pelo pré-processamento, geração de séries multitemporais e interpretação dos dados SAR e ópticos; especialista em GEOBIA/OBIA para segmentação e parametrização de objetos e regras pós-classificação que garantam coerência ecológica dos polígonos; cientista de dados para machine learning; técnico de campo para coleta de amostras; especialista em altimetria e LiDAR para refinamento e analista com competência em programação e sua aplicação em geoprocessamento. Desta forma, o método poderá ser aplicado de forma adequada, contando com uma equipe especializada nas práticas necessárias para aplicação.

É interessante observar que o uso de imagens do satélite CBERS é possível para o mapeamento de áreas úmidas. Ele possui câmeras multiespectrais e pancromáticas, além de imagens de alta resolução, como aquelas geradas pelo CBERS 04A, com resolução de oito metros para multiespectral e dois metros para pancromática. O CBERS é fruto da cooperação entre Brasil e China e é gerido pelo Instituto Nacional de Pesquisas Espaciais, disponibilizando seus dados de forma aberta e gratuita, o que reduz custos e amplia o acesso para estudos (INPE, 2025).

CONSIDERAÇÕES FINAIS

Após a realização da pesquisa, conclui-se que, embora os avanços técnicos no delineamento de áreas úmidas sejam claros, ainda há a necessidade de consideração sobre os métodos empregados, uma vez que é necessário o cuidado sobre os tipos de sensores, dados e demais variáveis a serem utilizadas durante os estudos. A integração multissensorial e fluxos orientados a objeto, por exemplo, se mostraram práticos e replicáveis, mas apresentaram melhores resultados a partir da qualidade dos dados rotulados e de sua quantidade. É necessário destacar também que a área de estudo é de extrema importância, logo, para áreas mais extensas, o uso de LiDAR, o qual é um sensor mais caro, pode não ser viável, por exemplo.

Para o sudoeste paulista, um fluxo híbrido combinando dados multissensores, como SAR e ópticos, aprendizado profundo, como CNN, e segmentação orientada a objetos, como GEOBIA, é o melhor método, diferenciando os tipos de áreas úmidas presentes na região (veredas, brejos e campos úmidos). Também é válido indicar que o uso de RF para substituir o CNN barateia os custos e que o uso pontual de LiDAR pode aumentar a acurácia das pesquisas, uma vez que seus dados possuem

melhor resolução espacial. Porém, a adoção desta metodologia exige investimentos em capacitação, padronização e em plataformas que garantam atualização contínua e replicabilidade. Pode-se apontar, como lacunas no delineamento de áreas úmidas, a ausência de bases rotuladas compartilhadas entre os pesquisadores, a articulação entre produtores e usuários e a falta de padronização da validação multitemporal.

O uso de inteligência artificial está presente em forma de machine learning e deep learning, mostrando-se extremamente promissora, uma vez que permite automatizar etapas do mapeamento (delimitação e classificação) de áreas úmidas através de regras não muito complexas, diminuindo o esforço humano realizado e o tempo necessário, conseqüentemente diminuindo os custos financeiros. Por fim, destaca-se que os métodos tendem a continuar se desenvolvendo com o passar dos anos, logo, espera-se que este trabalho seja de ajuda para futuras pesquisas.

REFERÊNCIAS

ALMEIDA, P. M. M.; CRUZ, C. B. M.; AMARAL, F. G.; FURTADO, L. F. A.; DUARTE, G. S.; SILVA, G. F.; BARROS, R. S.; MARQUES, J. V. F. P. A.; BASTOS, R. M. C.; ROSÁRIO, E. S.; SANTOS, V. F.; ALVES, A.; CHAVES, F. O.; SOARES, M. L. G. *Mangrove Typology: A Proposal for Mapping based on High Spatial Resolution Orbital Remote Sensing*. *Journal of Coastal Research*, Special Issue n. 95, p. 1–5, 2020. DOI: <https://doi.org/10.2112/SI95-001.1>. Disponível em: <https://bioone.org/journals/journal-of-coastal-research/volume-95/issue-sp1/SI95-001.1/Mangrove-Typology--A-Proposal-for-Mapping-based-on-High/10.2112/SI95-001.1.short>. Acesso em: 08 out. 2025.

BASÍLIO, M. P.; PEREIRA, V.; COSTA, H. G.; SANTOS, M.; GHOSH, A. A systematic review of the applications of multi-criteria decision aid methods (1977–2022). *Electronics*, [S. l.]: MDPI, v. 11, n. 11, p. 1720, 2022. Disponível em: <https://doi.org/10.3390/electronics11111720>. Acesso em: 07 ago. 2025.

BELGIU, Mariana; DRAGUT, Lucian. Random forest in remote sensing: a review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 114, p. 24–31, 2016. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271616000265>. Acesso em: 09 ago. 2025.

BENDINI, H. N.; FONSECA, Leila M. G.; MARETTO, Raian V.; MENINI, Bruno; TAQUARY, Evandro C.; SIMÕES, Philippe S.; HAIDAR, Ricardo F.; VALERIANO, Dalton de M. Exploring a deep convolutional neural network and GEOBIA for automatic recognition of Brazilian palm swamps (veredas) using Sentinel-2 optical data. In: IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2021, Brasília. Anais... Piscataway: IEEE, 2021. p. 5401–5404. Disponível em: <https://ieeexplore.ieee.org/document/9554050>. Acesso em: 12 out. 2025.

BRAMER, W. M.; et al. A systematic approach to searching: an efficient and complete method to develop literature searches. *Journal of the Medical Library Association*, 2018. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC6148622/>. Acesso em: 07 ago. 2025.

BRASIL. Lei n. 12.651, de 25 de maio de 2012. Dispõe sobre a proteção da vegetação nativa; altera as Leis n.os 6.938, de 31 de agosto de 1981, 9.393, de 19 de dezembro de 1996, e 11.428, de 22 de dezembro de 2006; revoga as Leis n.os 4.771, de 15 de setembro de 1965, e 7.754, de 14 de abril de 1989, e a Medida Provisória n.º 2.166-67, de 24 de agosto de 2001; e dá outras providências. *Diário Oficial da União*, Brasília, DF, 28 maio 2012. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/l12651.htm. Acesso em: 12 out. 2025.

BRASIL. Ministério do Meio Ambiente. *Estratégia de conservação e uso sustentável das zonas úmidas no Brasil*. Brasília, out. 2018. 22 p. Disponível em: https://www.gov.br/mma/pt-br/assuntos/biodiversidade-e-biomas/biomas-e-ecossistemas/arquivos/estrategia_ramsar_final.pdf. Acesso em: 07 ago. 2025.

CANISIUS, F.; BRISCO, B.; MURNAGHAN, K.; VAN DER KOOIJ, M.; KEIZER, E. SAR backscatter and InSAR coherence for monitoring wetland extent, flood pulse and vegetation: a study of the Amazon lowland. *Remote Sensing*, v. 11, n. 6:720, 2019. DOI: 10.3390/rs11060720. Disponível em: <https://www.mdpi.com/2072-4292/11/6/720>. Acesso em: 07 ago. 2025.

CASAGRANDE, Matheus Felipe Stanfoca; FURLAN, Lucas Moreira; MOREIRA, César Augusto; ROSA, Fernanda Teles Gomes; ROSOLEN, Vania. Non-invasive methods in the identification of hydrological connectivity and subsurface flow in

isolated wetlands. *Environmental Research / Remote Sensing (ou Environmental Challenges)*, v. 202, 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2667010021002122>. Acesso em: 08 ago. 2025.

CONTI, L. A.; BARCELLOS, R. L.; OLIVEIRA, P.; NASCIMENTO NETO, F. C.; CUNHA-LIGON, M. Geographic object-oriented analysis of UAV multispectral images for tree distribution mapping in mangroves. *Remote Sensing*, v. 17, n. 9:1500, 2025 (preprint/publicado). DOI: 10.3390/rs17091500. Disponível em: <https://www.mdpi.com/2072-4292/17/9/1500>. Acesso em: 07 ago. 2025.

CORDEIRO, C. L. O.; ROSSETTI, D. 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*, 2015. DOI: 10.1080/01431161.2015.1060644. Disponível em: https://www.researchgate.net/publication/281223452_Mapping_vegetation_in_a_late_Quaternary_landform_of_the_Amazonian_wetlands_using_object-based_image_analysis_and_decision_tree_classification. Acesso em: 07 ago.2025.

CORLETT, R. T.; et al. The impacts of the coronavirus pandemic on biodiversity research and conservation. 2020. Disponível em: https://pdxscholar.library.pdx.edu/context/polisci_fac/article/1091/viewcontent/coronavirusOA2020.pdf. Acesso em: 07 ago. 2025.

DEMARQUET, Q.; BERTOLDI, L.; GOSSELIN, M.; LE BOURSICAUD, R.; KAMMANN, C.; AL-SABAH, S.; LEROY, B.; BAGHDADI, N.; HAGOLLE, O. Long-term wetland monitoring using the Landsat archive. *Remote Sensing*, v. 15, n. 3, p. 820, 2023. Disponível em: <https://www.mdpi.com/2072-4292/15/3/820>. Acesso em: 07 ago. 2025.

