

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

TÁSSIA FRAGA BELLOLI

**ESTIMATIVA DE BIOMASSA E ESTOQUE DE CARBONO DE VEGETAÇÃO
MACROFÍTICA A PARTIR DE DADOS ESPECTRAIS E DE CAMPO,
BANHADO GRANDE, RS.**

Porto alegre
2019

TÁSSIA FRAGA BELLOLI

**ESTIMATIVA DE BIOMASSA E ESTOQUE DE CARBONO DE VEGETAÇÃO
MACROFÍTICA A PARTIR DE DADOS ESPECTRAIS E DE CAMPO,
BANHADO GRANDE, RS.**

Dissertação apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto da Universidade Federal do Rio Grande do Sul, como requisito parcial para obtenção do Título de Mestre em Sensoriamento Remoto e Geoprocessamento.

Área de Concentração: Sensoriamento Remoto aplicado.

Orientadora: Tatiana Mora Kuplich

Co-Orientador: Laurindo Antonio Guasselli

BANCA EXAMINADORA

Prof. Dra. Denise Cybis Fontana – UFRGS

Prof. Dr. Luis Chimelo Ruiz –UFRGS

Prof. Dra. Rutineia Tassi – UFSM

Porto alegre
2019

CIP - Catalogação na Publicação

Belloli, Tássia Fraga

Estimativa de biomassa e estoque de carbono de vegetação macrofítica a partir de dados espectrais e de campo, Banhado Grande, RS. / Tássia Fraga Belloli. -- 2019.

127 f.

Orientadora: Tatiana Mora Kuplish.

Coorientador: Laurindo Antonio Guasselli.

Dissertação (Mestrado) -- Universidade Federal do Rio Grande do Sul, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Programa de Pós-Graduação em Sensoriamento Remoto, Porto Alegre, BR-RS, 2019.

1. Áreas úmidas. 2. Biomassa. 3. Carbono azul. 4. Sensoriamento Remoto. I. Kuplish, Tatiana Mora, orient. II. Guasselli, Laurindo Antonio, coorient. III. Título.

AGRADECIMENTOS

Agradeço à Universidade Federal do Rio Grande do Sul e ao Centro Estadual de Pesquisa em Sensoriamento Remoto (CEPSRM), pela estrutura, auxílio financeiro, aprendizado e ensino de qualidade, sem os quais não seria possível a realização desta pesquisa.

Ao CNPQ, pelo apoio financeiro-institucional concedido.

Aos colegas do PPGSR, pelos conhecimentos trocados e parcerias.

À minha orientadora, Prof. Dr^a. Tatiana Mora Kuplich, pela oportunidade concedida, incentivos e ensinamentos trocados durante a pesquisa. Ao meu orientador Prof. Dr. Laurindo Antonio Guasselli, pelos ensinamentos, dedicação, apoio e ética durante os 6 anos de pesquisas compartilhadas. À ambos por acolherem meu tema de pesquisa e acreditarem na minha capacidade de realizar este trabalho.

À Fundação do Meio Ambiente de Gravataí e ao Paulo Müller, que proporcionaram estrutura e suporte para os trabalhos de campo, fundamentais para a pesquisa. Também aos colaboradores que me ajudaram com as coletas de campo.

Ao Aiurgue Rosa pelo companheirismo, total apoio e incentivo, carinho e compreensão durante esta pesquisa, pela força nos momentos difíceis.

Aos meus pais e irmã, pelo apoio incondicional nos estudos.

Agradeço a todos que me acompanharam durante esta pesquisa e que contribuíram de alguma forma para essa etapa da minha vida.

Quanto mais espiritual se busca ser, mais comprometimento com a natureza deve haver. Uma vez que o homem é a própria natureza – e o absoluto se manifestando na natureza que cada um é – a busca pelo autoconhecimento passa necessariamente pelo conhecimento intuitivo, contemplativo e metodológico do mundo natural. Com a integração espiritual à natureza – o que gera proteção, preservação e sustentabilidade.

O eco dos druidas (2018). Yuri Levi/

Nolando

Aos meus pais e companheiro, pelo incentivo e apoio incondicional durante minha formação acadêmica.

A minha “cãopaneira” Lili, que partiu na fase final desta pesquisa e me mostrou como posso ser forte diante das peripécias da vida, dedico.

RESUMO

Diante do cenário de mudanças climáticas, as Áreas Úmidas (AUs) tem se destacado por atuarem substancialmente como sumidouro de CO₂ atmosférico a partir de sua fixação na biomassa vegetal e nas turfeiras. No entanto, a degradação destes ecossistemas faz com que as AUs passem de ecossistemas fixadores de CO₂ para fonte de gases de efeito estufa. Desse modo, quantificar e monitorar biomassa é de grande importância para preservar os estoques de carbono, bem como estimativas acuradas de carbono podem contribuir para preservação, prevenção de perdas e restauração destes ecossistemas. Este estudo teve como objetivo principal estimar biomassa vegetal e estoques de carbono orgânico da espécie *Scirpus giganteus*, no Banhado Grande – RS, a partir de dados espectrais e dados de campo. Para tanto, utilizou-se dois métodos: i) delimitação da área da espécie por Análise de Imagem Baseada em Objetos Geográficos (GEOBIA) e mineração de dados *Random Forest*, integrando imagens dos sensores Sentinel 1 e 2A; e ii) análise de correlação e regressão linear a partir de dados de campo e espectrais dos sensores PlanetScope e Sentinel-2A.

Coletas de vegetação foram realizadas em área experimental no Banhado Grande, município de Glorinha, durante um ciclo anual. Na GEOBIA foi utilizado o método de mineração de dados *Random Forest* (RF) para classificação de espécies de vegetação no Banhado Grande, visando delimitar a área ocupada pela espécie *S.giganteus* e estimar os estoques das variáveis biofísicas para sua área total de cobertura. As equações de regressão envolveram como variáveis dependentes (y): a biomassa e o carbono orgânico vegetal, obtidos diretamente nas amostras, e como variáveis independentes (x) as bandas espectrais e os índices de vegetação (IV). O tratamento estatístico envolveu a análise da matriz de correlação (r) entre as variáveis x e y; a análise de regressão linear simples e múltipla, com as seguintes estatísticas: R², R²aj., EQM, CV%, DP e análise de resíduos. Como resultados, a classificação GEOBIA alcançou uma acurácia de 91,3% e de 91% para a classe Emergente, correspondente à área da *S.gigantes* (1.507 ha). Considerando os valores médios, obteve-se um estoque de biomassa de 8,63 ton/ha e 3,54 ton/ha de carbono orgânico para a área da classe. Os índices de vegetação foram mais bem correlacionados e preferíveis como variáveis preditoras nos modelos de regressão. O modelo mais acurado ocorreu com dados do sensor PlanetScope e IV sPRI, a partir de uma regressão linear simples. Gerou uma estimativa média de 656.33 g/m² de biomassa (EQM =157,10 g/m², 23,8% da biomassa média observada) e de 270.81 g/m² de carbono (EQM =62,77 g/m², 23% do carbono médio observado). Além de proverem estimativas atuais das variáveis biofísicas, com relativa confiabilidade, o uso destas metodologias a partir de dados dos sensores ópticos e SAR possibilitam minimizar os esforços de campo, mostrando-se especialmente úteis para monitoramento e inventário dos estoques de carbono. Contribuem desse modo, com o reconhecimento da função ambiental do Banhado Grande como ecossistema de carbono azul.

Palavras-chave: biomassa, carbono azul, sensoriamento remoto, áreas úmidas, banhados, Análise de Imagens Baseada em Objetos, modelos de regressão,

ABSTRACT

Given the climate change scenario, the wetlands have stood out for acting substantially as atmospheric CO₂ sinks from their fixation on plant biomass and peat bogs. However, the degradation of these ecosystems causes wetlands to move from CO₂-fixing ecosystems to a source of greenhouse gases. Thus, quantifying and monitoring biomass is of great importance for preserving carbon stocks, and accurate carbon estimates can contribute to the preservation, loss prevention and restoration of these ecosystems. This study aimed to estimate plant biomass and organic carbon stocks of *Scirpus giganteus* species in Banhado Grande, from spectral data and field data. For this purpose, two methods were used: i) delimitation of the species area by Geographic Object Based Image Analysis (GEOBIA) and Random Forest data mining, integrating Sentinel 1 and 2A sensor images; and ii) correlation and linear regression analysis from field and spectral data from the PlanetScope and Sentinel-2A sensors. Vegetation collections were performed in an experimental area in Banhado Grande, municipality of Glorinha-RS, during an annual cycle. In GEOBIA, the Random Forest (RF) data mining method was used to classify vegetation species in Banhado Grande, aiming to delimit the area occupied by the species *S.giganteus* and to estimate the stocks of biophysical variables for their total coverage area. The regression equations involved as dependent variables (y): aboveground biomass and organic carbon, obtained directly in the samples, and as independent variables (x) the spectral bands and the vegetation indices (VIs). The statistical treatment involved the analysis of the correlation matrix (r) between the variables x and y; the simple and multiple linear regression analysis, with the following statistics: R², R²_{aj.}, RMSE, CV%, SD and residual analysis. As a result, the GEOBIA classification reached an accuracy of 91.3% and 91% for the Emerging class, corresponding to the *S.giganteus* area (1,507 ha). Considering the average values, a aboveground biomass stock of 8.63 tons/ha and 3.54 tons/ha of organic carbon were obtained for the class area. Vegetation indices were better correlated and preferable as predictor variables in the regression models. The most accurate model occurred with data from the PlanetScope and VI sPRI sensor from a simple linear regression. It generated an average estimate of 656.33 g/m² of biomass (RMSE = 157.10 g / m², 23.8% of the average observed biomass) and 270.81 g/m² of carbon (RMSE = 62.77 g / m², 23% of the observed average carbon). In addition to providing current estimates of biophysical variables with relative reliability, the use of these methodologies from the optical sensor and SAR data makes it possible to minimize field efforts and is especially useful for monitoring and inventorying carbon stocks. They also contributed to the recognition of Banhado Grande's environmental function as a blue carbon ecosystem.

Keywords: Aboveground biomass, blue carbon, remote sensing, wetlands, marshes, Object-based Image Analysis , regression models.

LISTA DE ILUSTRAÇÕES

Figura 1. Localização da área de estudo.....	7
Figura 2. Litologia da área de estudo.....	8
Figura 3. Mapa altimétrico APABG/BHRG.....	9
Figura 4. Precipitação média mensal (mm) na APABG.....	10
Figura 5. Indivíduo de <i>Scirpus giganteus</i>	11
Figura 6. Formas biológicas: a) emergente; b) anfíbia.	13
Figura 7. Formas biológicas das macrófitas aquáticas.....	17
Figura 8. Curva de fator de reflectancia típica de uma folha verde.....	27
Figura 9. Curva de reflectancia de folhas verdes e senescentes.....	28
Figura 10. Curvas espectrais de reflectância da vegetação, do solo e da gua.....	29
Figura 11. Curvas de reflectância espectral de Spatterdock.....	31
Figura 12. Projeção simplificada das parcelas. Imagem aérea obtida por drone.....	47
Figura 13. A) Imagem com ponto de localização de uma parcela; b) imagem pós corte da vegetação.	49
Figura 14. Amostras coletadas no segundo trabalho de campo.....	49
Figura 15. Obtenção da biomassa seca das amostras.	51
Figura 16. Fluxograma metodológico.	56
Figura 17. Fluxograma metodológico.....	61
Figura 18. Boxplot das variáveis biofísicas.....	69
Figura 19. Precipitação acumulada para 5, 20, 30 e 60 dias.....	71
Figura 20. Classificação baseada em objetos no Banhado Grande.	75
Figura 21. Dispersão dos valores estimados pelas equações vs observados em conjunto com a reta de regressão.....	89

LISTA DE TABELAS

Tabela 1. Imagens utilizadas para o estudo.	52
Tabela 2. Características das bandas ópticas.	56
Tabela 3. Características.....	60
Tabela 4. Índices de vegetação utilizados no estudo	61
Tabela 5. Estatísticas das variáveis biofísicas.	64
Tabela 6. Classes, dominância de espécies e tipologias no Banhado Grande.	69
Tabela 7. Matriz de confusão	76
Tabela 8. Estatísticas das variáveis espectrais nas parcelas em cada um dos sensores..	80
Tabela 9. Matriz de correlação entre as bandas espectrais e variáveis biofísicas.	81
Tabela 10. Matriz de correlação entre os índices espectrais e variáveis biofísicas em cada sensor.....	84
Tabela 11. Matriz de correlação entre os índices espectrais de borda vermelha e variáveis biofísicas. Em negrito, a mais alta correlação.....	86
Tabela 11. Equações de regressão..	87
Tabela 12. Estimativas das variáveis biofísicas em g/m ² , geradas a partir das regressões lineares vs valores observados <i>in situ</i>	88

LISTA DE ABREVIATURAS E SIGLAS

AD: Árvore de decisão

APABG: Área de Proteção Ambiental do Banhado Grande

AUs: Áreas úmidas

CO₂: Carbono atmosférico

CPRM: Companhia de Pesquisa de Recursos Minerais

CV: Coeficiente de Variação

DNOS: Departamento Nacional de Obras de Saneamento

DP: Desvio Padrão

EM: Espectro Eletromagnético

EQM: Erro Quadrático Médio

g/m²: Gramas por metro quadrado

GEE: Gases de Efeito Estufa

GEOBIA: Análise de Imagem Baseada em Objetos Geográficos

ha: Hectares

mm: milímetros

MMA: Ministério do Meio Ambiente

NIR: Reflectância no Infravermelho Próximo do EM

PBIA: Análise de imagem baseada em pixel

r: Coeficiente de correlação de Pearson

R²: Coeficiente de determinação

R²aj.: Coeficiente de determinação ajustado

RAS: Radar de Abertura Sintética

RE: Reflectância *Red Edge* (borda vermelha do EM)

REM: Radiação Eletromagnética

RF: Random Forest

RS: Estado do Rio Grande do Sul

RVS: Refúgio de Vida Silvestre

SBG: Sistema Banhado Grande

SWIR: Infravermelho de ondas longas

SWIR: Reflectância no Infravermelho de ondas Curtas do EM

ton/ha: Toneladas por hectare

µm: Nanômetro

SUMÁRIO

1	INTRODUÇÃO	1
1.1	APRESENTAÇÃO	1
1.2	CONTEXTO CIENTÍFICO	1
1.3	JUSTIFICATIVA	4
1.4	OBJETIVO GERAL	5
1.4.1	Objetivos específicos	5
1.5	LOCALIZAÇÃO E CARACTERIZAÇÃO DA ÁREA DE ESTUDO	6
1.5.1	Área de Proteção Ambiental do Banhado Grande (APABG)	6
2	REFERENCIAL TEÓRICO	15
2.1	ÁREAS ÚMIDAS E VEGETAÇÃO MACROFÍTICA	15
2.2	BIOMASSA E PRODUTIVIDADE PRIMÁRIA	21
2.3	CICLO DO CARBONO EM AUs	23
2.4	SENSORIAMENTO REMOTO NO ESTUDO DA VEGETAÇÃO EM AUs	28
2.4.1	Delimitação e classificação de AUs	33
2.4.2	Estimativa de biomassa e carbono em AUs a partir de dados espectrais	38
3	METODOLOGIA	47
3.1	MATERIAIS	47
3.2	MÉTODOS	47
3.2.1	Experimento de campo e amostragem	48
3.2.2	Imagens utilizadas e pré-processamentos	52
3.2.3	Mapeamento da área da espécie a partir de Análise de Imagens Baseada em Objetos Geográficos (GEOBIA) e mineração de dados	57
3.2.4	Estimativa de biomassa e carbono a partir de dados espectrais	62
4	RESULTADOS	68
4.1	QUANTIFICAÇÃO DAS VARIÁVEIS BIOFÍSICAS A PARTIR DAS COLETAS DE CAMPO	68
4.2	DELIMITAÇÃO DA ÁREA DE OCUPAÇÃO DA ESPÉCIE E ESTIMATIVA DAS VARIÁVEIS BIOFÍSICAS	73
4.3	COMPARAÇÃO DOS DADOS ESPECTRAIS DOS SENSORES E CORRELAÇÃO COM AS VARIÁVEIS BIOFÍSICAS	79
4.4	ANÁLISE DOS MODELOS DE REGRESSÃO PARA ESTIMATIVA DAS VARIÁVEIS BIOFÍSICAS	87
5	CONCLUSÕES	91
5.1	CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES	92
6	REFERÊNCIAS	94

ANEXOS

Anexo A. Laudo de análise de carbono orgânico. Amostras 1º trabalho de campo.....114

Anexo B. Laudo de análise de carbono orgânico. Amostras 2º trabalho de campo.....115

Anexo C. Laudo de análise de carbono orgânico. Amostras 3º trabalho de campo.....116

1 INTRODUÇÃO

1.1 APRESENTAÇÃO

Esta dissertação objetivou estimar as variáveis biofísicas de biomassa vegetal e carbono orgânico da espécie *Scirpus gigantes* a partir de dois métodos: i) delimitação da área da espécie por Análise de Imagem Baseada em Objetos Geográficos (GEOBIA) e método de mineração de dados *Ramdon Forest*; e ii) análise de correlação e regressão linear a partir de dados de campo e espectrais dos sensores PlanetScope e Sentinel-2.

O estudo está dividido em cinco tópicos gerais. O primeiro é introdutório, no qual são apresentados o contexto científico, a justificativa da pesquisa e os objetivos, e finda com as características da área de estudo e da espécie vegetal. No segundo tópico é apresentada a revisão teórica e metodológica. No terceiro tópico expõem-se os materiais e descrição dos métodos utilizados.

No quarto tópico apresentam-se os resultados, que incluem a quantificação das variáveis biofísicas a partir dos dados de campo; a delimitação da área da espécie através da GEOBIA e estimativa das variáveis biofísicas em ton/ha para esta área; comparação e análise de correlação dos dados espectrais dos sensores com as variáveis biofísicas e análise dos modelos de regressão linear para estimativa das variáveis através das imagens orbitais.

Finalmente, no quinto tópico foram feitas as conclusões acerca dos resultados apresentados e discutidos neste estudo e considerações finais.

1.2 CONTEXTO CIENTÍFICO

Compreender a dinâmica do carbono nos ecossistemas, especificamente a fixação de carbono atmosférico (CO₂) pelas plantas, é cada vez mais importante diante das mudanças climáticas (CROOKS et al., 2010). Sabe-se que as formações vegetais desempenham um importante papel no ciclo global do carbono, mas ainda são poucos os estudos que têm quantificado o estoque de carbono nos diferentes biomas brasileiros (REZENDE et al., 2006).

Neste cenário, as Áreas Úmidas (AUs) têm se destacado por sua capacidade de absorver e estocar carbono da atmosfera, sendo esta função ambiental objeto de

estudos recentes, referida na literatura internacional como *Blue Carbon* (carbono azul) (MCLEOD *et al.*, 2011; SIIKAMÄKI *et al.*, 2012; WORLD WILDLIFE FUND, 2012).

Apesar da evolução no conhecimento, das cooperações mundiais e legislações que visam à preservação das AUs, estes ecossistemas continuam tendo sua extensão reduzida, o que ameaça seus serviços ecossistêmicos altamente valiosos e imprescindíveis, como, por exemplo, a absorção de dióxido de carbono da atmosfera, que cumpre papel relevantíssimo na mitigação das mudanças climáticas globais (CDB, 2010; RUSSI *et al.*, 2013; DAVIDSON, 2014, MITCH; GOSSELINK, 2015).

De acordo com Russi *et al.* (2013) o carbono nas turfas das AUs se acumula ao longo de milhares de anos em decorrência da inundação permanente que restringe a decomposição aeróbica. Logo, a degradação destes ecossistemas através das atividades humanas faz com que as áreas úmidas passem de ecossistemas fixadores de CO₂ para fonte de gases de efeito estufa.

Tal fato despertou o interesse dos pesquisadores nesta temática, que incluíram as AUs em estudos de balanço de carbono e outros gases essenciais para a regulação do clima (RICHEY *et al.*, 2002; MITCH *et al.*, 2013), bem como para quantificação destes para projetos de compensação de emissões e crédito de carbono, semelhantes aos programas de REDD - Redução das Emissões por Desmatamento e Degradação (MCLEOD, 2011; ALONG, 2012; SUTTON-GRIER; MOORE, 2016).

Dadas as dificuldades de acesso para pesquisas e medições diretas em AUs, a estimativa de dados biofísicos através do sensoriamento remoto é uma alternativa viável e tem sido amplamente utilizada com sensores como AVHRR (PENUELAS *et al.*, 1993); Landsat TM (BARBOSA *et al.*, 2008; FERREIRA, 2015;) HJ-1B (GAO *et al.*, 2017) e World View (MUTANGA; ADAM; CHO, 2012; SCHILE, BYRD, KELLY, 2013; BYRD *et al.*, 2014). Com os novos sistemas de satélite de resolução moderada, a estimativa de dados biofísicos em nível de parcela também pode ser obtida por meio de sensores de imagem aprimorados, com menor tempo de revisitação. Entre essas novas plataformas estão Sentinel-2 (2015, 2017) e PlanetScope (2014).

O uso de modelos estatísticos para estimativa de biomassa e carbono derivados de dados de sensoriamento remoto contribui para o monitoramento do ambiente e para mensurar estes parâmetros na vegetação, minimizando a necessidade de coletas destrutivas. Baseiam-se em modelos empíricos de correlação e regressão,

tendo como variáveis dependentes os parâmetros biofísicos adquiridos *in situ* e como variáveis independentes e preditoras os valores espectrais das bandas e/ou combinações de bandas (índices) (SILVA et al., 2008).

A contribuição das áreas úmidas para a estimativa do estoque total de carbono deve basear-se em conhecimento preciso da área, com ênfase na composição da vegetação, solos e água (GRENIER et al., 2008; MITCH; GOSSELINK, 2015). Em consequência da alta heterogeneidade espacial e variabilidade hidrológica temporal, que se reflete na heterogeneidade dos valores dos pixels, as áreas úmidas estão entre os ecossistemas mais difíceis de mapear e classificar com imagens de sensoriamento remoto (MAHDAVI *et al.*, 2017; BERHAME, 2018).

Devido a isso, estudos mais recentes em áreas úmidas adotam Análise de Imagem Baseada em Objetos Geográficos (GEOBIA), que segmenta a imagem em uma série de objetos que representam um grupo de pixels com padrão espacial e, em seguida, procede-se à classificação da imagem (MISHRA, 2014; DRONOVA, 2015). A abordagem GEOBIA oferece várias vantagens sobre Análise de Imagem Baseada em Pixel (PBI), como a ausência do efeito “sal e pimenta” nos resultados de classificação, capacidade de utilizar formas, características contextuais e texturais e tratamento de paisagens, consistindo em objetos relativamente homogêneos (MISHRA, 2014).

Entre as técnicas de mineração de dados para classificação em AUs estão os algoritmos de classificação por aprendizagem de máquina Árvore de Decisão (AD) e *Random Forest* (RF) que, em comparação com métodos mais tradicionais, fornecem uma estrutura adequada para combinar diferentes tipos de fontes de dados, acomodando bandas e índices derivados de imagens e fontes auxiliares como variáveis hidrogeomórficas, conjuntos de dados de elevação, entre outros (BERHANE et al., 2018).

Os mapeamentos têm sido realizados considerando principalmente variáveis como tipo de vegetação e proporção de inundação (GRENIER et al., 2008; SIEBEN, 2016, MORANDEIRA et al., 2016) métricas de paisagem e topográficas (BERHANE et al., 2018).

1.3 JUSTIFICATIVA

Pesquisas sobre estimativas, compensação de emissões e crédito de carbono têm incentivado gestores públicos a reduzir ou deter a destruição nestes ecossistemas, contribuindo com a preservação, prevenção de perdas e restauração das áreas úmidas (CROOKS et al., 2010) e até a criação de áreas úmidas artificiais (MEANS et al., 2016). No Rio Grande do Sul, no entanto, as AUs têm sido negligenciadas em tais estudos, visto que a quantidade de pesquisas e publicações, principalmente no âmbito internacional, é ainda incipiente.

De acordo com Klamt et al. (1985), estima-se que o estado do Rio Grande do Sul (RS) possuía originalmente 5,3 milhões de hectares de áreas úmidas, o que correspondia a aproximadamente 19% da sua superfície total. Estes ambientes foram intensamente modificados e fragmentados, principalmente em decorrência da agricultura. Mesmo com a supressão, o RS ainda possui importantes e significativos remanescentes destes sistemas, com área total de 600.746,91 ha (RAMOS et al., 2015).

Entre as AUs remanescentes, destaca-se o Banhado Grande e o RVS Banhado dos Pachecos, na Bacia hidrográfica do Rio Gravataí, que além de atuarem como reguladores naturais da vazão do rio, são locais estratégicos de conservação, devido à sua alta diversidade biológica e produtividade. Destacam-se também pela presença de turfeiras ativas (ACOORDI; HARTZ; OHLWEILER, 2003) associadas ao maior grau de umidade e densidade da vegetação (FRANTZ et al., 1990).

O rio Gravataí, originalmente meandrante, teve parte do seu leito retificado pelo Departamento Nacional de Obras de Saneamento (DNOS) com a finalidade de drenar as áreas úmidas da bacia e expandir as áreas agricultáveis. Ao longo dos anos, a intensificação e a sistematização das lavouras orizícolas causaram transformações no regime hídrico do rio e nas áreas úmidas, implicando em impactos ambientais como erosão hídrica (ETCHELAR, 2017) e avanço das lavouras sobre o Banhado Grande, entre outros (GUASSELLI et al., 2015; BELLOLI, 2016).

Devido à sua alta diversidade biológica e para a proteção deste sistema e de suas funções hidrológicas foi criada em 1998 a Área de Proteção Ambiental do Banhado Grande (APABG), com o objetivo de preservar, disciplinar o processo de ocupação e assegurar a sustentabilidade do uso dos recursos naturais. Dentro da área da APA existem mais duas unidades de conservação, uma área de proteção integral

com 2.543,46 ha, o Refúgio de Vida Silvestre Banhado dos Pachecos , no município de Viamão; e uma unidade de conservação municipal de proteção integral, a Reserva Ecológica do Banhado Grande, criada em 1981, com 7.340 ha, no município de Gravataí.

O Banhado Grande é a única área de banhado não reconhecida como unidade de conservação integral dentro da APA. Devido à falta de Plano de Manejo e de fiscalização efetiva, suas áreas limítrofes são pressionadas e gradativamente ocupadas pela agricultura (BELLOLI, 2016).

Diante da persistência dos impactos ambientais sobre o Banhado Grande, esta pesquisa justifica-se pela necessidade de monitoramento e conservação de suas funções ambientais, bem como pela falta de pesquisas sobre a função ambiental dos banhados do RS quanto ambientes fixadores de carbono. A ideia central da pesquisa baseia-se na premissa de que a mensuração da biomassa vegetal e fixação de carbono podem ser realizadas com uso do sensoriamento remoto e geoprocessamento.

1.4 OBJETIVO GERAL

Esta dissertação tem como objetivo geral estimar biomassa vegetal e estoques de carbono orgânico da espécie *Scirpus giganteus*, no Banhado Grande – RS, a partir de dados espectrais e dados de campo.

1.4.1 Objetivos específicos

Para que o objetivo geral seja atingido, os seguintes objetivos específicos deverão ser realizados:

- Delimitar a área de cobertura da espécie a partir de Classificação Baseada em Objetos Geográficos (GEOBIA) e estimar biomassa vegetal e estoques de carbono orgânico para a área delimitada;
- Analisar as relações entre as variáveis biofísicas e os dados espectrais (bandas e índices de vegetação) a partir dos sensores Sentinel-2 e PlanetScope;
- Estimar as variáveis biofísicas a partir de modelos de regressão com imagens dos sensores Sentinel-2A e PlanetScope.

LOCALIZAÇÃO E CARACTERIZAÇÃO DA ÁREA DE ESTUDO

1.4.2 Área de Proteção Ambiental do Banhado Grande (APABG)

A Área de Proteção Ambiental Banhado Grande, criada pelo Decreto nº. 38.971, de 23 de outubro de 1998, é uma Unidade de Conservação do Sistema Nacional de Unidades de Conservação da Natureza (SNUC), Lei nº. 9.985 de 18/07/2000, classificada como de proteção de uso sustentável.

De acordo com o Decreto da criação da APABG, no seu artigo 3º, os objetivos são a proteção dos banhados formadores do rio Gravataí: Banhado dos Pachecos, Banhado Grande e o Banhado do Chico Lomã; compatibilizar o desenvolvimento socioeconômico com a proteção dos ecossistemas existentes; conservar o solo e as riquezas hídricas, com a implementação de estratégias de gerenciamento da bacia hidrográfica do rio Gravataí; recuperar as áreas degradadas com vistas à regeneração dos ecossistemas; contribuir para a otimização da vazão do rio Gravataí; proteger a fauna e a flora nativas, principalmente as espécies da biota raras, endêmicas, ameaçadas ou em perigo de extinção; e proteger os locais de reprodução e desenvolvimento da fauna e da flora nativas.