DEL-RIO, G.; RÉGO, M. A.; SILVEIRA, L. F. A multiscale approach indicates a severe reduction in Atlantic Forest wetlands and highlights that São Paulo Marsh Antwren is on the brink of extinction. *PLoS ONE*, v. 10, n. 3: e0121315, 2015. DOI: 10.1371/journal.pone.0121315. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0121315>. Acesso em: 07 ago. 2025.

DURIGAN, G.; MUNHOZ, C. B.; ZAKIA, M. J. B.; et al. Cerrado wetlands: multiple ecosystems deserving legal protection as a unique and irreplaceable treasure. *Perspectives in Ecology and Conservation*, v. 20, n. 3, 2022. DOI: <https://doi.org/10.1016/j.pecon.2022.06.002>. Acesso em: 07 ago. 2025.

DRONOVA, I. Object-based image analysis in wetland research: a review. *Remote Sensing*, v. 7, n. 5, p. 6380–6413, 2015. Disponível em: <https://www.mdpi.com/2072-4292/7/5/6380>. Acesso em: 07 ago. 2025.

FONSECA, J.; DOUZAS, G.; BAÇAO, F. Increasing the effectiveness of active learning: introducing artificial data generation in active learning for land use/land cover classification. *Remote Sensing*, v. 13, n. 13, art. 2619, 2021. Disponível em: <https://www.mdpi.com/2072-4292/13/13/2619>. Acesso em: 07 ago. 2025.

FURLAN, L. M.; MOREIRA, C. A.; ALENCAR, P. G.; ROSOLEN, V. Satellite, UAV, and geophysical data to identify surface and subsurface hydrodynamics of geographically isolated wetlands: understanding an undervalued ecosystem at the Atlantic Forest–Cerrado interface of Brazil. *Remote Sensing*, v. 15:1870, 2023. Disponível em: <https://www.mdpi.com/2072-4292/15/7/1870>. Acesso em: 07 ago. 2025.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, v. 202, p. 18–27, 2017. DOI: <https://doi.org/10.1016/j.rse.2017.06.031>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425717302900>. Acesso em: 10 out. 2025.

GOVIL, S.; LEE, A. J.; MACQUEEN, A. C.; PRICOPE, N. G.; MINEI, A.; CHEN, C. Using hyperspatial LiDAR and multispectral imaging to identify coastal wetlands using gradient boosting methods. *Remote Sensing*, v. 14, n. 23, p. 6002, 2022. Disponível em: <https://www.mdpi.com/2072-4292/14/23/6002>. Acesso em: 07 ago. 2025.

GOULART, F.; FARIAS, R.; SILVA, A. The study of ecosystem services in Brazil: trends and gaps. *Ambiente & Sociedade*, v. 25, p. 1–23, 2022. Disponível em:

<https://www.redalyc.org/journal/928/92860487005/92860487005.pdf>. Acesso em: 07 ago. 2025.

GUASSELLI, L. A.; SIMIONI, J. P. D.; LAURENT, F. Mapping and classification of wetlands using Topographic Wetness Index (TWI) from Digital Elevation Models of the Gravataí River Basin — Rio Grande do Sul State (RS), Brazil. *Revista Brasileira de Geomorfologia*, v. 21, n. 3, p. 639–659, 2020. DOI: 10.20502/RBG.V21I3.1714. Disponível em: <https://lume.ufrgs.br/bitstream/handle/10183/214172/001116537.pdf>. Acesso em: 07 ago. 2025.

GUYNUP, Simon. *Brazil's Pantanal is at risk of collapse, scientists say*. Mongabay, 2022. Disponível em: <https://news.mongabay.com/2022/12/brazils-pantanal-is-at-risk-of-collapse-scientists-say/>. Acesso em: 21 out. 2025.

HADDAWAY, N. R.; BAYLISS, H. R. Shades of grey: two forms of grey literature important for reviews in conservation. *Biological Conservation*, v. 191, p. 827–829, 2015. Disponível em: <https://doi.org/10.1016/j.biocon.2015.08.018>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0006320715300689?via%3Dihub>. Acesso em: 07 ago. 2025.

HAYASHI, S. N.; SOUZA FILHO, P. W. M. E.; NASCIMENTO JÚNIOR, W. R.; FERNANDES, M. E. B. Status of mangroves land use on the Brazilian Amazon coast from RapidEye imagery and GEOBIA approach. *Anais da Academia Brasileira de Ciências*, v. 95(2):e20210468, 2023. DOI: 10.1590/0001-3765202320210468. Disponível em: <https://www.scielo.br/j/aabc/a/vcswV7jTXn5ZpRWrsmdLdMn/?format=html&lang=en>. Acesso em: 07 ago. 2025.

HEUMANN, Benjamin W. An object-based classification of mangroves using a WorldView-2 image. *Remote Sensing*, v. 3, n. 11, p. 2440–2460, 2011. Disponível em: <https://www.mdpi.com/2072-4292/3/11/2440>. Acesso em: 12 out. 2025.

INSTITUTO NACIONAL DE CIÊNCIA E TECNOLOGIA EM ÁREAS ÚMIDAS (INAU). *Inventário das áreas úmidas brasileiras: distribuição, ecologia, manejo, ameaças e lacunas de conhecimento*. Goiânia, 2024. Disponível em:

https://inau.org.br/site/images/e-book/c_c_inventario_das_areas_umidas_brasileiras_inau_e-book.pdf. Acesso em: 07 ago. 2025.

INSTITUTO DE PESQUISAS AMBIENTAIS — SISTEMA AMBIENTAL PAULISTA. *Áreas úmidas paulistas*. Metadados e shapefile, 01 out. 2024. Disponível em: <https://datageo.ambiente.sp.gov.br/geoportal/catalog/search/resource/details.page?uid=%7BABC15902-3151-4270-92D8-BAC95CA1A476%7D&>. Acesso em: 21 out. 2025.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS – INPE. CBERS — Satélite Sino-Brasileiro de Recursos Terrestres. São José dos Campos: INPE. Disponível em: <https://www.gov.br/inpe/pt-br/programas/cbers>. Acesso em: 09 dez. 2025.

JAFARZADEH, H.; MAHDIANPARI, M.; GILL, E. W.; BRISCO, B.; MOHAMMADIMANESH, F. Remote sensing and machine learning tools to support wetland monitoring: a meta-analysis of three decades of research. *Remote Sensing*, v. 14, n. 23, art. 6104, 1 dez. 2022. Disponível em: <https://doi.org/10.3390/rs14236104>. Acesso em: 07 ago. 2025.

JUSTINO, Sérgio Túlio Pereira; SILVA, Rafael Barroca; GUERRINI, Iraê Amaral; DA SILVA, Richardson Barbosa Gomes; SIMÕES, Danilo. Monitoring Environmental Degradation and Spatial Changes in Vegetation and Water Resources in the Brazilian Pantanal. *Sustainability*, Basel: MDPI, v. 17, art. 51, 2025. Disponível em: <https://doi.org/10.3390/su17010051>. Acesso em: 9 ago. 2025.

KAVRAN, D.; MONGUS, D.; ŽALIK, B.; LUKAČ, N. Graph neural network-based method of spatio-temporal land cover mapping using satellite imagery. *Sensors*, v. 23, n. 14, art. 6648, 2023. Disponível em: <https://www.mdpi.com/1424-8220/23/14/6648>. Acesso em: 07 ago. 2025.

KORB, C. C.; GUASSELLI, L. A.; HASENACK, H.; BELLOLI, T. F.; CUNHA, C. S. Temporal and spatial variability of hydrogeomorphological attributes in coastal wetlands — Lagoa do Peixe National Park, Brazil. *Coasts*, v. 5, n. 3, p. 23, 2025. Disponível em: <https://doi.org/10.3390/coasts5030023>. Acesso em: 07 ago. 2025.

LANG, M.; MCCARTY, G. *Light Detection and Ranging (LiDAR) for improved mapping of wetland resources and assessment of wetland conservation practices*.

CEAP Science Note, Natural Resources Conservation Service (NRCS), Sept. 2014. Disponível em: <https://www.nrcs.usda.gov/publications/ceap-wetland-2014-LiDARMappingWetlandResourcesAssessment.pdf>. Acesso em: 22 out. 2025.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. Deep learning. *Nature*, v. 521, p. 436-444, 2015. Disponível em: <https://www.nature.com/articles/nature14539>. Acesso em: 09 dez. 2025.

LOPES, J. P. N.; NASCIMENTO JÚNIOR, W. R.; DINIZ, C. G.; SOUZA FILHO, P. W. M. E. Mangrove changes over the past decade in South and Southeast Brazil using spaceborne optical and SAR imagery. *Anais da Academia Brasileira de Ciências*, suppl., e20201533, 2023. Disponível em: <https://www.scielo.br/j/aabc/a/hmWGwq7bqDWVRw5c76hjj8z/?lang=en>. Acesso em: 07 ago. 2025.

MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*. Berkeley: University of California Press, 1967. p. 281–297.

MAHDIANPARI, M.; GRANGER, J. E.; MOHAMMADIMANESH, F.; SALEHI, B.; BRISCO, B.; HOMAYOUNI, S.; GILL, E.; HUBERTY, B.; LANG, M. Meta-analysis of wetland classification using remote sensing: a systematic review of a 40-year trend in North America. *Remote Sensing*, v. 12, n. 11, p. 1882, 2020. Disponível em: <https://doi.org/10.3390/rs12111882>. Acesso em: 07 ago. 2025.