Com uma área aproximada de 136.935 ha, a APABG localiza-se na região nordeste do estado do Rio Grande do Sul, entre as coordenadas geográficas de 29°45' a 30°12' de latitude Sul e 50°27' a 51°12' de longitude oeste, abrangendo os municípios de Santo Antônio da Patrulha, Glorinha, Gravataí e Viamão (RIO GRANDE DO SUL, 2012). Apresenta como peculiaridade uma extensa área úmida constituída pelo conjunto do banhado Dos Pachecos (cerca de 2.000 ha) e Banhado Grande (cerca de 5.000 ha). Figura 1.

No interior da APABG, foi criada pelo Decreto nº 41.559, de 24/04/2002, uma área de proteção integral com 2.543,46 ha, o Refúgio de Vida Silvestre (RVS) Banhado dos Pachecos, no município de Viamão. Os objetivos principais da sua criação, segundo o artigo 2º, são a proteção dos seus ecossistemas, com exemplares da flora e fauna silvestres das formações remanescentes da Planície Lagunar, principalmente aqueles relacionados aos banhados; a conservação das nascentes formadoras do rio Gravataí; a realização de pesquisas científicas e a Educação Ambiental.

Além do Refúgio de Vida Silvestre Banhado dos Pachecos, há uma unidade

de conservação municipal de proteção integral no interior da APABG, a Reserva Ecológica do Banhado Grande, criada em 1981, com 7.340 ha, no município de Gravataí. Atualmente sua implementação está sob um Termo de Ajustamento de Conduta (TAC) firmado entre a Prefeitura de Gravataí e o Ministério Público.

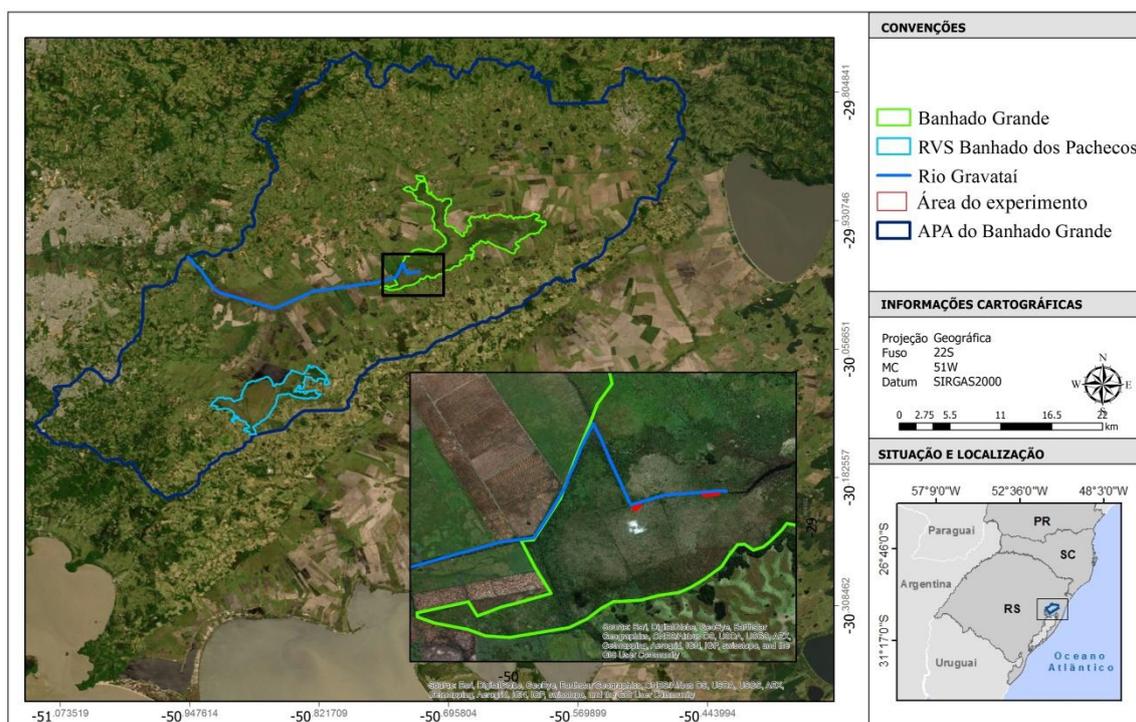


Figura 1. Localização da área de estudo. Fonte: Autora

Grande parte das nascentes do rio Gravataí em conjunto com os banhados e os cursos d'água provenientes da Coxilha das Lombas e da encosta da serra, formam uma extensa planície inundável durante grandes pulsos de inundação, denominada por Meneghetti (1998) de Sistema Banhado Grande (SBG).

A partir de fotografias aéreas da década de 1940, estima-se que este mosaico de áreas úmidas era perene e chegava a ocupar uma área de 450km². Em consequência das drenagens artificiais promovidas pelo Departamento Nacional de Obras de Saneamento e pelos arrozeiros, no ano de 1971, esta área foi reduzida a 138 km². Em 1989 estimava-se que as áreas dos banhados ocupavam cerca de 60 km² (UFRGS, 2002). Atualmente, os banhados restringem-se a dois remanescentes, isolados por extensas lavouras de arroz, e que se conectam apenas durante níveis consideráveis de precipitação (SIMIONI et al., 2017).

Rossato (2011) classificou o clima na região como Subtropical III, isto é, clima úmido, com variação longitudinal das temperaturas médias. Caracteriza-se por chuvas que oscilam entre 1700 a 1800 mm anuais distribuídas de 100 a 120 dias de chuva. A temperatura média anual varia entre 17°C e 20°C. A temperatura média do mês mais frio oscila entre 11°C e 14°C e a temperatura média do mês mais quente varia entre 23°C e 26°C.

A APABG está inserida, quase em sua totalidade, na Região Geomorfológica da Planície Costeira Interna (PROTEGER, 1994). Predominam a litologia de depósitos de planície lagunar e aluvionares e ambientes sedimentares de turfa heterogênea, intercalada ou misturada com areia silte e argila. As turfas são interligadas pelos depósitos de planície de inundação, composto por areia siltico-argilosa, Figura 2 (CPRM, 2016).

Os depósitos turfáceos na área merecem uma maior atenção em função da temática do estudo. Na tentativa de incluir o SBG como Área Úmida de Importância Internacional (AUII). Accordi; Hartz e Ohlweiler (2003) destacam as turfeiras ativas do SBG como arquivos paleo-ambientais insubstituíveis, que agem como sumidouros de carbono à medida que acumulam matéria orgânica. O solo orgânico do Banhado dos Pachecos é formado por turfas de idades holocênicas (2.500 +/- 100 a 4.500 +/- 100 anos B.P.), com espessura em torno de 2 m (VILLWOCK *et al.*, 1980).

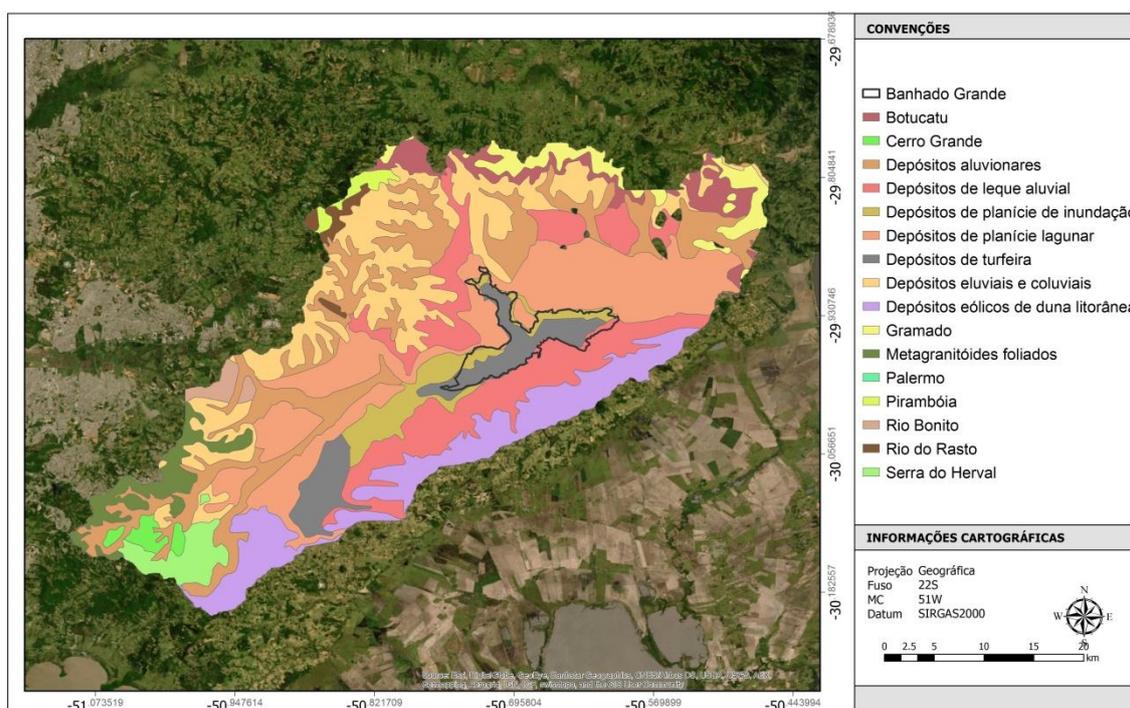


Figura 2. Litologia da área de estudo. Fonte: Autora, adaptado de CPRM, 2016.

As altitudes na APABG variam desde cotas inferiores a 20 m, no centro, até cotas de 350 m, no norte, associadas aos derrames basálticos. O mapa altimétrico (Figura 3) destaca as cotas altimétricas entre 0 e 20 metros na Bacia Hidrográfica do rio Gravataí (BHRG), que incluem a planície de inundação do rio e os banhados. A cota de 11 metros (polígono preto) conecta os banhados a planície de inundação do rio Gravataí e as áreas suscetíveis aos grandes pulsos de inundação em uma extensa área plana (SIMIONI, GUASSELLI, ETCHELAR, 2017). As terras planas do local resultam de processos de acumulação permanente ou periódica durante as inundações (MELLO, 1998).

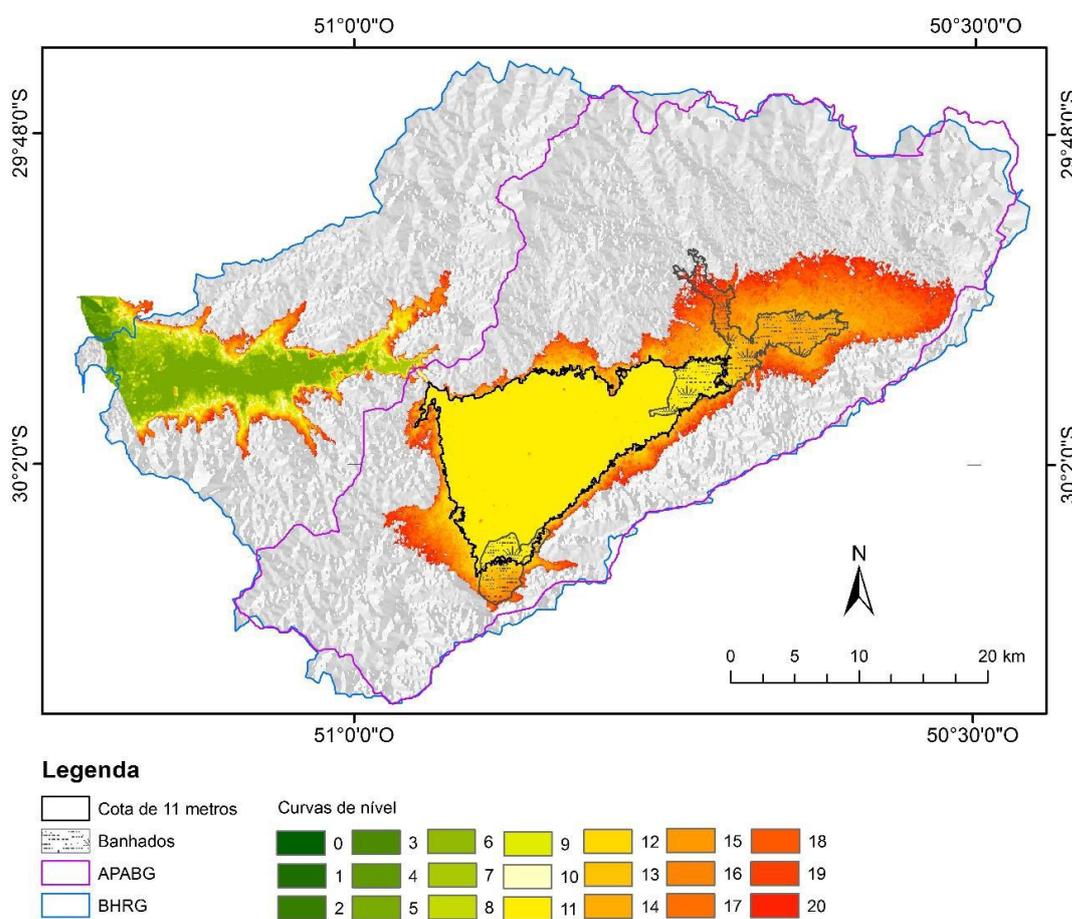


Figura 3. Mapa altimétrico das áreas entre 0 e 20 metros na APABG/BHRG. Fonte: LAGAM/UFRGS. Elaborado por: ETCHELAR, C. B.

A APABG localiza-se, parte no bioma Mata Atlântica (25% da área), especialmente na encosta do Planalto) e parte no bioma Pampa (75% da área). Entre as formações vegetais naturais encontra-se a presença da Floresta Estacional Semidecidual (Rio Grande do Sul, 2012). Oliveira *et al.* (2005) verificaram fragmentos

de mata paludosa no Alto Gravataí, na área norte do Banhado Grande, que se constituem nos últimos e escassos remanescentes da Floresta Estacional Semidecidual submetidos à influência fluvial permanente na APABG.

Teixeira *et al.* (1986) identificaram a área do entorno dos banhados como campos úmidos, alagados em significativa parte do ano, principalmente no período de estação chuvosa. Esta formação campestre, normalmente posicionada nas bordas e adjacências dos banhados, não se constitui em banhados, em função da constituição da cobertura florística de gramíneas homogêneas de pequeno porte e da presença da “estação seca”. Banhado Grande.

Para a compreensão das formações e características da vegetação no Banhado Grande é necessário primeiramente abordar alguns aspectos do meio físico e hidrodinâmico.

A formação do SBG remonta aos principais episódios transgressivos-regressivos ocorridos na área nos últimos milhares de anos (TOMAZELLI; VILLWOCK, 2000). De acordo com Frantz *et al.* (1990) o Sistema Banhado Grande originou-se através do assoreamento contínuo de uma Paleolaguna isolada do mar por uma barreira arenosa de idade pleistocênica denominada Barreira das Lombas. Essa configuração geomorfológica e hidrográfica faz com que as áreas úmidas da APABG se transformem em bacias de acumulação de água, em função das baixas cotas altimétricas registradas nestes ambientes, o que dificulta o escoamento superficial e contribui para a grande quantidade de umidade presente nas áreas de banhado.

A hidrodinâmica do Banhado Grande perfaz um ciclo de inundações sazonais, que apresenta maiores inundações nos períodos típicos de maior precipitação na região da APABG, que ocorre entre o inverno e a primavera (MELLO, 1998) mais precisamente, entre os meses de junho e novembro (Figura 4) (RIO GRANDE DO SUL, 2012; SIMIONI; GUASSELLI; ETCHELAR, 2017). Segundo Junk *et al.* (1989), a principal função de força responsável pela existência, produtividade e interações da biota em sistemas rio-planície de inundação é o pulso de inundação, que constitui uma via de interação lateral.

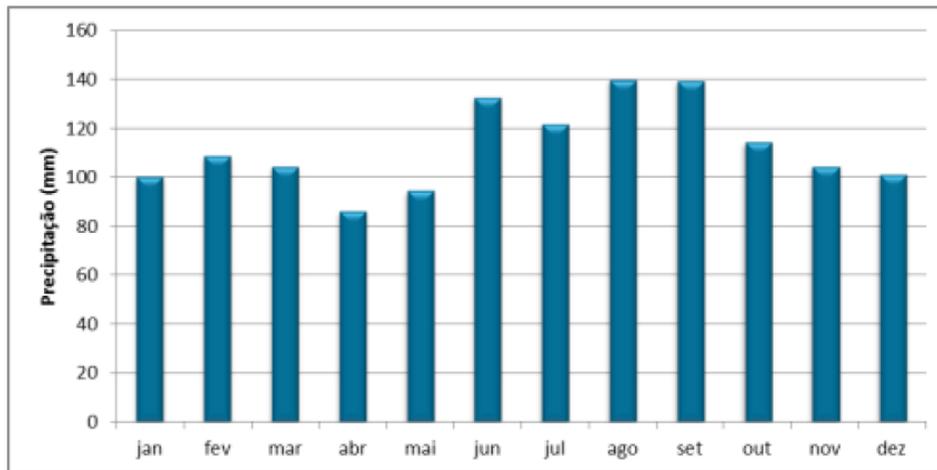


Figura 4. Precipitação média mensal (mm) na APABG. Fonte: Rio Grande do Sul, 2012.

1.4.2.1 Tipologias vegetais

Os estudos de Irgang (1982, apud FRANTZ *et al.*, 1990) e FZB (1983) são os únicos até o momento que descrevem com maior detalhe e caracterizam a vegetação predominante no Banhado Grande. Estes apontam que predomina como cobertura vegetal no Banhado Grande a comunidade de macrófitas aquáticas, subdivididas em duas principais formações vegetais que variam com a região de dominância dentro do banhado. É identificado o “banhado baixo”, composto por espécies de macrófitas flutuantes, fixadas em solos flutuantes de baixo e médio porte, e o “banhado alto”, composto por espécies de macrófitas aquáticas de grande porte fixadas ao solo.

No denominado “Banhado Alto”, a composição vegetal é descrita por espécies de macrófitas aquáticas fixadas ao solo formando um extrato alto e denso com cerca de dois metros, com a maior dominância de *Scirpus sp.* (tiririca), *Eryngium sp.* (caraguatá-do-banhado) e *Typha sp.* (capim camalote), ocorrendo em meio a essa vegetação o *Cephalanthus sp.* (sarandi). Conforme Frantz *et al.* (1990) “está vegetação de elevada densidade torna-se intransponível e o nível da água mesmo no verão é mantido acima da superfície.” Teixeira *et al.* (1986) apontam que ocorrem também *Eryngium pandanifolium* (Gravatá), *Bromélia anthiakantha* (banana do mato), *Scirpus giganteus* (tiririca) e outras.

Cabe destacar o estudo de Frantz *et al.* (1990) como o primeiro relacionando o ambiente sedimentar às formações vegetais. A partir de imagens orbitais os autores fizeram um zoneamento interno a partir do comportamento diversificado da vegetação e identificaram regiões mais propícias para acumulação de matéria

orgânica geradora de depósitos turfáceos. Primeiramente, foram analisados os solos e tipos de depósitos sedimentares na região e, após, relacionados com tipo de cobertura vegetal.

Os autores concluíram que a distribuição espacial e taxonômica da vegetação está ligada à disposição e a variabilidade sedimentar do ambiente, ou seja, determinados depósitos sedimentares vão fazer parte do condicionamento de determinadas espécies de macrófitas aquáticas. Foi possível inferir que as porções medianas e sudoeste do Banhado Grande apresentam maior perspectiva à presença de turfa por apresentar maior grau de umidade e maior densidade da vegetação.

A vegetação escolhida para esta pesquisa pertence a espécie *Scirpus giganteus* (Kunth), de nome popular tiririca ou palha, Família Cyperaceae e Gênero *Scirpus* L, Figura 5. Possui forma biológica anfíbia ou emergente (Figura 6) e como habitat lagoas, rios e banhados. Possui floração e frutificação nas estações de primavera, verão e outono (IRGANG; GASTAL, 1996). É destacada como a espécie de maior abrangência no Banhado Grande Por Leite e Guasselli (2013), e distribui-se sobre a região com perspectiva à presença de turfa.



Figura 5. Individuo de *Scirpus giganteus*. Fonte: Re flora - Herbário Virtual, 2019.

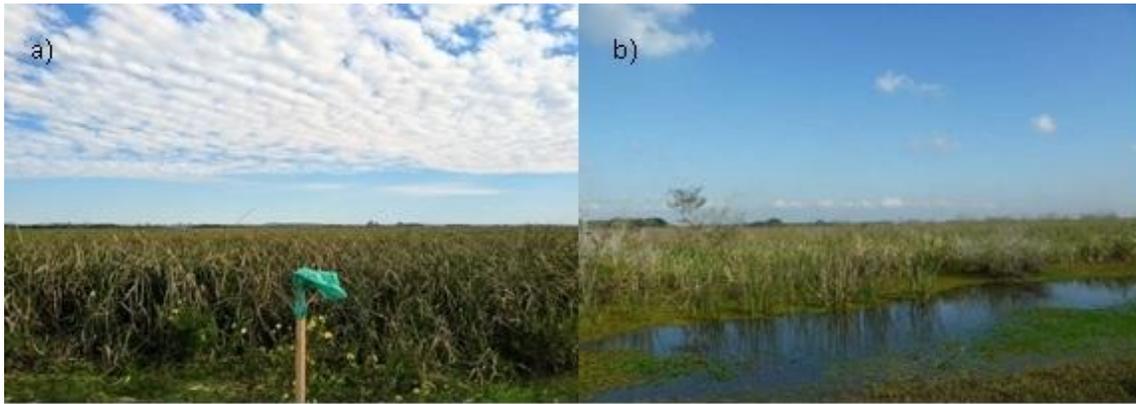


Figura 6. Formas biológicas: a) emergente; b) anfíbia. Fonte: autora, 2018.

Segundo Oliveita et al. (2006) a comunidade de *Scirpus giganteus* (tirirical) constitui comunidades monodominantes, conferindo a este tipo de banhado o caráter denso e quase impenetrável, pelo entrelaçamento e aspereza de suas folhas. Coloniza grandes extensões, em terrenos que permanecem longos períodos alagados ou apenas encharcados.

A *Scirpus giganteus* é uma espécie amplamente distribuída na América do Sul, comumente encontrado em muitos pântanos de água doce. Comunidades dominadas principalmente por *S. giganteus* são estruturalmente simples, mas estáveis e elásticas, a maioria dos casos aparece como estandes monoespecíficos ou de forma difusa (VALLI et al., 1992; KANDUS 1997; PROTOLONGO et al., 2005).

Como muitas macrófitas emergentes comumente encontradas em solos saturados, *S. giganteus* é uma espécie perene rizomatosa, que cresce através das repetidas produções de rametes e as estruturas emergentes desenvolvem nós localizados em rizomas, abaixo da superfície do solo. No caso de *S. giganteus*, os brotos não são visíveis em rametes vegetativos e as folhas são as únicas estruturas observáveis (PROTOLONGO et al., 2005). Não apresenta um período marcado de crescimento e suas folhas atingem mais de um metro de altura (PROTOLONGO; KANDUS, 2005).

A maior representação florística de espécies desta família nas comunidades de banhados herbáceos do Rio Grande do Sul foi registrada anteriormente para os banhados do Parque Estadual Delta do Jacuí, da Estação Ecológica do Taim, os banhados nas nascentes do rio Gravataí e para os banhados da planície de inundação do rio dos Sinos (OLIVEIRA et al., 2006). Esta dominância florística também foi

constatada por Kandus et al. (2003) nas comunidades herbáceas das ilhas bonaerenses do baixo delta do rio Paraná (Argentina).

2 REFERENCIAL TEÓRICO

O referencial teórico foi estruturado em quatro tópicos que abrangem a temática da pesquisa. Inicialmente, abordam-se conceitos relacionados às áreas úmidas e vegetação característica, o segundo item versa sobre biomassa vegetal e produtividade primária, o terceiro item discorre sobre o ciclo do carbono em AUs e sua relação com as mudanças climáticas; o último item explana sobre o sensoriamento remoto no estudo da vegetação em áreas úmidas, abordando também sobre metodologias de mapeamento e estimativa de biomassa e carbono a partir de dados espectrais.

2.1 ÁREAS ÚMIDAS E VEGETAÇÃO MACROFÍTICA

O termo áreas úmidas (AUs) engloba uma variada gama de ecossistemas. A primeira definição do conceito de áreas úmidas surge na Convenção de Ramsar, realizada no ano de 1971, no Irã. Esta convenção estabeleceu uma ampla definição dos tipos de zonas úmidas, incluindo mangues e pântanos, lagos e rios, prados úmidos e turfeiras, oásis, estuários, deltas e planícies de maré, áreas marinhas perto da costa, manguezais e recifes de corais, totalizando 42 diferentes tipos de zonas úmidas, estendendo seus limites até a profundidade de 6 m (RAMSAR, 2013).

Nos últimos vinte anos, o reconhecimento das áreas úmidas está principalmente associado à diversidade biológica que estes ecossistemas abrigam e os serviços ambientais ou funções que lhes são associados (GUIMARÃES, 2014). De acordo com o MMA (2010), alguns analistas deduzem que 50% das Áreas Úmidas de todo o mundo já estejam perdidas e que tais perdas seguem ocorrendo, especialmente nos países em desenvolvimento.

Pesquisas e publicações da Convenção de Ramsar asseguram que o colapso dos serviços prestados por estes ambientes, decorrente de usos não sustentáveis e da supressão das zonas úmidas, pode resultar em desastres ambientais com elevados custos em termos de vidas humanas e em termos econômicos (MMA, 2016). Nesta perspectiva, pesquisas que contribuam com o uso sustentável das áreas úmidas e que busquem quantificar e valorizar suas funções ambientais são fundamentais para sua conservação.

Para Diegues (2010), entre as principais funções hidrológicas das áreas úmidas está a capacidade de armazenar e liberar água, atuando no controle das inundações e na descarga de água nas épocas de estiagem, conhecido como efeito “esponja”. Atuam também na retenção de sedimentos, que não só reduzem a erosão, como também retém nos sedimentos elementos tóxicos, como inseticidas e fungicidas, que de outra forma passariam mais rapidamente para a cadeia trófica.

Ainda, de acordo com Diegues (2010), outra função dessas áreas é a retenção e acúmulo de nutrientes, constituindo-se em áreas altamente produtivas e habitats para inúmeras espécies, desde endêmicas até migratórias. A alta diversidade biológica e produtividade existente nesses ecossistemas são destacadas pela maioria dos autores. Maltchik (2003) considera este ecossistema um dos mais produtivos do mundo, uma vez que produz oito vezes mais matéria orgânica do que os campos de cultivo e tem grande capacidade de fixar a energia solar. Mitch e Gosselink (2015) também consideram estes ambientes os demais alta produtividade biológica no planeta com base na presença de macrófitas aquáticas e suas interações com o meio físico e biótico.

Os conceitos para áreas úmidas são definidos, principalmente, a partir de características de nível de inundação e saturação do solo com água, tipos de vegetação e tipos de solos característicos, não existindo assim um único conceito ecologicamente correto para tal (JUNK, 2012).

No Rio Grande do Sul, o termo banhado é utilizado para denominar áreas úmidas, como terras alagadas e/ou alagáveis, com flora e fauna adaptadas a este sistema. A palavra é de origem espanhola, por isso bastante difundida no Estado. Em outras regiões do país é denominado de brejo ou pântano (IRGANG; GASTAL, 1996). Na bibliografia internacional, o termo banhado corresponde à *marsh* em inglês (RINGUELET, 1962; WILDROLZER, 1986).

Após o Brasil tornar-se um membro signatário da Convenção Ramsar, no ano de 1993 (JUNK; PIEDADE, 2015) foi crescente a necessidade dos pesquisadores em evidenciar a importância destas áreas no Estado, no âmbito ecológico, social e microclimático. Desde então, diversos estudos vêm sendo desenvolvidos, abordando os banhados sob diferentes perspectivas e a partir de distintas definições. Diante disto, Simioni e Guasselli (2017) propuseram uma definição de banhado que engloba os três critérios básicos para definição e delimitação de uma Área Úmida, proposto

por Cowardin *et al.* (1979): i) hidrologia; ii) vegetação; iii) depósitos geológicos e tipos de solos:

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

Dentre as inúmeras importâncias atribuídas a este sistema estão a diversidade biológica, a produtividade, o armazenamento de água, controle de grandes inundações, recarga de aquíferos subterrâneos, purificação da água e estabilidade climática; além de proporcionarem condições favoráveis à produção de peixes e à agricultura (MALTCHIK, 2003).

Conforme Wildholzer (1986), um importante serviço prestado pelos banhados é o fornecimento de alimento e abrigo, tanto para a fauna local, quanto para a migratória. Pela mesma razão, são considerados locais de reprodução e crescimento de várias espécies, propiciando áreas de repouso, nidificação, e hibernação especialmente para aves migratórias.