MEDEIROS, I. S.; REBELO, V. A.; SANTOS, S. S.; MENEZES, R.; ALMEIDA, N. V.; MESSIAS, L. T.; NASCIMENTO, J. L. X.; LUNA, F. O.; MARMONTEL, M.; BORGES, J. C. G. Spatiotemporal dynamics of mangrove forest and association with strandings of Antillean manatee (*Trichechus manatus*) calves in Paraíba, Brazil. *Journal of the Marine Biological Association of the United Kingdom*, v. xx, p. 1–8, 2021. Disponível em: <https://www.mamiraua.org.br/documentos/9aebaa3cd24cfcfb7e94bbf2c31d6f28.pdf>. Acesso em: 09 ago. 2025.

MIURA, Yohei; SHAMSUDDUHA, Mohammad; SUPPASRI, Anawat; SANO, Daisuke. A Global Multi-Sensor Dataset of Surface Water Indices from Landsat-8 and Sentinel-2 Satellite Measurements. *Scientific Data*, v. 12, n. 1, p. 1253, 2025. Disponível em: <https://doi.org/10.1038/s41597-025-05562-z>. Acesso em: 09 dez. 2025.

MOORE, G. K. *What is a picture worth? A history of remote sensing*. U.S. Geological Survey, 1979. Disponível em: <https://pubs.usgs.gov/publication/70112362>. Acesso em: 22 out. 2025.

MORPHUM ENVIRONMENTAL; LYNKER ANALYTICS. *Wetland mapping methods review — discovery approach* (Relatório para agência nacional, New Zealand). 2021. Disponível em: <https://environment.govt.nz/assets/publications/Wetland-mapping-methods-review-discovery-approach.pdf>. Acesso em: 07 ago. 2025.

MOHER, D.; et al. Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015 statement. *Systematic Reviews*, v. 4, n. 1, p. 1, 2015. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/25554246/>. Acesso em: 07 ago. 2025.

NASA. Remote Sensing. Earthdata — Earth Observation Data Basics. 2025. Disponível em: <https://www.earthdata.nasa.gov/learn/earth-observation-data-basics/remote-sensing>. Acesso em: 23 out. 2025.

NUNES DA CUNHA, C.; PIEDADE, M. T. F.; JUNK, W. J. *Classificação e delineamento das áreas úmidas brasileiras e de seus macrohabitats*. Cuiabá: EdUFMT, 2015. Disponível em: <https://cppantanal.org.br/wp-content/uploads/2017/04/E-book-Classificacao-e-Delineamento-das-AUs.pdf>. Acesso em: 07 ago. 2025.

OLIVEIRA, A. E. L.; BAYER, M. Inventário de áreas úmidas da bacia hidrográfica do Rio Santa Maria, na microrregião do Vão do Paranã: “O Pantanal” de Goiás. *Boletim Goiano de Geografia*, Goiânia, v. 44, 2024. Disponível em: <https://revistas.ufg.br/bgg/article/view/78527/41866>. Acesso em: 07 ago. 2025.

PARRON, L. M.; FIDALGO, E. C. C.; LUZ, A. P.; CAMPANHA, M. M.; TURETTA, A. P. D.; PEDREIRA, B. C. C. G.; PRADO, R. B. *Research on ecosystem services in Brazil: a systematic review. Ambiente & Sociedade*, v. 14, n. 3, 2019. Disponível em: <https://www.scielo.br/j/ambiagua/a/h8GB7DGMKPFf9rpncKKsRWK/>. Acesso em: 07 ago. 2025.

PEIXOTO, H. J. C.; EL-ROBRINI, M. Dinâmica espaço-temporal (1986-2020) de manguezais de RESEX da Foz do rio Pará (Amazônia oriental, Brasil). *Novos Cadernos NAEA*, v. 27, n. 2, p. –, 2023. DOI: 10.18542/ncn.v27i2.13688. Disponível em: <https://periodicos.ufpa.br/index.php/ncn/article/view/13688>. Acesso em: 13 out. 2025

PHIRI, D.; et al. Sentinel-2 data for land cover/use mapping: a review. *Remote Sensing*, v. 12, n. 14, 2020. Disponível em: <https://www.mdpi.com/2072-4292/12/14/2291>. Acesso em: 22 out. 2025.

PRICOPE, Narcisa Gabriela; HALLS, Joanne Nancie; MAPES, Kerry Lynn; BAXLEY, James Brian; WU, James J. Quantitative comparison of UAS-borne LiDAR systems for coastal and wetland applications. *Sensors*, v. 20, n. 16, p. 4453, 2020. Disponível em: <https://www.mdpi.com/1424-8220/20/16/4453>. Acesso em: 07 ago. 2025.

PT PAULISTA – Diretório Estadual do Partido dos Trabalhadores. *Sudoeste Paulista*. Disponível em: <https://ptpaulista.com.br/macrorregioes/sudoeste-paulista/>. Acesso em: 03 out. 2025.

RAMOS, A.; FARIA, P. M.; FARIA, Á. Revisão sistemática de literatura: contributo para a inovação na investigação em ciências da educação. *Revista Diálogo Educacional*, Curitiba, v. 14, n. 41, p. 17-36, jan./abr. 2014. Disponível em: <http://www.redalyc.org/articulo.oa?id=189130424002>. Acesso em: 07 ago. 2025.

RAMSAR CONVENTION SECRETARIAT. *An Introduction to the Ramsar Convention on Wetlands*. 7. ed. Gland: Ramsar Convention Secretariat, 2016. Disponível em: https://www.ramsar.org/sites/default/files/documents/library/handbook1_5ed_introductiontoconvention_final_e.pdf. Acesso em: 21 out. 2025.

RAMSAR CONVENTION. *The List of Wetlands of International Importance (Ramsar List)*. [s.l.], 2023. Disponível em:

<https://www.ramsar.org/sites/default/files/2023-08/sitelist.pdf>. Acesso em: 21 out. 2025.

RAPINEL, Sébastien; BETBEDER, Julie; DENIZE, Julien; FABRE, Élodie; POTTIER, Éric; HUBERT-MOY, Laurence. SAR analysis of wetland ecosystems: Effects of band frequency, polarization mode and acquisition dates. *International Journal of Applied Earth Observation and Geoinformation*, 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0924271620302793>. Acesso em: 07 ago. 2025.

RIBEIRO, J. F.; WALTER, B. M. T. *Fitofisionomias do bioma Cerrado*. Planaltina: Embrapa-CPAC, 1998. p. 151–212. Disponível em: <https://www.alice.cnptia.embrapa.br/handle/doc/554094>. Acesso em: 07 ago. 2025.

RIBEIRO, S.; MOURA, R. G.; STENERT, C.; FLORÍN, M.; MALTCHIK, L. Land use in Brazilian continental wetland Ramsar sites. *Land Use Policy*, v. 99, 2020. DOI: 10.1016/j.landusepol.2020.104851. Disponível em: https://www.researchgate.net/publication/342053037_Land_use_in_Brazilian_continental_wetland_Ramsar_Sites. Acesso em: 07 ago. 2025.

RODRIGUES, S. W. P.; SOUZA FILHO, P. W. M. E. Detecção de mudanças no manguezal ao longo do estuário do Rio Coreaú, Nordeste do Brasil, a partir da classificação orientada a objeto em imagens orbitais. *Anuário do Instituto de Geociências (UFRJ)*, vol. 43, n. 3, p. 158–169, 2020. Disponível em: <https://revistas.ufrj.br/index.php/aigeo/article/view/38595>. Acesso em: 09 ago. 2025.

RONNEBERGER, Olaf; FISCHER, Philipp; BROX, Thomas. U-Net: Convolutional Networks for Biomedical Image Segmentation. In: NAVAB, Nassir; HORNEGGER, Joachim; WELLS, William; FRANGI, Alejandro (eds.). *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*. Cham: Springer, 2015. p. 234–241. Disponível em: https://doi.org/10.1007/978-3-319-24574-4_28. Acesso em: 07 ago. 2025.

ROVAL, André S.; COELHO-JR, Clemente; ALMEIDA, Renato de; CUNHA-LIGON, Marília; MENGHINI, Ricardo P.; TWILLEY, Robert R.; CINTRÓN-MOLERO, Gilberto; SCHAEFFER-NOVELLI, Yara. Ecosystem-level carbon stocks and sequestration

rates in mangroves in the Cananéia–Iguape estuarine system, southeastern Brazil. *Forest Ecology and Management*, v. 479, art. 118553, 2021. DOI: 10.1016/j.foreco.2020.118553. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0378112720313220>. Acesso em: 07 out. 2025

SALINAS, J. B. G.; EGGERTH, M. K. P.; MILLER, M. E.; MEZA, R. R. B.; CHACALTANA, J. T. A.; ACUÑA, J. R.; BARROSO, G. F. Wetland mapping with multitemporal Sentinel radar remote sensing in the southeast region of Brazil. *ISPRS Archives / Proceedings*, March 2020 (proc. conf.). Disponível em: <https://d-nb.info/1221274201/34>. Acesso em: 08 ago. 2025.