Chomenko (2007) destacou de forma mais completa todos os bens/materiais e funções dos banhados, incorporando os âmbitos ecológicos, ambientais e sociais. Dentre as funções não citadas anteriormente, a autora coloca ainda:

Fixam carbono nas plantas e no solo; disponibilizam solos ricos em nutrientes; contribuem para a estabilidade / fixação de margens; reduzem os processos de erosão de solos; reduzem os efeitos de períodos de estiagem; habitats de animais de distintos grupos (inclusive migratórios e ameaçados de extinção); mantêm biodiversidade (manutenção de banco genético); fornecem material para produção de artesanatos, fito medicamentos, etc.; propiciam oportunidades de exploração turística de contemplação, lazer, recreação; propiciam atividades educativas, ao ar livre, para as comunidades humanas, etc.; criam oportunidades de empregos para comunidades locais; incrementam a autoestima de populações locais e melhoria da qualidade de vida (CHOMENKO, 2007).

Simioni e Guasselli (2017) destacam que devido sua importância, os ecossistemas de banhados são considerados Áreas de Preservação Permanente (APP)

no Estado, sendo necessária a realização de um adendo na legislação federal para a inclusão do termo no Cadastro Ambiental Rural (RIO GRANDE DO SUL, 2015).

Entre as definições de banhados, a presença da vegetação adaptada ou plantas aquáticas é recorrente. A terminologia utilizada para descrever o conjunto de vegetais adaptados ao ambiente aquático é muito variada. Na literatura especializada podem ser encontrados termos como hidrófitas, helófitas, euhidrófitas, limnófitos, plantas aquáticas, macrófitas, entre outros. O termo macrófitas aquáticas, ou simplesmente macrófita, pode ser considerado de uso mais corrente (POMPÊO; MOSCHINI-CARLOS, 2003).

Quanto a vegetação típica, Oliveira et al. (2006) destaca:

“São denominadas regionalmente de banhados as formações hidrófilas, predominantemente herbáceas, às vezes arbustivas. A vegetação das áreas úmidas apresenta forte relação com o gradiente topográfico e conseqüentemente com o período de permanência de água no solo, variáveis determinantes na composição florística e formas de vida que caracterizam as comunidades destes ambientes” (OLIVEIRA et al., 2006).

Para o Estado, a obra de maior referência para o estudo de macrófitas ainda é de Irgang e Gastal (1996), em que foram catalogadas mais de 300 espécies, levando em conta as áreas úmidas da região costeira. De acordo com os autores, as macrófitas são definidas como os vegetais visíveis a olho nu, cujas partes fotossintetizantes ativas estão permanentemente, ou por diversos meses, todos os anos, total ou parcialmente submersos em água doce ou salobra, ou ainda flutuantes na mesma. Na Figura 7, são apresentadas as formas biológicas das macrófitas aquáticas, segundo Irgang e Gastal (1996).

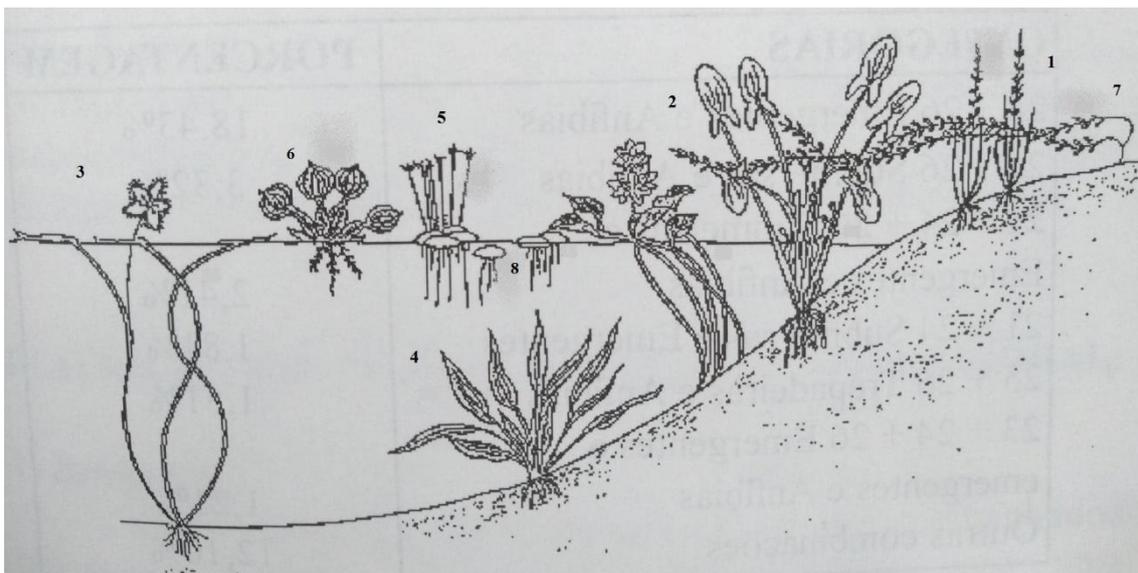


Figura 7. Formas biológicas das macrófitas aquáticas: 1- Anfíbias: plantas capazes de viver tanto em área alagada como fora da água; 2- Emergentes: plantas enraizadas no fundo, parcialmente submersas e parcialmente fora da água; 3- Flutuantes fixas: enraizadas no fundo com caule e/ou folhas flutuantes; 4- Enraizadas submersas; 5- Epífitas: instalam-se sobre outras plantas aquáticas; 6- Flutuantes livres acima da superfície; 7- Trepadeiras; 8- Flutuantes livres na superfície e abaixo. Fonte: Adaptado de Irgang e Gastal (1996).

Irgang e Gastal (1996) destacam a grande presença das espécies anfíbias na planície costeira do estado, totalizando 43,20% frente a 56,80% das espécies puramente aquáticas. Segundo os autores, as espécies anfíbias não são englobadas por nenhum conceito restritivo, sendo difícil localizá-las entre as definições de plantas terrestres ou aquáticas por terem adaptações para os dois ambientes. Porém, estas foram englobadas no estudo pela sua dependência total da água em abundância, pelo menos em alguns períodos do seu ciclo vital.

Para Burger (2000) as macrófitas são os vegetais que melhor caracterizam os banhados. Nestes ambientes, as macrófitas desempenham importantes papéis na hidrologia e ecologia para todo o ecossistema. Elas atuam na oxigenação da água, na ciclagem e retenção de nutrientes e poluentes e no controle da eutrofização artificial (ESTEVES, 1998). Atuam como produtores primários e de biomassa vegetal, servindo como fonte de matéria orgânica autóctone para todo o ecossistema (POMPÊO; MOSCHINI-CARLOS, 2003; ROLON; MALTCHIK, 2006).

Para os organismos aquáticos e terrestres, as macrófitas fornecem alimento, habitat e local de refúgio (ESTEVES, 1998; ROLON; MALTCHIK, 2006). Servem ainda de suporte para desova de várias espécies de moluscos, anfíbios e pássaros e

para o desenvolvimento de algas perifíticas (POMPÊO; MOSCHINI-CARLOS, 2003; POMPÊO, 2008; THOMAZ; ESTEVES, 2011).

O ciclo de vida das macrófitas é relativamente rápido. A estratégia de reprodução inclui, em alguns casos, tanto a reprodução sexuada quanto assexuada, permitindo maior êxito no crescimento e propagação (MENEZES, 1984). Segundo Irgang e Gastal Jr (1996) o pico de florescimento e frutificação das macrófitas na Planície Costeira do Estado ocorre em maior proporção no verão, somente poucas plantas florescem no inverno. Algumas espécies apresentam florescimento e frutificação contínuos, durante todo o ano.

Diante da importância dos banhados, a partir de suas funções e benefícios para a biodiversidade e sociedade, é de extrema importância o conhecimento sobre os fatores que afetam ou contribuem com o desequilíbrio destes ambientes, visando o monitoramento de sua saúde e conservação como um todo dos banhados remanescentes. Apesar do número ainda incipiente de pesquisas em banhados, dentro deste contexto, são encontrados estudos com resultados semelhantes.

Maltchik *et al.* (2004) apontam uma série de fatores abióticos que podem afetar a composição florística e a estrutura da comunidade macrofítica, como o teor de nutrientes na água e no sedimento, luminosidade e flutuação dos níveis de água. A variação no crescimento destas depende das condições climáticas, concentrações de nutriente, espaço livre entre as plantas e condições de mistura e turbulência (MENEZES, 1984). O regime hidrológico é um dos fatores mais importantes, pois provoca alterações diretamente na biomassa, composição, produtividade e riqueza (NEIFF, 1997; MALTCHIK *et al.*, 2004).

Cabe também destacar a influência das variáveis temporais. A superfície ocupada por determinada comunidade vegetal pode sofrer expansão, retração e mesmo substituição, dependendo do maior ou menor alagamento do solo, em decorrência da dinâmica hídrica da região. Assim, em certo período do ano, uma área ocupada por um campo úmido pode, em outra época, dar lugar a uma comunidade de espécies flutuantes livres (OLIVEIRA *et al.*, 2006).

2.2 BIOMASSA E PRODUTIVIDADE PRIMÁRIA

Os termos biomassa e produtividade são mencionados com frequência em estudos de áreas úmidas relacionados diretamente a cobertura vegetal e a produção de matéria orgânica. Conforme Pompêo e Moschine-Carlos (2003) a biomassa das macrófitas é o peso do material vegetal vivo e morto, coletado por um amostrador de área conhecida. Posteriormente o material é seco e pesado e o resultado final é expresso por unidade de área. No caso das macrófitas emersas e submersas, considera-se a biomassa acima e abaixo da lâmina d'água, inclusive do material presente no interior do sedimento.

A produtividade primária refere-se ao processo da criação de matéria orgânica por plantas fotossintetizantes que incorporam energia do sol e minerais, assim como CO₂ e água (LIETH, 1975). De acordo com Ferreira (2005) este termo é utilizado geralmente para expressar o quão produtivo pode ser um ecossistema ou ambiente, isto é, se sua produtividade por unidade de área e por unidade de tempo é alta ou baixa.

Ainda, de acordo com Pompêo e Moschine-Carlos (2003) é comum representar a biomassa das macrófitas em teor de matéria orgânica. Esta pode ser obtida através da incineração de uma fração da biomassa (teor de matéria orgânica por peso seco livre de cinzas). Durante o processo, toda a matéria orgânica é volatilizada, restando em cinzas os elementos minerais presentes no tecido vegetal. Pela diferença de pesos, é determinada a quantidade de matéria orgânica e de cinzas.

Quando se deseja inferir sobre o papel das macrófitas e sua influência sobre os fluxos energéticos relacionados à cadeia de detritos e produção primária em ecossistemas aquáticos, a avaliação da biomassa vegetal destas plantas é o primeiro procedimento a ser realizado. Através da determinação das variações de biomassa, pode-se determinar o período de crescimento destes vegetais, avaliar os estoques de nutrientes da planta e do sistema e estimar a produção primária (JUNK; PIEDADE, 1993, POMPÊO; MOSCHINE-CARLOS, 2003).

Segundo Piedade, Junk e Long (1991), as macrófitas podem representar as principais produtoras de matéria orgânica dos ambientes lênticos, atingindo cerca de 100 ton de peso seco/ha/ano, podendo constituir até a metade do aporte de carbono orgânico que se acumulam no sedimento em ambientes lacustres e ainda contribuem para a ciclagem de nutrientes (BIANCHINI, 1999).

Através da avaliação da biomassa ao longo do tempo, é possível identificar os fatores ambientais preponderantes que determinam alterações e possíveis desequilíbrios nos sistemas aquáticos. Kufner et al. (2011) analisaram a influência do pulso de inundação sobre a biomassa de espécies de macrófitas em uma lagoa no Pantanal mato-grossense. A partir da quantificação da biomassa seca, concluíram que os maiores valores de biomassa, foram obtidos nos períodos de cheia. Verificaram também que, com a diminuição no nível da água e aparecimento de bancos de areia, houve recuo e redução gradual das populações de duas espécies analisadas.

Utilizando o mesmo método de avaliação, Mauhs et al. (2006) verificaram as possíveis relações entre a biomassa de macrófitas em um banhado no município de Palmares do Sul – RS, com variáveis ambientais de profundidade, temperatura e fotoperíodo, a partir de métodos estatísticos.

Como resultado, os valores máximos de biomassa ocorreram no período de verão e os valores mínimos no período de inverno. Embora não tenha sido encontrada boa correlação entre as variáveis ambientais e biomassa, a diminuição dos valores de biomassa coletada a partir do terceiro mês foi atribuída a um período de grande estiagem, devido ao ressecamento dos campos adjacentes ao banhado, o que colaborou com o aumento da pressão por herbivoria extensiva na vegetação de borda e interior do banhado, modificando a cobertura vegetal, especialmente das espécies de maior dominância.

Neste contexto, o método de avaliação da biomassa utilizada nos estudos citados permitiu verificar a influência dos fatores ambientais e, ainda, de uma atividade econômica, respectivamente, sobre a redução de espécies e alteração da comunidade vegetal, evidenciando a relevância da avaliação da biomassa para monitorar a sanidade e estado de conservação destes ambientes.

2.3 CICLO DO CARBONO EM AUs

As áreas úmidas contêm cinco reservatórios de carbono principais: carbono na biomassa vegetal, carbono orgânico particulado, carbono orgânico dissolvido, carbono de biomassa microbiana e produtos finais gasosos, como dióxido de carbono e metano. Os últimos quatro são presentes na água, nos detritos e no solo, e também carbono refratário (isto é, carbono resistente, que mantém sua força em altas temperaturas). Estes reservatórios de carbono podem ser usados na descrição de ciclos de carbono (KAYRANLI et al., 2009).

O monitoramento da biomassa vegetal nas AUs é de grande importância para preservar os estoques de carbono nestes sistemas. A biomassa nas áreas úmidas atua substancialmente na fixação de carbono inorgânico (CO_2 atmosférico) através do processo de fotossíntese, em que a planta utiliza a radiação solar como energia para converter gás carbônico e água em carbono orgânico (carboidrato) e oxigênio (TABILO-VALDIVIESO, 1999; MOREIRA, 2012).

A quantidade de carbono a ser fixada pela vegetação depende da radiação fotossinteticamente ativa, da composição florística e da estrutura do dossel que compõe a vegetação. Este processo é influenciado diretamente pela fotossíntese e importante em relação à produtividade dos ecossistemas terrestres (ARAGÃO; SHIMABUKURO, 2004).

O que diferencia o potencial das AUs quanto a retenção de carbono da atmosfera de outros sistemas terrestres é o acúmulo deste nas formações turfosas. Segundo Iturraspe (2010) na maioria dos ecossistemas o ciclo do carbono é completo e se equivalem a produtividade da biomassa e sua decomposição, salvo certas florestas tropicais que produzem turfas. Nas AUs com turfeiras ativas, o ciclo do carbono é incompleto pela baixa decomposição no meio saturado anaeróbico, resultando na acumulação de matéria orgânica a cada ciclo anual e em um balanço positivo de carbono.

Assim, o ciclo do carbono nas AUs inicia com a fixação de CO_2 pelas plantas que sintetizam matéria orgânica; as fibras mortas da biomassa vegetal são cobertas a cada ano por novas plantas que, em um lento processo, se transformam em turfas (ITURRASPE, 2010). Parte do carbono assimilado retorna à atmosfera como metano (CH_4), um gás de efeito estufa produzido por bactérias no ambiente anaeróbico (WHITING; CHANTON, 2001; ITURRASPE, 2010). As condições anaeróbicas das

turfas também lhes conferem o potencial de emitir quantidades consideráveis de óxido nitroso (N₂O) (MMA, 2007; ITURRASPE, 2010; MITCH; GOSSELINK, 2015).

Conforme exposto, as turfeiras em seu estado natural incidem no balanço de três tipos de Gases de Efeito Estufa (GEE). Em vista disso e diante do aumento das concentrações destes gases na atmosfera e o seu efeito potencial sobre o clima e os ecossistemas terrestres, pesquisas têm sido realizadas visando estimar a contribuição das AUs na emissão de GEE e na absorção do CO₂ atmosférico.

Para Joosten (2008) o efeito negativo em longo prazo das emissões de metano é menor que o efeito positivo do sequestro de CO₂. Brix et al. (2001) examinaram se um banhado com *Phragmites* (Caniço) na Europa poderia ser considerado fonte ou coletor de GEE. Aferiram que quando avaliados em um período de tempo menor (<60 anos), essas áreas úmidas poderiam ser consideradas uma fonte de GEE com base na emissão de CH₄ e CO₂ em relação à fixação de carbono. No entanto, o CH₄ não persiste na atmosfera por longos períodos. Ao avaliarem por um período mais longo (> 100 anos), verificaram que estes atuam como sumidouro para os GEE.

Mitsch *et al.* (2013) encontraram resultados semelhantes comparando 21 áreas úmidas de todo o mundo, muitas delas de água doce. O mesmo foi comprovado por Whiting e Chanton (2001) a partir de medidas sazonais em três diferentes AUs na Flórida, Virgínia e Canadá.

Essas pesquisas têm quantificado e atestado a contribuição das AUs na fixação de carbono atmosférico, porém, a maioria delas detém-se no estudo das turfas. Sabe-se que as formações vegetais desempenham um importante papel no ciclo global do carbono, mas ainda são poucos os estudos que investigam a capacidade de armazenamento de carbono nas plantas nativas de AUs.

Entre os poucos estudos com esta temática no Brasil, Esteves (2006) avaliou a contribuição da macrófita *Typha domingensis* para o estoque de biomassa e nutrientes como carbono, nitrogênio e fósforo na região litorânea da lagoa do Campelo, RJ, a partir da análise de biomassa seca (“método do quadro”) e da determinação dos nutrientes em um analisador elementar Perkin Elmer 2400. Encontrou nas folhas adultas o maior valor nutricional e elevados conteúdos de carbono (340 a 460 mg.g⁻¹PS), e que a biomassa expressiva desta estrutura indica que esta é a principal estocadora e fonte de nutrientes na porção litorânea da lagoa do Campelo, RJ.

Mohedano (2010) avaliou o potencial de macrófitas *lemnáceas* no tratamento e valorização dos efluentes líquidos e gasosos da suinocultura, visando a redução da emissão de GEE, a partir de um experimento em escala laboratorial. As lemnas foram cultivadas em câmaras de crescimento em meio de cultura, injetadas diferentes quantidades de CO₂ e monitoramento a redução de CO₂ nas câmaras. Constatou uma taxa de fixação de carbono de 7,15g/m²/dia, cerca de 25t/ha/ano. Quanto a produtividade de biomassa da espécie, o resultado foi de 180g/m²/dia de matéria fresca, ou 68t/ha/ano. Concluiu a potencialidade do uso de lemnas como uma tecnologia eficiente na remoção de GEE, principalmente em uma atmosfera com elevadas concentrações de gás carbônico.

Diante do cenário de mudanças climáticas apontadas nos relatórios publicados da quarta avaliação do Painel Intergovernamental sobre Mudanças do Clima (IPCC, 2007) e cientes do potencial das AUs quanto ao armazenamento de carbono e da degradação que estes ecossistemas vêm sofrendo ao longo dos anos, a Convenção sobre Diversidade Biológica (*Convention on Biological Diversity*) voltou sua atenção para os impactos potenciais sobre estas e para sua contribuição na mitigação das mudanças do clima, visando sua conservação.

O relatório intitulado *Inter-relações entre Biodiversidade e Mudanças Climáticas* (MMA, 2007), incluiu a restauração de AUs como estratégia de mitigação do aquecimento global com relação as suas reservas de carbono e sua capacidade de sequestro e armazenamento. Também foi mencionado que a degradação das AUs por atividades humanas contribui para a liberação de grandes quantidades de GEE, sendo assim necessários esforços conjuntos para sua conservação.

De acordo com Crooks et al. (2011) a pesquisa científica sobre o fluxo de GEE entre a atmosfera e esses ecossistemas está em andamento há algum tempo, mas foram dois Relatórios publicados em 2009 - *The Management of Natural Coastal Carbon Sinks*¹ e *Blue Carbon*² – que trouxeram este aspecto à atenção das mudanças climáticas e ao surgimento do termo *Blue Carbon* (carbono azul). Ao mesmo tempo, a publicação do *World Development Report 2010: Development and Climate*

¹ Laffoley, D.; Grimsditch, G. (Eds.) 2009. *The Management of Natural Coastal Carbon Sinks*. IUCN, Gland, Switzerland, 53pp.

² Nellemann, C.; Corcoran, E.; Duarte, C. M.; Valdes, L.; De Young, C.; Fonseca, L.; Grimsditch, G. (Eds.) 2009. *Blue Carbon. A Rapid Response Assessment*. United Nations Environment Programme, GRIDArendal.

*Change*³ e *Convenient Solutions to an Inconvenient Truth*⁴, ressaltaram a importância de aproveitar os sistemas naturais, incluindo as áreas úmidas e os serviços de armazenamento de carbono que fornecem, na luta para reduzir as emissões de carbono.

O termo carbono azul emerge referindo-se aos benefícios da mitigação das mudanças climáticas através do gerenciamento aprimorado, que inclui a conservação e restauração de processos biogeoquímicos realizados por áreas úmidas costeiras, incluindo pântanos de água doce (*marshes*) e salobra (*tidal marshes*), manguezais, plantas marinhas e recifes de corais. O valor recentemente reconhecido deste serviço ecossistêmico para a mitigação climática pode proporcionar um novo incentivo para priorizar a restauração e conservação desses ecossistemas costeiros (EMMETT-MATTOX; CROOKS, 2017).

A partir destes relatórios surgiram mais pesquisas interessadas em estimar o carbono armazenado na vegetação para justificar projetos de restauração e criação de AUs (MEANS *et al.*, 2016), para redução da degradação e conservação como ferramenta de mitigação de impactos das mudanças climáticas (SIKAMAKI; SANCHIRICO; JARDINE, 2012) e para projetos de compensação de emissões e crédito de carbono, semelhantes aos programas de Redução das Emissões por Desmatamento e Degradação (REDD) (MCLEOD, 2011; ALONG, 2012; SUTTON-GRIER; MOORE, 2016).

Todos esses fatores enfatizam a importância de manter estes ecossistemas saudáveis e preservados. No entanto, a determinação direta de propriedades biofísicas das macrófitas como biomassa e carbono, seu mapeamento e monitoramento tradicional em campo, são difíceis, principalmente em grandes extensões espaciais, e apresentam desafios como a inacessibilidade de algumas áreas para amostragem de campo; mudanças rápidas na localização, extensão e densidade das plantas, custos elevados, mão de obra e tempo de viagem (VIS; CARIGNAN, 2003; SILVA *et al.*, 2008).

Dadas essas limitações, o monitoramento e estimativa de dados biofísicos em AUs através da detecção remota por satélite é uma alternativa viável e tem sido

³ The World Bank, 2010a. World Development Report 2010: Development and Climate Change. The International Bank for Reconstruction and Development: Washington, D.C.

⁴ The World Bank 2010b. Convenient Solutions to an Inconvenient Truth: Ecosystem-Based Approaches to Climate Change. The International Bank for Reconstruction and Development: Washington, D.C.

utilizada tanto como método único (LEITE; BAPTISTA, 2015; FERREIRA, 2015; SIMIONI; WOLLMANN, 2016), quanto em conjunto com dados coletados *in situ* (BARBOSA, 2006; MUTANGA *et al.*, 2012; SCHILE *et al.*, 2013; BYRD *et al.*, 2014; GAO *et al.*, 2017).

2.4 SENSORIAMENTO REMOTO NO ESTUDO DA VEGETAÇÃO EM AUs

O uso adequado de sensores remotos passivos requer uma compreensão dos processos físicos envolvidos na interação entre a Radiação Eletromagnética (REM) e a vegetação. Quanto ao sensoriamento remoto de plantas aquáticas, este tem algumas dificuldades particulares que devem ser adequadamente endereçadas para obter resultados bem-sucedidos (SILVA et al., 2008).

As características espectrais dos vegetais em geral, incluindo as de macrófitas, estão na sua maioria relacionadas à absorção da REM pelos pigmentos da planta na região visível do espectro (0,4 a 0,72 μm), à reflectância da REM na região do infravermelho próximo (0,72 a 1,1 μm) em função da estrutura celular, e à absorção pela água na região do infravermelho médio (1,1 a 3,2 μm), Figura 8 (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Os pigmentos existentes nas folhas são, aproximadamente, clorofila (66%), carotenos (6%) e xantofilas (29%), sendo que estes valores variam intensamente de acordo com as espécies. Estes pigmentos absorvem radiação na região do azul (próximo a 0,445 μm), mas somente a clorofila absorve na região do vermelho (0,645 μm) sendo que a absorção da REM aumenta proporcionalmente com o aumento do conteúdo de clorofila (PONZONI; SHIMABUKURO; KUPLICH, 2012; MOREIRA, 2012).

Na região do infravermelho próximo (NIR) a absorção da radiação é muito baixa e ocorre um considerável espalhamento interno da radiação, sendo que a reflectância pode chegar a 50% dependendo da estrutura anatômica das folhas (PONZONI; SHIMABUKURO; KUPLICH, 2012; MOREIRA, 2012).

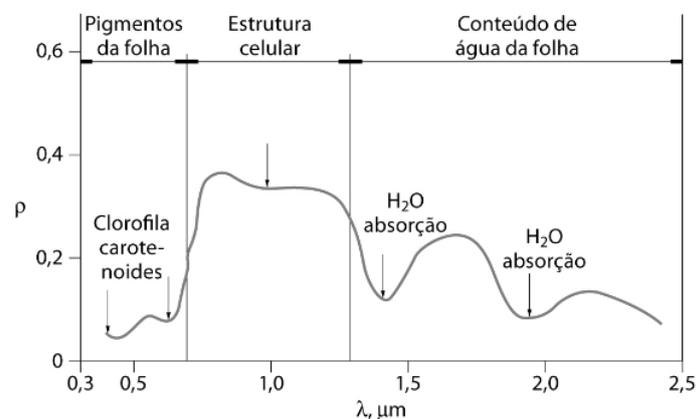


Figura 8. Curva de fator de reflectância típica de uma folha verde. Fonte: Ponzoni; Shimabukuro; Kuplich, 2012.

A região de “borda vermelha” do espectro (*Red edge*) é a região de mudança abrupta na refletância da folha entre, 680 e 780 nm, devido aos efeitos combinados da forte absorção de clorofila nos comprimentos de onda vermelhos e alta refletância nos comprimentos de onda Infravermelho próximo devido ao espalhamento interno da folha (HORLER et al., 1983). O valor de refletância nesta região do espectro está relacionado a parâmetros bioquímicos da vegetação (por exemplo, conteúdo de clorofila), parâmetros biofísicos (por exemplo, índice de área foliar) e déficit hídrico na biomassa da vegetação (FILELLA e PENUELAS, 1994; CLEVERS et al. 2002; MUTANGA; ADAM; CHO, 2012).

A banda de borda vermelha, embora não esteja disponível em todos os sensores, fornece informações adicionais para os estudos que investigam a vegetação e a qualidade de corpos d'água interiores com conteúdo relativamente alto de fitoplâncton (WEICHELT et al. 2011; WEN et al. 2014).

No estado de senescência, a resposta espectral das plantas se difere bastante da resposta de uma folha sadia, Figura 9. Na faixa do infravermelho próximo, região do espectro eletromagnético que responde pela característica do estado vegetativo da planta, há uma grande diminuição na resposta refletida e captada pelos sensores. O inverso, ou seja, menor absorção e maior quantidade de energia refletida ocorrem nos comprimentos de onda do visível devido à perda dos pigmentos clorofilados, e nas bandas do infravermelho médio devido à perda do conteúdo de água (MOREIRA, 2012).

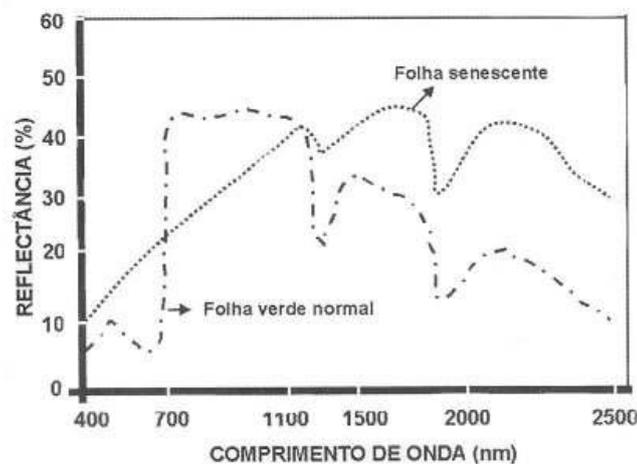


Figura 9. Curva de reflectância de folhas verdes e de folhas senescentes. Fonte: Moreira, 2012.

Embora a resposta espectral do dossel da vegetação aquática possa ser semelhante ao terrestre, a presença de água (condições submersas ou inundadas) acrescenta fatores que podem influenciar significativamente a resposta espectral da vegetação. De acordo com Silva et al. (2008) no caso da vegetação emergente, a presença de pulsos de inundação introduz variabilidade nos valores de reflectância devido à mistura de sinais das plantas e da água. Esta mistura geralmente resulta em uma diminuição da radiação total refletida, especialmente nas regiões do infravermelho próximo a médio, onde a absorção de água é mais forte, Figura 10.