SANCHES, R. A.; ROSSETE, A. N.; REZENDE, A. C. P.; ALVES, H. Q.; VILLAS-BÔAS, A. Subsídios para a proteção de áreas úmidas da bacia do rio Xingu (Mato Grosso, Brasil). *Revista Árvore*, Viçosa-MG, v. 36, n. 3, p. 489–498, 2012. Disponível em: <https://www.redalyc.org/pdf/488/48822958011.pdf>. Acesso em: 12 out. 2025.

SANTOS FILHO, H.; CORNERO, C.; PEREIRA, A. Detecção automática da área úmida APA de Fazendinha (Macapá–Amapá) e seu entorno com o uso do complemento *Water Plugin* e insumos SAR da banda P. *Revista Brasileira de Sensoriamento Remoto*, v. 2, n. 2, p. 43–58, 2021. Disponível em: <https://rbsr.com.br/index.php/RBSR/article/download/46/30>. Acesso em: 07 ago. 2025.

SILVA, Isadora Taborda; PESSI, Dhonatan Diego; GUARALDO, Eliane; PARANHOS FILHO, Antônio Conceição. O avanço do uso de ferramentas geoespaciais na gestão de áreas úmidas continentais. *Revista de Geociências do Nordeste*, [S. l.], v. 6, n. 2, p. 223–235, dez. 2020. Disponível em: <https://periodicos.ufrn.br/revistadoregne/article/view/20843>. Acesso em: 04 ago. 2025.

SIMIONI, J. P. D.; GUASSELLI, L. A.; NASCIMENTO, V. F.; et al. 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*, v. 22, p. 5603–5620, 2020 (published online 2019). DOI:

10.1007/s10668-019-00442-0. Disponível em: https://www.researchgate.net/publication/335127564_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. Acesso em: 07 ago. 2025.

SIMIONI, J. P. D.; GUASSELLI, L. A.; DE OLIVEIRA, G. G.; RUIZ, L. F. C.; DE OLIVEIRA, G. A. A comparison of data mining techniques and multi-sensor analysis for inland marshes delineation. *Wetlands Ecology and Management*, v. 28, p. 577–594, 2020. DOI: 10.1007/s11273-020-09731-2. Disponível em: https://www.researchgate.net/publication/342022982_A_comparison_of_data_mining_techniques_and_multi-sensor_analysis_for_inland_marshes_delineation. Acesso em: 07 ago. 2025.

SIMIONI, J. P. D.; GUASSELLI, L. A.; RUIZ, L. F. C.; NASCIMENTO, V. F.; DE OLIVEIRA, G. Small inner marsh area delimitation using remote sensing spectral indexes and decision tree method in southern Brazil. *Revista de Teledetección (RAET)*, v. 52, p. 55–66, 2018. DOI: 10.4995/raet.2018.10366. Disponível em: https://www.researchgate.net/publication/329926444_Small_inner_marsh_area_deli_mitation_using_remote_sensing_spectral_indexes_and_decision_tree_method_in_s_outhern_Brazil. Acesso em: 07 ago. 2025.

SOUSA, N. L.; LOMBARDI, J. A. Flora vascular de uma área de campo úmido em Analândia, estado de São Paulo. *Rodriguésia*, v. 67, n. 3, p. 539–552, 2016. Disponível em: https://dspace.jbrj.gov.br/jspui/bitstream/doc/62/1/2016_Sousa%2c%20Lombardi_Rodrigu%C3%A9sia.pdf. Acesso em: 07 ago. 2025.

TANNUS, J. L. S. *Estudo da vegetação dos campos úmidos de Cerrado: aspectos florísticos e ecológicos*. 138 f. Tese (Doutorado em Ciências Biológicas – Biologia Vegetal) – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Instituto de Biociências de Rio Claro, Rio Claro, 2007. Disponível em: <https://repositorio.unesp.br/server/api/core/bitstreams/d3c4d64a-27fd-4b67-9a55-33a1d0c3872a/content>. Acesso em: 07 ago. 2025.

TAVEIRA, K. V. M.; SANTOS, R. S.; LEÃO, B. L. C.; STECHMAN NETO, J.; PERNAMBUCO, L.; SILVA, L. K.; CANTO, G. L.; PORPORATTI, A. L. Diagnostic

validity of methods for assessment of swallowing sounds: a systematic review. *Brazilian Journal of Otorhinolaryngology*, v. 84, n. 5, p. 638–652, 2018. Disponível em: <https://www.scielo.br/j/bjorl/a/fCCKPtDPSsm6L5QtJpKHvWj/abstract/?lang=en>. Acesso em: 07 ago. 2025.

THOLO, Harineck Mayamiko; MASUKU, Precious; MWASE, Weston; KACHAMBA, Daud Jones; NJALA, Allena; TCHONGWE, Wilson; MVULA, Richard Lizwe; TCHUWA, Isaac; MZUMARA, Tiwonge I.; CHISENGA, Chikondi; KADEWA, Wilfred; CHINKAKA, Emmanuel; NYENGERE, Jabulani. Integrating remote sensing and machine learning for mapping of seasonal wetland shrinkage in southern Malawi. *Discover Environment*, v. 3, art. 230, 2025. Disponível em: <https://doi.org/10.1007/s44274-025-00442-0>. Acesso em: 09 dez. 2025.

TUIA, D.; PERSSELLO, C.; BRUZZONE, L. Domain adaptation for the classification of remote sensing data: an overview of recent advances. *IEEE Geoscience and Remote Sensing Magazine*, v. 4, n. 2, p. 41–57, 2016. Disponível em: https://www.researchgate.net/publication/303847469_Domain_Adaptation_for_the_Classification_of_Remote_Sensing_Data_An_Overview_of_Recent_Advances. Acesso em: 07 ago. 2025.

USDA NRCS. *Light detection and ranging (LiDAR) for improved mapping of wetland resources and assessment of wetland conservation practices*. CEAP Science Note, 2014. Disponível em: <https://www.nrcs.usda.gov/publications/ceap-wetland-2014-LiDARMappingWetlandResourcesAssessment.pdf>. Acesso em: 07 ago. 2025.

USGS / LANDSAT. *Landsat 8: Operational Land Imager (OLI) and Thermal Infrared Sensor (TIRS)*. U.S. Geological Survey, 2025. Disponível em: <https://landsat.gsfc.nasa.gov/satellites/landsat-8/>. Acesso em: 22 out. 2025.

WANG, Y.; ALBRECHT, C. M.; BRAHAM, N. A. A.; MOU, L.; ZHU, X. X. Self-supervised learning in remote sensing: a review (preprint / relatório técnico). 2022. Disponível em: <https://elib.dlr.de/190040/1/2206.13188.pdf>. Acesso em: 07 ago. 2025.

ZHANG, Han; XIA, Qing; DAI, Shuo; ZHENG, Qiong; ZHANG, Yunfei; DENG, Xingsheng. Object-oriented multi-feature ensemble classification for mangrove mapping. *Frontiers in Marine Science*, 2023. Disponível em: <https://www.frontiersin.org/articles/10.3389/fmars.2023.1243116/full>. Acesso em: 10 out. 2025.

ZHOU, R.; YANG, C.; LI, E.; CAI, X.; YANG, J.; XIA, Y. Object-Based Wetland Vegetation Classification Using Multi-Feature Selection of Unoccupied Aerial Vehicle RGB Imagery. *Remote Sensing*, v. 13, n. 23, art. 4910, 2021. Disponível em: <https://doi.org/10.3390/rs13234910> . Acesso em: 22 out. 2025.

APÊNDICE A - INFORMAÇÕES SOBRE AS PESQUISAS SELECIONADAS

Título	Spatiotemporal dynamics of mangrove forest and association with strandings of Antillean manatee (<i>Trichechus manatus</i>) calves in Paraíba, Brazil
Autores	Iara Dos Santos Medeiros, Vanessa Araújo Rebelo, Sebastião Silva Dos Santos, Rafael Menezes, Nadjacleia Vilar Almeida, Leonardo Tortoriello Messias, João Luiz Xavier Do Nascimento, Fábria De Oliveira Luna, Miriam Marmontel; João Carlos Gomes Borges
Ano de publicação	2021
Local do estudo	Paraíba, Brasil
Tipo de dados	óptico
Sensor	Imagens Landsat
Série temporal	Multitemporal (1980-2010)
Tipo de amostragem	Não especificado
Unidade de processamento	Pixel based
Feição	Bandas 3, 4 e 5
Número de feições	Polígonos de extensão de manguezal; bandas originais (3,4,5)
Método de classificação	Supervisionada
<i>Classificador</i>	<i>Maximum likelihood</i> (ArcGIS 10.3.0 software)
Índices de validação	não informado
Acurácia	não informado
Resolução das imagens	30m
Extensão da área	1980 (17.784,91 ha), 1990 (16.224,62 ha), 2000 (15.459,40) e 2010 (15.840,68)

Uso de IA	Não
Tipo de área úmida	manguezal
Revista publicada	Journal of the Marine Biological Association of the United Kingdom