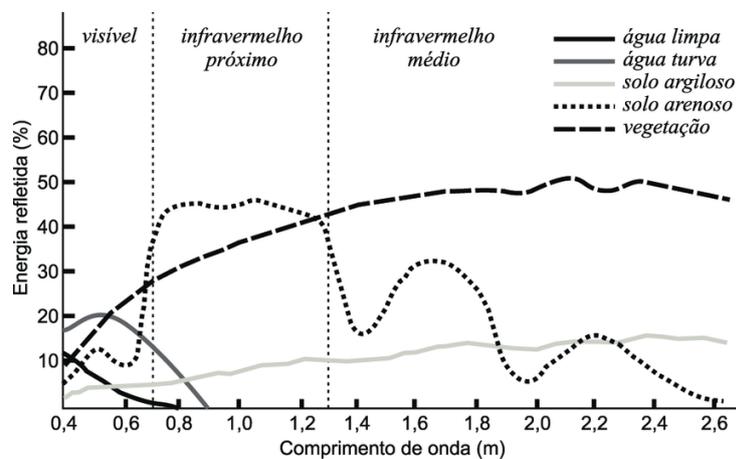


Figura 10. Curvas espectrais de reflectância da vegetação, do solo e da água. Fonte: Florenzano, 2002.

Jakubauskas *et al.* (2000), analisaram as variações na reflectância espectral na faixa do visível e infravermelho próximo para a espécie *Nuphar polysepalum* (macrófita flutuante), em função de sua cobertura vegetal, com auxílio de um espectrorradiômetro, Figura 11. Verificaram que a intensidade do efeito de mistura entre o sinal da água e da vegetação é determinada pela densidade da vegetação e pela estrutura do dossel, bem como pela natureza do sinal da água em função da quantidade, natureza dos materiais em suspensão e da profundidade da coluna de água, além da composição do substrato para profundidades rasas.

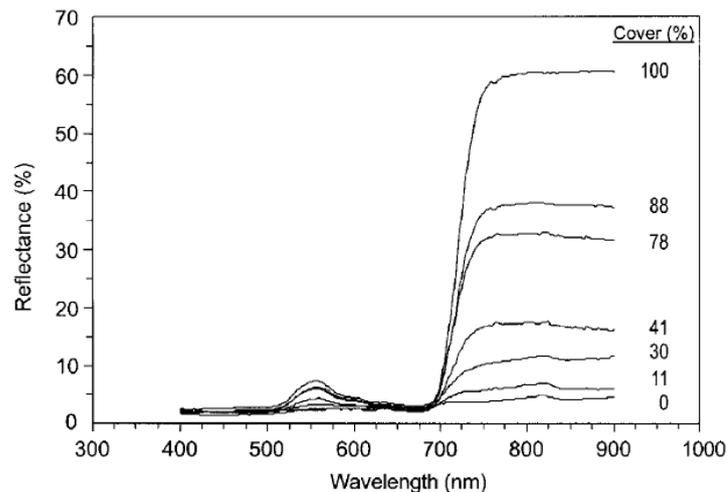


Figura 11. Curvas de reflectância espectral de Spatterdock na faixa de 400 a 900nm para cobertura do dossel variando de 0 a 100%. Fonte: Jakubauskas et al. (2000).

Segundo Díaz e Blackburn (2003) a presença de solos saturados também influencia nas propriedades de reflectância da vegetação de AUs. Os autores investigaram a influência da variação e intensidade de espalhamento nas propriedades de reflectância resultantes de mistura de solos com diferentes graus de umidade em ecossistemas de mangue, utilizando diferentes índices de vegetação. Avaliaram também a influência que essa mistura teve na resposta espectral da vegetação de mangue e o relacionamento entre o “range” dos índices de vegetação e o índice de área foliar dessa cobertura vegetal. Concluíram que o grau de umidade e a mistura dos solos diminuem a intensidade da resposta espectral e dos valores de NDVI.

De acordo com Guo et al. (2017) dentre todos os sistemas sensores disponíveis, os sistemas ópticos são os mais utilizados até o momento para estudos de vegetação em AUs, principalmente os de média resolução espacial (intervalo de 4 a 30 m), destacando-se os sensores Landsat TM (*Thematic Mapper*) e ETM+ (*Enhanced Thematic Mapper Plus*). Outros sensores como o Landsat 8 OLI (*Operational Land Imager*) e o Sentinel-2 ainda não foram utilizados em muitos estudos, respectivamente devido ao lançamento recente do primeiro e a recente disponibilidade gratuita dos dados do segundo.

Kandus et al. (2018) analisaram os tipos de sensores utilizados em publicações sobre sensoriamento remoto e áreas úmidas. Entre os sensores

ópticos, mais de 70% das publicações revisadas utilizaram os sensores Landsat TM, ETM e OLI. Entre os sensores que operam na faixa das microondas, mais de 34% utilizaram análise multisensor, 20% sensor JERS e 12% Envisat/ASAR.

No ano de 2014 e 2015 são lançados os satélites Sentinel 1 (Radar) e Sentinel-2A (Óptico), respectivamente, pela Agência Espacial Europeia (ESA), para dar continuidade as imagens multiespectrais fornecidas pela série de satélites SPOT e pelo instrumento USGS LANDSAT Thematic Mapper.

Com novas capacidades espectrais, o Sensor Óptico Sentinel-2 possui 4 bandas localizadas na faixa de borda vermelha e duas bandas na faixa infravermelha de ondas curtas (SWIR), com 20m de resolução espacial, além das bandas do visível e NIR com 10m de resolução espacial. Após disponibilizarem suas imagens de forma gratuita, suas imagens passam a ser exploradas com maior frequência para estudos em áreas úmidas.

Entre eles, estudos de delimitação e monitoramento apenas com sensor óptico (KAPLAN; AVDAM, 2017; SIMIONI et al., 2018a) e em análise multisensor óptico e radar (CHATZIATONIOU et al., 2017; PEREIRA; MONTES, 2017; SIMIONI et al., 2018b), para mapeamento e monitoramento de vegetação (YESOU et al., 2016), em análise espectral (AMANI et al., 2017), e apenas Sentinel 1 radar para avaliação do fluxo de carbono e umidade do solo (ZIELINSKA et al., 2016) e extração automática da superfície de água (HUANG et al., 2018). Em menor quantidade também se encontram pesquisas para estimativa de biomassa de vegetação emergente (KAPLAN; AVDAN; AVDAN. U, 2017) e de mangue (NAVARRO et al., 2019).

Conjuntamente com o sensor Sentinel, imagens do Sensor PlanetScope, lançado em 2014, começam a ser exploradas em AUs. Embora o sensor PlanetScope tenha menor número de bandas que o Sentinel-2 (azul, verde, vermelho e NIR), possui a resolução espacial mais alta, de 3m, além de revisita diária.

Estes dois sensores foram utilizados em conjunto para mapear áreas de turfa (CROWSON et al., 2018) e para estimativa de biomassa de mangue (BALOLOY et al., 2018). Entre outros trabalhos em AUs com este sensor, também foram explorados classificação de uso e cobertura (TUSCU et al., 2019) e índices espectrais para mapear e monitorar área de mangue (HOA, 2017).

Mahdavi et al. (2017) destacam que os sensores multiespectrais são especialmente úteis na análise das características espectrais das AUs, uma vez que adquirem informações em várias bandas espectrais e que o uso frequente destes sensores se deve a maior facilidade de pré-processamento dos dados, pois muitos já foram corrigidos geometricamente e radiometricamente, e à gratuidade da aquisição.

Destacam-se no estudo da vegetação de AUs os Índices de Vegetação (IVs). Diversos índices têm sido propostos na literatura com o objetivo de explorar as propriedades espectrais da vegetação, especialmente nas regiões espectrais do visível e infravermelho próximo, pelo seu comportamento antagônico, através da combinação de bandas espectrais (PONZONI; SHIMABUKURO; KUPLICH, 2012).

Esses índices são utilizados como indicadores de crescimento e vigor da vegetação e podem ser empregados para diagnosticar vários parâmetros biofísicos, como: índice de área foliar, biomassa, porcentagem de cobertura do solo, atividade fotossintética e produtividade, além de minimizarem os efeitos de iluminação da cena, declividade da superfície e geometria de aquisição (PONZONI; DISPERATI, 2001).

Entre as principais aplicações em AUs, os IVs têm sido utilizados para estimar e comparar dados de campo de variáveis biofísicas, como biomassa e carbono orgânico (MUTANGA et al., 2012; BYRD et al., 2014; LEITE; BAPTISTA, 2015), e estudos de anomalias e monitoramentos dos padrões e dinâmicas das macrófitas. Em corpos hídricos como reservatórios e rios, são utilizados principalmente para o monitoramento de infestações, dispersão e comportamento das macrófitas (GALO, 2002; VIRGÍLIO, 2013; MIRANDA, 2015).

Nas AUs do Rio Grande do Sul, têm sido utilizados para avaliar padrões espaço-temporais e dinâmicas das macrófitas, principalmente relacionados ao regime pluviométrico e pulsos de inundação (GIOVANNINI, 2004; GUASSELLI, 2005; LEITE, 2011; SIMIONI; WOLLMANN, 2016).

2.4.1 Delimitação e classificação de AUs

Diante da importância das funções biológicas e benefícios naturais das áreas úmidas, o monitoramento de sua sanidade através de parâmetros biofísicos e ecológicos, bem como de possíveis perdas de área e degradação, é crucial para a conservação desses ecossistemas. O primeiro passo para o monitoramento é o mapeamento. Dada a inacessibilidade a maioria das AUs e as grandes extensões de

cobertura, são necessárias observações de satélite para mapear e classificar os tipos de vegetação e fornecer melhores estimativas da produção de biomassa desses habitats (COSTA, 2002; GOETZ e DUBAYAH, 2011).

Quanto ao mapeamento das variáveis biofísicas de biomassa e carbono, Grenier et al. (2008) apontam que o mapeamento de áreas úmidas usando sensoriamento remoto enfatiza os diferentes tipos de AUs e permite a ampliação de medições de fixação e de fluxos de carbono feitas diretamente. Costa (2002) relata que a extensão aérea desses ecossistemas e sua produtividade são essenciais para uma compreensão inicial de sua biogeoquímica.

Mcleod (2011) menciona que para quantificar o potencial de fixação de C dos sistemas costeiros com vegetação, é preciso medir e mapear sua variabilidade espacial e regional, se possível também das taxas de fixação de C entre os sumidouros de carbono azul, relacionando essas diferenças com as características ecológicas e ambientais. Esses mapas podem ser usados para orientar os esforços de planejamento e restauração da conservação.

A produção de mapas e inventários de áreas úmidas, no entanto, exige o desenvolvimento de esquemas de classificação para descrever classes de áreas úmidas a serem mapeadas (MAHDAVI et al., 2017). As classificações de zonas úmidas são tipicamente baseadas em diferenças estruturais e funcionais entre diferentes comunidades vegetais e regimes hidrológicos (FRANKLIN et al., 2017). Nesse sentido, a classificação das comunidades de plantas que caracterizam um ecossistema é uma importante ferramenta de planejamento estratégico para a conservação das AUs (SIEBEN et al., 2016).

Devido a sua alta heterogeneidade espacial e variabilidade hidrológica temporal, as áreas úmidas estão entre os ecossistemas mais difíceis de classificar com imagens de sensoriamento remoto (BERHANE, 2018, MAHDAVI et al., 2017). Consequentemente, para implementar esquemas de classificação, foram gerados numerosos métodos de classificação (MAHDAVI et al., 2017).

Uma das técnicas mais comuns para classificação do uso e cobertura da terra a partir de imagens de sensoriamento remoto é a Análise de Imagem Baseada em Pixel (PBIA) (MOFFET; GORELICK, 2013). Esta abordagem automatizada associa cada pixel da imagem a uma determinada classe, com base na sua assinatura espectral. A abordagem PBIA apresenta algumas restrições no mapeamento de AUs,

como por exemplo, a heterogeneidade nos valores de pixels próximos, a existência de pixels mistura, e a variação da umidade do solo e da vegetação que podem gerar diferenças espectrais em uma mesma classe ou até mesmo gerar ruídos *speckle* “sal e pimenta” (DRONOVA, 2015).

A Análise de imagens Baseada em Objetos Geográficos (GEOBIA) apresenta uma estrutura para lidar com estas restrições em áreas úmidas heterogêneas. O GEOBIA consiste em realizar uma segmentação baseada em objetos, que são grupos de pixels, conforme a cor, textura, forma, tamanho e localização (DRONOVA, 2015). O GEOBIA possibilita a amostragem de imagens multisensores e com multiresoluções, resultando em um conjunto de dados de alta dimensionalidade (DRONOVA, 2015; FRANKLIN et al., 2018).

Muitos estudos verificaram maior potencial da GEOBIA para classificação de AU's, em relação a PBIA (DRONOVA, 2015). Kamal e Phinn (2011) compararam o GEOBIA e o PBIA para mapeamento de espécies de mangue, identificando que a abordagem baseada em objetos apresentou uma acurácia global de 76%, enquanto que a abordagem baseada em pixels apresentou uma acurácia global 68%. Isso foi verificado por Ouyang et al. (2011) que compararam o GEOBIA e o PBIA para o mapeamento a vegetação de pântanos salgados. A abordagem baseada em objetos apresentou uma acurácia global de 87%, enquanto que a PBIA apresentou uma acurácia global 82%.

Uma das etapas mais importantes da GEOBIA é a determinação dos parâmetros da segmentação. O parâmetro de escala da segmentação controla a heterogeneidade espectral e o tamanho máximo do objeto, podendo afetar diretamente a qualidade da segmentação e a acurácia da classificação (DRONOVA, 2015). Kavzoglu e Yildiz (2014) entendem que é iminente a avaliação de diversos parâmetros para a segmentação, pois, os valores apresentam variações conforme o tamanho e a heterogeneidade da área. Moffett e Gorelick (2013) verificaram que mesmo na ausência de heterogeneidade na imagem, o tamanho, a forma e a regularidade dos objetos variaram drasticamente de acordo com os parâmetros inseridos na segmentação.

Com abordagens GEOBIA, os objetos gerados a partir da segmentação de imagens podem ser classificados usando um procedimento baseado em regras (um conjunto de regras) (ZHOU; TROY, 2008) ou usando algoritmos de aprendizado de máquina com base em amostras de treinamento (PU et al., 2011). Esses algoritmos

são comumente categorizados como classificadores paramétricos (Máxima Verossimilhança e de Bayes) e não paramétricos (K vizinho mais próximo), Árvore de Decisão (AD) e *Support Vector Machine* (SVM), sendo estes os mais frequentemente utilizados (QIAN et al., 2015).