Título	Mangrove Typology: A Proposal for Mapping based on HighSpatial Resolution Orbital Remote Sensing
Autores	Paula Maria Moura de Almeida, Carla Madureira, Felipe Gonçalves Amaral, Madureira Cruz et al
Ano de publicação	2020
Local do estudo	São Caetano de Odivelas, Pará, Brasil
Tipo de dados	Óptico e Lidar
Sensor	Sem sensores especificados
Série temporal	Data única
Tipo de amostragem	Campo: medição de >50 parcelas de estruturas de plantas. Validação: dois pesquisadores que não participaram do mapeamento selecionaram e avaliaram pontos aleatórios
Unidade de processamento	Object based
Feição	Polígonos de classes e extratos de altura. infravermelho próximo, verde e azul
Número de feições	Não informado
Método de classificação	GEOBIA, classificação guiada por dados de campo
<i>Classificador</i>	<i>GEOBIA method (eCognition Developer® software)</i>
Índices de validação	Validação por pontos aleatórios avaliados por dois analistas independentes; matriz de confusão calculada; acurácia global = 94%; índice Kappa = 0,91.
Acurácia	94%
Resolução das imagens	0.4m
Extensão da área	Mais de 27.000 ha
Uso de IA	Não
Tipo de área úmida	Manguezal
Revista publicada	Journal of Coastal Research — Special Issue No. 95

Título	SPATIO TEMPORAL DYNAMICS (1986-2020) OF MANGROVES FROM RESEX OF THE MOUTH OF THE PARÁ RIVER (EASTERN AMAZON, BRAZIL)
Autores	Herbert Junior, Maâmar El-Robrini
Ano de publicação	2024
Local do estudo	Pará, Brasil
Tipo de dados	Óptico
Sensor	Landsat 5, Landsat 7 e Landsat 8
Série temporal	Multitemporal (1986, 1993, 1999, 2004, 2010, 2016 e 2020)
Tipo de amostragem	Não especificado
Unidade de processamento	pixel based
Feição	Polígonos de manguezal
Número de feições	Não informado
Método de classificação	Supervisionada no QGIS
<i>Classificador</i>	Não especificado
Índices de validação	Não especificado
Acurácia	Não especificado
Resolução das imagens	30m
Extensão da área	Mocapajuba: 210,28 km ² ; São João da Ponta: 34,09 km ²
Uso de IA	Não
Tipo de área úmida	manguezais inseridos em Reservas Extrativistas
Revista publicada	Novos Cadernos NAEA (periódico da Universidade Federal do Pará)

Título	A comparison of data mining techniques and multi-sensor analysis for inland marshes delineation.
Autores	João P. D. Simioni; Laurindo A. Guasselli; Guilherme G. de Oliveira; Luis F. C. Ruiz; Gabriel de Oliveira.
Ano de publicação	2020
Local do estudo	Brasil — Rio Grande do Sul; Banhado Grande (bacia do rio Gravataí)

Tipo de dados	óptico
Sensor	ALOS PALSAR I (quad-pol L-band, 12.5 m); Sentinel-1A (VV/VH, 10 m GRD); Sentinel-2A MSI (10 m); WorldView-2 (2 m, para referência).
Série temporal	Principalmente 2018 (Sentinel-1/2 e WorldView-2) com ALOS PALSAR 2011 para comparação; comparação histórica via carta topográfica de 1975 (análise 1975 vs 2018).
Tipo de amostragem	Amostras de referência obtidas por campo e interpretação: 450 pontos de campo (GNSS RTK) coletados em 01–04/12/2018 para classes (Wet Meadow, Rice Crop etc.). Amostras adicionais geradas por interpretação (WorldView-2). totalizando 1000 amostras de cada classe 80% para treinamento e 20% para validação
Unidade de processamento	Object-based
Feição	Polígonos/objetos com classes: Inland Marsh (IM), Wet Meadow (WM), Rice Crop (RC). Atributos espectrais, texturas SAR e atributos de objetos usados.
Número de feições	não especificado
Método de classificação	GEOBIA seguido por aplicação comparativa de quatro algoritmos de data-mining / classificador supervisionado: CART, ANN, Random Forest (RF) e k-NN. Testaram combinações de atributos e parâmetros.
<i>Classificador</i>	CART; ANN (rede neural) — com validação cruzada; Random Forest — parâmetros testados; k-NN (vários k e métricas). k-NN obteve melhor OA em cenário apresentado.
Índices de validação	Matriz de confusão; Overall Accuracy (OA), Producer's Accuracy (PA) e User's Accuracy (UA) por classe; validação 80% treino / 20% validação (amostras aleatórias via plugin Geopatterns).
Acurácia	98.5%
Resolução das imagens	Multirresolução: WorldView-2 (2 m, referência visual), ALOS PALSAR (12.5 m), Sentinel-1 (10 m), Sentinel-2 (10 m nas bandas usadas).
Extensão da área	Banhado Grande ≈ 5.591 ha; mapeamento indicou redução histórica (~28.1% desde 1975) e conversão para agricultura (~15.3%).
Uso de IA	Sim: métodos de machine learning/IA foram aplicados. Especificamente: ANN (rede neural) e Random Forest (algoritmos de aprendizado de máquina), além de k-NN e CART (data-mining). Os autores

	testaram hiperparâmetros e usaram validação cruzada/partição treino-validação; as técnicas ML/IA foram centrais na comparação de desempenho entre classificadores.
Tipo de área úmida	charcos/brejos continentais
Revista publicada	Wetlands Ecology and Management

Título	Status of mangroves land use on the Brazilian Amazon coast from RapidEye imagery and GEOBIA approach.
Autores	Sanae N. Hayashi; Pedro Walfir M. Souza-Filho; Wilson R. Nascimento Jr.; Marcus E. B. Fernandes.
Ano de publicação	2023
Local do estudo	Brasil — Costa Amazônica (faixa contínua entre a Baía do Marajó, Pará, até a Baía de São José, Maranhão).
Tipo de dados	Óptico
Sensor	RapidEye (imagens selecionadas entre 2011–2015: banda 4 = red-edge, banda 5 = green, banda 3 = blue; resolução espacial típica do RapidEye ≈ 5 m).
Série temporal	multitemporal (2011-2015)
Tipo de amostragem	Validação/controle de referência: amostragem estratificada aleatória para pontos de controle de campo / interpretação — 2.330 pontos de controle (GCPs) coletados/interpretados de forma estratificada e aleatória para avaliação da classificação.
Unidade de processamento	Object-based (GEOBIA)
Feição	Polígonos/objetos representando classes de cobertura e uso: Mangrove forest (MF); salt flat (SF/apicum)
Número de feições	não especificado
Método de classificação	GEOBIA — multi-resolution segmentation + classificação baseada em atributos de objeto (espectral, textura, forma) e regras/fluxo de decisão orientado à interpretação
<i>Classificador</i>	Abordagem orientada a objeto e baseada em regras/atributos; o artigo não indica uso de classificadores de machine-learning (p.ex. RF, SVM) como etapa principal — o foco foi GEOBIA (segmentação + regras/atributos).

Índices de validação	Matriz de confusão construída a partir dos 2.330 GCPs; calculados Producer's Accuracy, User's Accuracy, Overall Accuracy, Kappa e Tau.
Acurácia	95.12%
Resolução das imagens	RapidEye — ~5 m (uso de composições banda 4/5/3 para melhor discriminação).
Extensão da área	não especificado
Uso de IA	Não
Tipo de área úmida	manguezal
Revista publicada	Anais da Academia Brasileira de Ciências

Título	Detection of changes in mangroves along the Coreau River Estuary, Northeastern Brazil from object-oriented classification in orbital images.
Autores	Suzan Waleska Pequeno Rodrigues; Pedro Walfir Martins e Souza Filho
Ano de publicação	2020
Local do estudo	Brasil — Ceará, estuário do Rio Coreau
Tipo de dados	Óptico
Sensor	Landsat TM (Landsat-5), ETM+ (Landsat-7), OLI (Landsat-8) e ResourceSat-1 LISS-3 (24 m)
Série temporal	Multitemporal: imagens selecionadas para os anos entre 1985 e 2013
Tipo de amostragem	Amostragem direcionada / pontos de controle de campo
Unidade de processamento	Object-based (GEOBIA)
Feição	Polígonos/objetos representando classes
Número de feições	Não informado
Método de classificação	GEOBIA com segmentação multiresolução + árvore de decisão / regras orientadas a objeto
<i>Classificador</i>	Abordagem baseada em regras/árvore de decisão dentro do ambiente object-based (eCognition)
Índices de validação	Validação posicional (CAS / PEC / SE) e validação temática por Índice Kappa (Landis & Koch) e Acurácia Geral (Overall Accuracy)
Acurácia	97%
Resolução das imagens	30 m no geral e 24 m para 2010
Extensão da área	1985 = 37,665 km ² , 2013 = 38,745 km ² ; o estudo reporta ganhos e perdas por intervalos
Uso de IA	Não, o estudo aplicou GEOBIA (object-based

	segmentation + regras / árvore de decisão) e procedimentos estatísticos de validação; não há descrição do uso de algoritmos de machine-learning supervisionados
Tipo de área úmida	manguezal
Revista publicada	Anuário do Instituto de Geociências: UFRJ (Vol. 43, n. 3, 2020)

Título	Mangrove changes over the past decade in South and Southeast Brazil using spaceborne optical and SAR imagery.
Autores	João Paulo N. Lopes; Wilson R. Nascimento Jr; Cesar G. Diniz; Pedro W. M. Souza-Filho.
Ano de publicação	2023
Local do estudo	Brasil — faixa costeira dos cinco estados do Sul e Sudeste: Espírito Santo (ES), Rio de Janeiro (RJ), São Paulo (SP), Paraná (PR) e Santa Catarina (SC)
Tipo de dados	Óptico + Radar + DEM
Sensor	Landsat-5 TM (2008), Landsat-8 OLI (2016), ALOS-1 PALSAR (2008), ALOS-2 PALSAR (2016); SRTM/ALOS DEMs.
Série temporal	Multitemporal — comparativo entre 2008 e 2016
Tipo de amostragem	Validação temática: amostragem por pontos de referência em imagens de alta resolução (Google Earth Pro): 600 pontos para classificação temática por ano (300 pontos em mangrove + 300 em “others” por ano); 1000 pontos distribuídos (aleatório + estratificado) para avaliação da detecção de mudança (gain/loss/no change) segundo Olofsson et al. (2014).
Unidade de processamento	Object-based (GEOBIA)
Feição	Polígonos/objetos representando classes
Número de feições	Não informado
Método de classificação	GEOBIA com segmentação em 3 níveis, combinação ponderada de sensores (radar com maior peso no nível 1; óptico maior peso no nível 2), classificação (algoritmo não-paramétrico/unsupervised + expressões/rules para refino).
<i>Classificador</i>	Fluxo baseado em expressões/algoritmos de agrupamento não supervisionado +

	regras/object-reclassification (implementado em eCognition); não há uso primário de classificador ML padrão (RF/SVM) no fluxo principal.
Índices de validação	Matriz de confusão; User's / Producer's Accuracy; Overall Accuracy; Kappa por classe; Tau index; para detecção de mudança: OA, Overall Disagreement, Quantity & Allocation Disagreement (Pontius & Millones) e ajuste de áreas
Acurácia	93%
Resolução das imagens	Landsat: 30 m (bandas selecionadas; OLI band 8 = 15 m pan-resampled available); ALOS PALSAR: 10 m (backscatter); SRTM/DEM: 30 m.
Extensão da área	823.03 km ²
Uso de IA	Não
Tipo de área úmida	manguezal
Revista publicada	Anais da Academia Brasileira de Ciências

Título	Small inner marsh area delimitation using remote sensing spectral indexes and decision tree method in southern Brazil.
Autores	João P. D. Simioni; Laurindo A. Guasselli; Luis F. C. Ruiz; V. F. Nascimento; Gabriel de Oliveira.
Ano de publicação	2018
Local do estudo	Brasil — Estado do Rio Grande do Sul; área de estudo: Banhado Grande (BG) marsh, bacia do Rio Gravataí
Tipo de dados	Óptico
Sensor	Sentinel-2A
Série temporal	Multiescala sazonal — duas datas em 2018: Summer (02/09/2018) e Winter (19/07/2018).
Tipo de amostragem	Amostragem para treinamento/validação: pontos de amostra divididos em 70% treinamento / 30% validação. (Amostragem construída a partir de interpretação/controle de campo e imagens de referência). .WorldView-2 multispectral satellite image from 02/05/2018 with 1.85 m spatial resolution , selected 2000 random points
Unidade de processamento	Pixel-based

Feição	polígonos de classes
Número de feições	não informado
Método de classificação	Decision Tree (CART)
<i>Classificador</i>	CART (Classification and Regression Trees)
Índices de validação	Proportion Correct (PC), Producer's Accuracy (PA) e User's Accuracy (UA) — matriz de confusão usada para cálculo.
Acurácia	95.9%
Resolução das imagens	Resultado/processamento em 10 m (bands 3/4/8 nativamente 10 m; bandas SWIR resampleadas a 10 m).
Extensão da área	não especificado
Uso de IA	Sim (ML clássico): uso de algoritmo de aprendizagem (CART: árvore de decisão) aplicado a variáveis (17 índices). Embora CART seja uma técnica de machine-learning/ data-mining (não deep learning), caracteriza aplicação de IA/ML no fluxo.
Tipo de área úmida	marisma/brejo interior/plantação de arroz
Revista publicada	Revista de Teledetección (Spanish Journal of Remote Sensing)

Título	Wetland mapping with multitemporal Sentinel radar remote sensing in the southeast region of Brazil.
Autores	J. B. G. Salinas; M. K. P. Eggerth; M. E. Miller; R. R. B. Meza; J. T. A. Chacaltana; J. R. Acuña; G. F. Barroso.
Ano de publicação	2020
Local do estudo	Brasil, sudeste do país
Tipo de dados	Radar
Sensor	Sentinel-1B
Série temporal	Multitemporal — imagens de 2016 e 2019
Tipo de amostragem	Validação de campo / ground truth
Unidade de processamento	Pixel-based
Feição	Polígonos de wetlands
Número de feições	4.157
Método de classificação	K-means (unsupervised clustering)
<i>Classificador</i>	K-means (algoritmo de clusterização não-supervisionada)

Índices de validação	Matriz de confusão / acurácia temática comparada com dados de campo: Overall Accuracy (OA) e Kappa reportados; acurácia por classe também apresentada (wetlands, non-wetlands, open water).
Acurácia	81.9%
Resolução das imagens	10 m
Extensão da área	262.27 km ²
Uso de IA	Sim, uso de técnica de aprendizado não-supervisionado (K-means clustering), que é uma forma básica de machine learning
Tipo de área úmida	zonas úmidas da planície costeira
Revista publicada	The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences

Título	Exploring a Deep Convolutional Neural Network and GEOBIA for Automatic Recognition of Brazilian Palm Swamps (Veredas) Using Sentinel-2 Optical Data.
Autores	Hugo N. Bendini; Leila M. G. Fonseca; Raian V. Mareto; Bruno M. Matosak; Evandro C. Taquary; Philippe S. Simões; Ricardo F. Haidar; Dalton de M. Valeriano.
Ano de publicação	2021
Local do estudo	Brasil — duas ecorregiões do Cerrado: “Chapadão do São Francisco” (oeste da Bahia) e “Basaltos do Paraná” (noroeste de Minas Gerais).
Tipo de dados	Óptico
Sensor	Sentinel-2 (bandas 2, 3 e 8: Blue, Green/Red, NIR: processadas a 10 m).
Série temporal	data única
Tipo de amostragem	Base de campo fornecida por secretarias estaduais (field-work database). even collecting samples only in one region, the model presented a good transferability, with a reasonable performance in a different ecoregion, in which the Veredas present different spatial patterns.
Unidade de processamento	Dual: object-based (GEOBIA — segmentação multiresolução e extração de 22 atributos por segmento) e pixel/patch-based para Deep Learning (chips para U-Net / semantic segmentation).

Feição	Vereda (palm swamp) vs Other (restante da paisagem)
Número de feições	não especificado
Método de classificação	Comparação direta entre: (a) GEOBIA com Random Forest aplicado aos objetos (segmentos) e (b) Deep CNN (U-Net) para segmentação semântica (treinada com chips).
<i>Classificador</i>	GEOBIA → Random Forest (mtry = 5; ntree = 500). Deep learning → U-Net (baseline U-Net via DeepGeo; 50 epochs, batch size 5, learning rate 0.1 com decaimento, Average Soft Dice loss, data augmentation).
Índices de validação	Matriz de confusão; Overall Accuracy (OA); Sensitivity; Specificity; F1-score por classe; tabelas de confusão apresentadas para cada método e região (treino e transferência).
Acurácia	93%
Resolução das imagens	10 m
Extensão da área	não especificado
Uso de IA	Sim — aplicação direta de Deep Learning. Uso explícito de U-Net (CNN) para segmentação semântica (semantic segmentation) e comparação com abordagem GEOBIA+RF. O artigo ainda emprega machine-learning clássico (Random Forest) dentro do fluxo GEOBIA.
Tipo de área úmida	veredas
Revista publicada	Remote Sensing

Título	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.
Autores	João Paulo Delapasse Simioni; Laurindo Antonio Guasselli; Victor Fernandez Nascimento; Luis Fernando Chimelo Ruiz; Tássia Fraga Belloli.
Ano de publicação	2020
Local do estudo	Brasil, RS — Banhado Grande
Tipo de dados	Radar
Sensor	ALOS PALSAR-1 (L-band, full-pol available for the area in 2011) e Sentinel-1 (C-band, GRD dual-pol VV/VH). Processamento SAR em SNAP (calibração radiométrica, filtragem de speckle, composições polarimétricas).

Série temporal	Data única/campanha focal
Tipo de amostragem	Amostragem por pontos de referência (coleta/interpretação): total 1.000 amostras divididas em 700 (70%) para treinamento e 300 (30%) para validação.
Unidade de processamento	Pixel-based
Feição	4 classes temáticas: Marsh (MA); Wet meadow (WM); Rice crop (RC); Bare soil (BS).
Número de feições	não informado
Método de classificação	Decision Tree (CART)
<i>Classificador</i>	CART (Classification and Regression Trees)
Índices de validação	Matriz de confusão; Proportion Correct (PC) (Pontius & Millones), Producer's Accuracy (PA) e User's Accuracy (UA) (Congalton). Relataram PA/UA por classe e PC global.
Acurácia	73%
Resolução das imagens	10 m
Extensão da área	5.591 ha
Uso de IA	Sim — técnicas de data-mining / machine-learning clássicas foram aplicadas.
Tipo de área úmida	brejo interior / planície alagável
Revista publicada	International Journal of Applied Earth Observation and Geoinformation

Título	Mapping vegetation in a late Quaternary landform of the Amazonian wetlands using object-based image analysis and decision tree classification.
Autores	Carlos Leandro de Oliveira Cordeiro; Dilce de Fátima Rossetti.
Ano de publicação	2015
Local do estudo	Brasil, Roraima
Tipo de dados	optical + radar + dem
Sensor	ASTER (bandas VNIR usadas: band 1 e band 3 mencionadas), ALOS PALSAR (HH & HV polarizações), SRTM DEM; também NDVI derivado de ASTER.
Série temporal	data única
Tipo de amostragem	Amostras de referência / validação derivadas de campanhas/imagemery: conjuntos de amostras obtidos a partir de fotos aéreas, imagens de alta/moderada resolução no Google Earth e endmembers espectrais

Unidade de processamento	Object-based (OBIA)
Feição	classes mapeadas
Número de feições	não informado
Método de classificação	OBIA + data-mining (Decision Tree)
<i>Classificador</i>	Decision Tree (DT / data-mining)
Índices de validação	Matriz de confusão → Overall Accuracy (OA); Kappa (κ); e também quantity & allocation disagreement
Acurácia	88%
Resolução das imagens	ASTER VNIR (bandas 1–3) — 15 m (band 1 e band 3 mencionadas); SWIR bands ASTER a 30 m quando aplicáveis; SRTM DEM (\approx 30 m);
Extensão da área	dentro: 91606.03 ha; fora: 161116.45 ha
Uso de IA	Sim — Data Mining / Machine Learning aplicado.
Tipo de área úmida	várzeas amazônicas
Revista publicada	Acta Amazonica

Título	SAR Backscatter and InSAR Coherence for Monitoring Wetland Extent, Flood Pulse and Vegetation: A Study of the Amazon Lowland.
Autores	Francis Canisius; Brian Brisco; Kevin Murnaghan; Marco Van Der Kooij; Edwin Keizer.
Ano de publicação	2019.
Local do estudo	Brasil, Pará
Tipo de dados	radar + dem
Sensor	RADARSAT-2 extra-fine mode (XF0W2) Single Look Complex (C-band, HH)
Série temporal	Multitemporal (2014-2016)
Tipo de amostragem	Validação temática com pontos de referência / amostras de verificação: N = 200 pontos usados na matriz de confusão
Unidade de processamento	Pixel-based
Feição	polígonos de classes
Número de feições	não informado
Método de classificação	Extração de produtos estatísticos temporais de intensidade e coerência (stack statistics) + thresholding / regras empíricas
<i>Classificador</i>	Rule-based / thresholding / empirical decision rules
Índices de validação	Matriz de confusão (200 pontos); calculados Overall Accuracy (OA) e Kappa, além de Producer's/User's Accuracy por classe

Acurácia	86%
Resolução das imagens	RADARSAT-2 SLC com espaçamento de pixel em slant ~2.6 m (range) × 2.5 m (azimuth) — dados de alta resolução (extra-fine mode; referência a 1–5 m para interferometria). Produtos multi-look e ortorretificados usados nos mapas finais.
Extensão da área	aproximadamente 139 × 71 km ²
Uso de IA	Não — o estudo não aplicou técnicas de IA modernas.
Tipo de área úmida	várzeas amazônicas
Revista publicada	Remote Sensing of Environment

Título	Geographic Object-Oriented Analysis of UAV Multispectral Images for Tree Distribution Mapping in Mangroves.
Autores	Luis Américo Conti; Roberto Lima Barcellos; Priscila Oliveira; Francisco Cordeiro Nascimento Neto; Marília Cunha-Lignon.
Ano de publicação	2025
Local do estudo	Brasil — duas áreas costeiras: Cardoso Island (SP) e Suape Bay (PE).
Tipo de dados	Óptico
Sensor	DJI Phantom 4 Multispectral (P4M)
Série temporal	data única
Tipo de amostragem	Amostragem dirigida com inventário de campo
Unidade de processamento	Object-based
Feição	polígonos
Número de feições	não informado
Método de classificação	Workflow OBIA: segmentação multiresolução
<i>Classificador</i>	Random Forest (RF); Deep Neural Network
Índices de validação	Matrizes de confusão (por região e algoritmo); Overall Accuracy (OA); Producer's / User's Accuracy; F1-score / Sensitivity / Specificity
Acurácia	não especificado
Resolução das imagens	GSD: voos de detalhe ≈ ~1.4 cm/pixel; voos de mapeamento ≈ ~6 cm/pixel (
Extensão da área	não informado
Uso de IA	Sim. Aplicaram ML/IA: Random Forest (ML clássico), Deep Neural Network (aprendizado profundo) e Naive Bayes integrados ao fluxo OBIA.

Tipo de área úmida	manguezal
Revista publicada	Remote Sensing, v. 12, n. 22

Título	A Multiscale Approach Indicates a Severe Reduction in Atlantic Forest Wetlands and Highlights that São Paulo Marsh Antwren Is on the Brink of Extinction.
Autores	Glauca Del-Rio; Marco Antônio Rêgo; Luís Fábio Silveira.
Ano de publicação	2015.
Local do estudo	Brasil: bacias do Alto Tietê e Alto Paraíba do Sul, Estado de São Paulo
Tipo de dados	óptico + dem
Sensor	Landsat-8 (OLI), WorldClim para variáveis climáticas; SRTM para topografia/hidrologia.
Série temporal	Dados históricos desde início do século XX (mapas de ~1905 etc.) até dados atuais (coleta de campo e imagens modernas ~2011-2013).
Tipo de amostragem	Amostras de presença conhecidas: 15 locais históricos para modelagem; validação de campo em 59 locais verificados entre 2011–2013; registro de presença em 13 desses.
Unidade de processamento	Modelagem de distribuição de espécie (SDMs) + modelos de ocupação + verificação de habitat via imagens / classificação visual; área contínua de habitat potencial como raster; visualização em mapas.
Feição	Presença/ausência da espécie <i>Formicivora paludicola</i> ; habitat adequado vs inadequado; variáveis de ocupação como densidade de <i>Typha</i> , proximidade de rodovias, eucalipto, etc. Não é mapeamento de vegetação por classe ampla.
Número de feições	não informado
Método de classificação	Seis métodos de SDM comparados: GLM, GAM, MARS, Classification Tree Analysis (CTA), Artificial Neural Networks (ANN), Random Forest (RF). Random Forest teve melhor desempenho. Para ocupação, uso de modelos de ocupação (Occupancy models) e detecções em campo.
<i>Classificador</i>	Random Forest foi o melhor modelo para previsões de distribuição; usado para guiar campo.
Índices de validação	AUC, Kappa, TSS (True Skill Statistic) utilizados para avaliar desempenho dos modelos SDM. Validação de campo dos modelos preditivos.

Acurácia	100%
Resolução das imagens	Climáticas / altimétricas \approx 1 km (WorldClim / SRTM rasters). Landsat resolução de 30 m para imagens recentes; mapas históricos têm resoluções variadas. (15m)
Extensão da área	Extent of Occurrence (EOO) estimado \sim 1,268 km ² ; Environmental Suitability EOO \sim 1,245 km ² ; AOO \sim 1.42 km ² . Perda histórica de habitat apropriado $>$ 346 km ² .
Uso de IA	Sim: uso de métodos de machine learning / modelagem de espécies: ANN (Artificial Neural Networks) entre os sete métodos testados; Random Forest; também Classification Tree Analysis.
Tipo de área úmida	brejos e banhados da Mata Atlântica
Revista publicada	PLoS ONE, v. 14, n. 9

Título	Mapping and classification of wetlands using Topographic Wetness Index (TWI) from Digital Elevation Models of the Gravataí River Basin — Rio Grande do Sul State (RS), Brazil).
Autores	Laurindo A. Guasselli; João P. D. Simioni; François Laurent
Ano de publicação	2020
Local do estudo	Brasil — Estado do Rio Grande do Sul; Bacia do Rio Gravataí
Tipo de dados	óptico + dem
Sensor	ALOS PALSAR, ASTER GDEM e SRTM
Série temporal	Estudo baseado em produtos estáticos (DEMs) e imagens de verificação
Tipo de amostragem	não aplicável
Unidade de processamento	pixel-based
Feição	rede de drenagem sintética
Número de feições	não informado
Método de classificação	Cálculo de TWI a partir de DEMs + aplicação de limiares
<i>Classificador</i>	A classificação das amostras para definição de um limiar foi realizada a partir do método Classification and Regression Trees (CART). Rule-based / thresholding
Índices de validação	drainage delineation accuracy e channel initiation accuracy
Acurácia	75.1%

Resolução das imagens	ALOS PALSAR DEM = 12.5 m; ASTER GDEM = 30 m; SRTM = 30 m e 90 m
Extensão da área	Bacia do Rio Gravataí
Uso de IA	Não: fluxo baseado em índice topográfico (TWI)
Tipo de área úmida	banhados e áreas úmidas continentais
Revista publicada	Journal of Environmental Geography

APÊNDICE B - LISTA DE ARTIGOS SELECIONADOS APÓS LEITURA DO TÍTULO E ABSTRACT

Título	Número
Classification of wetlands and their macrohabitats in the marine floodplain of the Apodi-Mossoró river/RN (semi-arid coast of Brazil)	1
Forest vulnerability to coverage and use of land in an estuarine Environmental Protection Area of Pernambuco	2
Challenges of defining the floodplain through the “mean ordinary flood line” approach using remote sensing in Brazil: a case study of the São Francisco River	3
Land-cover changes and drivers of palm swamp degradation in southeastern Brazil from 1984 to 2018	4
Tidal flood area mapping in the face of climate change scenarios: Case study in a tropical estuary in the Brazilian semi-arid region	5
Mapping and classification of wetlands using topographic wetness index (twi) from digital elevation models of the the gravataí river basin - Rio grande do sul state (Rs), Brazil	6
High-resolution optical remote sensing for coastal benthic habitat mapping: A case study of the Suape Estuarine-Bay, Pernambuco, Brazil	7
Mangrove Typology: A Proposal for Mapping based on High Spatial Resolution Orbital Remote Sensing	8
Mangrove Typology: A Proposal for Mapping based on HighSpatial Resolution Orbital Remote Sensing	9
Detection of changes in mangroves along the Coreaú River Estuary, Northeastern Brazil from object-oriented classification in orbital images	10
Contribution of automatically generated radar altimetry water levels from unsupervised classification to study hydrological connectivity within Amazon floodplains	11
Characterizing seasonal dynamics of Amazonian wetlands for conservation and decision making	12
Multi-temporal flood mapping and satellite altimetry used to evaluate the flood dynamics of the Bolivian Amazon wetlands	13
Forest vulnerability to coverage and use of land in an estuarine Environmental	14

Protection Area of Pernambuco	
Small inner marsh area delimitation using remote sensing spectral indexes and decision tree method in southern Brazil	15
Influence of the structural framework on peat bog distribution in the tropical highlands of Minas Gerais, Brazil	16
Image fusion of Sentinel-2 and CBERS-4 satellites for mapping soil cover in the Wetlands of Pantanal	17
Classification of mangrove species in the north eastern of Brazil based on hybrid images of remote sensing	18
Spatial database modeling for mangrove forests mapping; example of two estuarine systems in Brazil	19
Genesis of peatlands and environmental changes quaternary in Serra do Espinhaço Meridional - MG	20
A multiscale approach indicates a severe reduction in atlantic forest wetlands and highlights that São Paulo Marsh antwren is on the brink of extinction	21
Mangrove shrimp farm mapping and productivity on the Brazilian Amazon coast: Environmental and economic reasons for coastal conservation	22
Hydrogeomorphology of wetlands in Chapada do Araripe, Northeast Brazil	23
Spatial-temporal distribution of mangrove species in the estuary of the Mamanguape river in the state of Paraíba, Brazil	24
Comparison of vegetation indices and image classification methods for mangrove mapping at semi-detailed scale in southwest of Rio de Janeiro, Brazil	25
Mangrove changes over the past decade in South and Southeast Brazil using spaceborne optical and SAR imagery	26
Classification of wetlands and their macrohabitats in the marine floodplain of the Apodi-Mossoró river/RN (semi-arid coast of Brazil)	27
Spatiotemporal dynamics of mangrove forest and association with strandings of Antillean manatee (<i>Trichechus manatus</i>) calves in Paraíba, Brazil	28
A comparison of data mining techniques and multi-sensor analysis for inland marshes delineation	29
SPATIOTEMPORAL DYNAMICS (1986-2020) OF MANGROVES FROM RESEX OF THE MOUTH OF THE PARÁ RIVER (EASTERN AMAZON, BRAZIL)	30
Epibenthic marine habitat mapping in a tropical bay: Todos os Santos Bay, Eastern Brazil	31
Status of mangroves land use on the Brazilian Amazon coast from RapidEye imagery and GEOBIA approach	32
Land Use and Occupation of Coastal Tropical Wetlands: Whale Coast, Bahia, Brazil	33
Environmental sensitivity map of Solimoes river basin using SAR images and fuzzy modeling	34
SAR Backscatter and InSAR Coherence for Monitoring Wetland Extent, Flood Pulse and Vegetation: A Study of the Amazon Lowland.	35
The neglected tropical grasslands: first record of campo com murundus and its plant communities in the state of Sao Paulo, Brazil	36

WETLAND MAPPING WITH MULTITEMPORAL SENTINEL RADAR REMOTE SENSING IN THE SOUTHEAST REGION OF BRAZIL	37
Estimation of the extent of defoliation in <i>Avicennia</i> L. (Acanthaceae) caused by caterpillars of <i>Hyblaea puera</i> (Cramer, 1777) in a tropical mangrove	38
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.	39
A new data-driven map predicts substantial undocumented peatland areas in Amazonia	40
The global distribution and trajectory of tidal flats	41
The neglected tropical grasslands: first record of campo com murundus and its plant communities in the state of Sao Paulo, Brazil	42
Future scenarios based on a CA-Markov land use and land cover simulation model for a tropical humid basin in the Cerrado/Atlantic forest ecotone of Brazil	43
Impacts of Holocene and modern sea-level changes on estuarine mangroves from northeastern Brazil	44
A Multiscale Approach Indicates a Severe Reduction in Atlantic Forest Wetlands and Highlights that Sao Paulo Marsh Antwren Is on the Brink of Extinction	45
Ecosystem-based management of Amazon fisheries and wetlands	46
Modeling Wetland Biomass and Aboveground Carbon: Influence of Plot Size and Data Treatment Using Remote Sensing and Random Forest	47
Geographic Object-Oriented Analysis of UAV Multispectral Images for Tree Distribution Mapping in Mangroves	48
Comparison of vegetation indices and image classification methods for mangrove mapping at semi-detailed scale in southwest of Rio de Janeiro, Brazil	49
Ecosystem-based management of Amazon fisheries and wetlands	50
Natural superficial water storage and aquifer recharge assessment in Brazilian savanna wetland using unmanned aerial vehicle and geophysical survey	51
Exploring a Deep Convolutional Neural Network and GEOBIA for Automatic Recognition of Brazilian Palm Swamps (Veredas) Using Sentinel-2 Optical Data	52
Small inner marsh area delimitation using remote sensing spectral indexes and decision tree method in southern Brazil	53
Remote Sensing Assessment of Suspended Matter and Dynamics in Patos Lagoon	54
Natural superficial water storage and aquifer recharge assessment in Brazilian savanna wetland using unmanned aerial vehicle and geophysical survey	55
REMOTE DETECTION OF POTENTIAL EFFECTS OF INTENSE DROUGHTS ON THE SEASONALITY OF WATER IN THE FLUVIAL-LACUSTRINE COMPLEX OF CURUAI, AMAZON RIVER, PARR, BRAZIL	56
Mangrove changes over the past decade in South and Southeast Brazil using spaceborne optical and SAR imagery	57
Improving mangrove above-ground biomass estimates using LiDAR	58
Seasonal foliage changes in the eastern Amazon basin detected from Landsat	59

Thematic Mapper satellite images	
A new data-driven map predicts substantial undocumented peatland areas in Amazonia	60
Spatial database modeling for mangrove forests mapping; example of two estuarine systems in Brazil	61
Geographic Object-Oriented Analysis of UAV Multispectral Images for Tree Distribution Mapping in Mangroves	62
Mangrove Forests Submitted to Depositional Processes and Salinity Variation Investigated using satellite images and vegetation structure surveys	63
Epibenthic marine habitat mapping in a tropical bay: Todos os Santos Bay, Eastern Brazil	64
High resolution mapping of inundation area in the Amazon basin from a combination of L-band passive microwave, optical and radar datasets	65
Impacts of land use change on mangrove blue carbon services: A future perspective in northeastern Brazil	66
Landscape dynamics in Amazon floodplains: a study of Lake Grande do Curuai, Para, Brazil	67
Mapping vegetation in a late Quaternary landform of the Amazonian wetlands using object-based image analysis and decision tree classification	68
High resolution mapping of inundation area in the Amazon basin from a combination of L-band passive microwave, optical and radar datasets	69
MAPPING AND CLASSIFICATION OF WETLANDS USING TOPOGRAPHIC WETNESS INDEX (TWI) FROM DIGITAL ELEVATION MODELS OF THE THE GRAVATAI RIVER BASIN RIO GRANDE DO SUL STATE (RS), BRAZIL	70
Contribution of automatically generated radar altimetry water levels from unsupervised classification to study hydrological connectivity within Amazon floodplains	71
Monitoring mangrove degradation caused by oil spills using spaceborne multispectral and SAR imagery	72
REMOTE DETECTION OF POTENTIAL EFFECTS OF INTENSE DROUGHTS ON THE SEASONALITY OF WATER IN THE FLUVIAL-LACUSTRINE COMPLEX OF CURUAI, AMAZON RIVER, PARR, BRAZIL	73