Duas abordagens de mineração de dados cada vez mais utilizadas para classificar imagens de sensoriamento remoto são a Árvore de Decisão (AD) baseada em regras e classificação *Random Forest* (RF). Os dois métodos são não-paramétricos e como tal, não são restringidos pela distribuição das variáveis preditoras (BERHANE et al., 2018).

Árvore de decisão é um método baseado em regras e condições, em que se é dado uma hipótese e existem duas possibilidades para respondê-la. Possui uma estrutura hierárquica, em que a hipótese representa o tronco de uma árvore, cada regra simboliza um galho e cada condição, uma folha (ou nó terminal). Pode ser utilizado com dados discretos (também chamada de aprendizagem de classificação) ou contínuos (regressão) (JENSEN, 2005).

Consiste em um fluxograma criado para categorizar os dados de maneira recursiva testando atributos do conjunto de dados em cada nó da árvore, com ramificações representando os diferentes resultados que levam a nós subsequentes, até que uma folha seja criada, representando uma classe (BERHANE et al., 2018).

Estudos vêm utilizando o método de AD para aplicações com referência espacial em AUs, como a geração de mapas de condições de inundação e tipos de cobertura (PARMUCHI; KARSZENBAUM; KANDUS, 2002) delimitar e distinguir AUs de outros tipos de coberturas (BAKER et al., 2006; SIMIONI et al., 2018a) e classificar tipos de AUs (WRIGHT e GALLANT, 2007).

A abordagem RF é uma técnica de classificação relativamente nova baseada no aprendizado de máquina e tem sido cada vez mais usada como um classificador de escolha para sensoriamento remoto de diferentes tipos de áreas úmidas e habitats aquáticos (BERHANE et al., 2018) e pode ser usada tanto para classificações quanto para regressões (MUTANGA; ADAM; CHO, 2012), bem como para determinar importância das variáveis (BELGIU; DRAGUT, 2016).

O RF é um método *ensemble-learning*, proposto por Breiman (2001), que seleciona de maneira aleatória percentuais dos dados de entrada e os separa em subconjuntos (nós), escolhendo o valor do atributo preditivo que minimiza a impureza do nó. Forma uma coleção de classificadores estruturados em árvore e para

cada sub-amostra é construída uma AD diferente e o valor estimado é referente à média da predição das árvores (TAALAB; CHENG; ZHANG, 2018). Cada classificador é gerado usando um vetor aleatório amostrado independentemente do vetor de entrada, e cada árvore lança um voto unitário para a classe mais popular para classificar um vetor de entrada (BREIMAN, 1999).

De modo geral, consiste em um conjunto de árvores de decisão, em que cada árvore é construída usando um subconjunto de amostras de treinamento com substituições. Apenas um subconjunto de recursos é usado para encontrar a melhor divisão em cada nó, que é um número constante sobre todos os nós e todas as árvores. Após o treinamento, o vetor do recurso de entrada é inserido em cada árvore e, em seguida, é atribuído um rótulo de classe para cada objeto no nó terminal com base na maioria dos votos (BREIMAN, 2001).

O RF tem sido utilizado para mapear e caracterizar AUs (TIAN et al., 2016; FRANKLIN; AHMED, 2017) e especificamente para classificar a cobertura vegetal (BEIJMA et al., 2014).

Para lidar com a complexidade física e a heterogeneidade das zonas úmidas e sua melhor caracterização, estudos integraram dados de sensoriamento remoto de múltiplos sensores (por exemplo, óptico, radar, lidar) e em múltiplas escalas espaciais (MISHRA, 2014). Fusão de dados ópticos e de Radar de Abertura Sintética (RAS) são um dos tipos mais comuns e promissores de combinação de dados para mapeamento e monitoramento de AUs (MAHDAVI et al., 2017).

Usando imagens de radar e análise conjunta entre imagens hiperespectrais, radar e índices de vegetação, pesquisadores conseguiram não apenas discriminar algumas espécies de zonas úmidas, mas também fazer progressos na estimativa de parâmetros bioquímicos e biofísicos da vegetação de zonas úmidas, como teor de água, biomassa e índice de área foliar (ADAM, MUTANGA; RUGEGE, 2010; OZESMI; BAUER, 2002; SIMARD; FATOYINBO; PINTO, 2010).

Técnicas GEOBIA e de mineração de dados combinadas com imagens ópticas e RAS permitem classificar com maior precisão tipos de vegetação em áreas úmidas. Destacam-se os trabalhos de Grenier et al. (2008) avaliaram métodos baseados em objetos com imagens ópticas e RAS para mapear classes de vegetação em áreas úmidas, obtendo uma acurácia global de 80%; Mui et al. (2015) ao aplicarem o GEOBIA e imagens de alta resolução espacial para o mapeamento de AUs obtiveram acurácias superiores a 80,0%. Ainda, conforme os autores, este valor pode ser

melhorado se forem adicionados dados de elevação e NDVI na classificação, por exemplo. E, Whyte et al. (2018) aplicaram o GEOBIA para monitorar AUs com imagens Sentinel 1 e 2, obtendo uma acurácia de 83,3%.

Além disso, métodos de mineração de dados proporcionam a seleção das características mais relevantes e reduzem a dimensionalidade do conjunto de dados, o que permite uma classificação mais acurada dos objetos geográficos (FRANKLIN et al., 2018). Em comparação com métodos baseados em pixels, o GEOBIA tem sido satisfatoriamente utilizado para classificação de áreas úmidas (POWERS et al., 2012; FRANKLIN; AHMED, 2017).

Quanto a contribuição das bandas ópticas na classificação de AUs, os estudos relataram que a vegetação em diferentes classes de AUs mostra maior variação nas bandas de borda vermelha e infravermelho próximo, conseqüentemente por suas características, mencionadas anteriormente. Portanto, essas duas bandas são as mais úteis para a detecção de AUs (ADAM et al., 2010; MUTANGA, ADAM, CHO, 2012; AMANI et al., 2017). Para Mahdavi et al. (2017) o papel das bandas visíveis na classificação não é central, pois as AUs são difíceis de distinguir visualmente.

Quanto as bandas RAS e polarizações, Silva et al. (2008) relata que a geometria do dossel, o conteúdo de umidade e a presença de características fortemente orientadas vertical ou horizontalmente, podem afetar o sinal resultante em algumas combinações de comprimento de onda e polarização. Por exemplo, plantas herbáceas densas, altas (1,5 m ou mais), orientadas verticalmente, mostram reflexão de canto na banda L (HH e VV), e até mesmo na C (HH) em baixos ângulos de incidência.

Para Henderson e Lewis (2008) ondas co-polarizadas (HH e VV) são mais efetivas na detecção de áreas úmidas não inundadas e geram maior contraste entre floresta seca e pântano inundado. A razão para isto é que a resposta do sinal de ondas polarizadas semelhantes é aumentada em condições de inundação. Ondas de polarização cruzada, no entanto, são mais apropriadas para distinção entre tipos de AUs. Dados co-polarizados duplos também são bem sucedidos na caracterização do mapeamento da vegetação inundada.

2.4.2 Estimativa de biomassa e carbono em AUs a partir de dados espectrais

A biomassa vegetal pode ser estimada por meio de dados espectrais, principalmente através do uso de análise de correlação e regressão, com bandas ou

combinações de bandas (índices) como variáveis preditoras (SILVA et al., 2008). Os índices de vegetação gerados a partir de imagens hiperespectrais ou multiespectrais podem ser correlacionados com as características da planta através de métodos empíricos, apresentando um método simples, direto e rápido para detectar e estimar características biofísicas e bioquímicas (SERRANO; PEÑUELAS; USTIN, 2002; BYRD et al., 2014).

A Razão Simples (*Simple Ratio* – SR) foi o primeiro índice de vegetação baseado na razão de bandas do vermelho e do infravermelho. Porém, para áreas densamente vegetadas, a quantidade de radiação eletromagnética refletida referente à região do vermelho aproxima-se de valores muito pequenos e essa razão, conseqüentemente, aumenta sem limites (PONZONI; SHIMABUKURO; KUPPLICH, 2012). Rouse et al. (1973) normalizaram a razão simples para o intervalo de -1 a +1, propondo o Índice de Vegetação por Diferença Normalizada (NDVI), Equação 1.

$$NDVI = \frac{(\rho_{IVP} - \rho_{Verm})}{(\rho_{IVP} + \rho_{Verm})} \quad (1)$$

Em que: ρ_{IVP} é a reflectância no infravermelho próximo; ρ_{Verm} é a reflectância no vermelho.

Como ferramenta para monitoramento da vegetação, o NDVI tem sido utilizado em estudos que envolvem a construção de perfis temporais, sazonais e fenológicos, pico de verde, período de crescimento, estudos climáticos e de mudanças agrícolas e florestais (PONZONI; SHIMABUKURO; KUPPLICH, 2012).

De acordo com Byrd et al. (2014) o uso do sensoriamento remoto óptico para estimar biomassa da vegetação emergente em AUs ocorreu a partir da década de 1980 na espécie *Spartina alterniflora* (Capim-marinho) que dominava os pântanos no oeste dos Estados Unidos, onde foi estabelecido que a biomassa pode ser modelada com NDVI calculado a partir de dados de reflectância de radiômetro portátil.

Para Guasselli (2005) as imagens de NDVI têm sido utilizadas em estudos que envolvem a determinação de índices de biomassa. Segundo o autor, o principal objetivo desse índice é realçar o alvo analisado em detrimento de outros alvos do seu entorno, como água e solo, constituindo-se bons indicadores da presença e condição da vegetação. Como os valores de reflectância da água nos comprimentos de onda do

visível são maiores do que no infravermelho, essas feições apresentam valores negativos, contrastando com o seu entorno.

Por ser sensível a condição da vegetação foliar verde (quantidade de clorofila) e a radiação fotossinteticamente ativa, o NDVI é frequentemente utilizado nos estudos ligados ao fenômeno da fotossíntese, estoques de carbono, balanço hídrico e outros processos relacionados (LILLESAND et al., 2007).

Para Byrd et al. (2014) o desafio dos índices do tipo NDVI, particularmente aqueles baseados nas faixas vermelha e NIR do espectro, é que eles apresentam um nível de saturação com a alta densidade de biomassa, não sendo preciso a 100% de cobertura vegetal, o que ocorre com frequência nos dosséis de AUs. Assim, dependendo das espécies de vegetação e tipos de dossel, este índice pode não obter os melhores resultados para inferência de biomassa.

O NDVI tem sido frequentemente usado para estimar a biomassa da vegetação de áreas úmidas, juntamente com o Índice de Vegetação Melhorado (EVI) (PEÑUELAS et al., 1993; ZHANG, 1998; BARBOSA, 2006; KEARNEY et al., 2009; BYRD et al., 2014). Estes índices também têm sido utilizados com sucesso para classificações, diferenciação de espécies, separabilidade entre água e terra seca, bem como para monitoramento e avaliação ambiental (GUASSELLI, 2005; SANTOS et al., 2009; VIRGÍLIO et al., 2013).

No entanto, esses índices de vegetação foram estabelecidos principalmente para a vegetação terrestre. Segundo Villa et al. (2013) pouca atenção foi dada até agora na obtenção de índices específicos para a vegetação de áreas úmidas e que a criação de IVs tem sido centrada na vegetação terrestre, principalmente pela dificuldade de detecção das propriedades da vegetação aquática, comparada com a terrestre.

Dentre os índices desenvolvidos até o momento, o mais recente foi proposto por Gao et al. (2017) para estimar biomassa da vegetação aquática submersa. O Índice de Vegetação Normalizado Ajustado a Água (NWAVI) foi desenvolvido apenas para vegetação submersa, excluindo as vegetações aquáticas emergentes, e calculado baseado na refletância do infravermelho próximo, do vermelho e da inclinação da linha de água. Por ser ainda recente, não foram encontrados outros trabalhos utilizando este índice e comprovando sua eficiência em outras áreas de estudo.

Outros dois índices foram propostos por Villa et al. (2014) para o mapeamento de diferentes espécies de vegetação aquática em três ecossistemas do norte da Itália. Os índices propostos são o Índice de Vegetação Aquática por Diferença Normalizada (NDAVI) e o Índice de Vegetação Ajustado a Água (WAVI). O NDAVI, Equação 2, segue a abordagem de diferenciação normalizada comum e amplamente testada e vem como uma adaptação do NDVI, especificamente destinada à vegetação aquática, onde o fundo da vegetação é geralmente composto de água ou solo saturado. Esta versão do NDVI adaptada para áreas úmidas substitui a banda espectral do vermelho (centrada aproximadamente em 0,66 μm) pela banda espectral do azul (centrada aproximadamente em 0,48 μm).

O WAVI é uma derivação do NDAVI com a introdução de um fator de correção L para ajustar a influência do sinal de fundo. Segundo Villas *et al.* (2014), para a formulação do WAVI (Equação 4), foi usado um valor único de $L = 0,5$ tendo este demonstrado bons resultados por reduzir sensivelmente a influência do fundo para uma boa variedade de condições de cobertura da vegetação. Os cálculos do NDAVI e WAVI são realizados conforme as Equações 2 e 3, respectivamente:

$$NDAVI = \frac{(\rho_{IVP} - \rho_{Azul})}{(\rho_{IVP} + \rho_{Azul})} \quad (2)$$

$$WAVI = (1 + L) \frac{(\rho_{IVP} - \rho_{Azul})}{(\rho_{IVP} + \rho_{Azul} + L)} \quad (3)$$

Em que: ρ_{IVP} é a reflectância no Infravermelho Próximo; ρ_{Azul} é a reflectância no Azul. L é o fator de correção (0,5).

A proposta dos índices de Villas et al. (2014) pode ser melhor entendida de acordo com as proposições de Peñuelas et al. (1993):

A água tem uma forte absorção no vermelho, mas menos absorção e maior dispersão no azul. A clorofila possui uma forte absorção no azul e vermelho, mas um mínimo de absorção no verde. Assim, a clorofila na água tende a aumentar a proporção de luminosidade verde e azul. Esta diferença fornece uma base para estimar o teor de clorofila dos sistemas aquáticos, e por sua vez, auxiliar na identificação da vegetação (PEÑUELAS et al., 1993).

Villas et al. (2014) aplicaram os índices sob um grande conjunto de imagens de sensores hiperespectrais e multiespectrais, com resoluções espaciais de 2 a 90 m, o que torna o método proposto prontamente transferível e flexível, além de dados multitemporais (entre os anos de 2005 a 2012). Concluíram que o NDAVI e o WAVI forneceram melhores características de separabilidade em comparação com aqueles obtidos por IVs "terrestres", em uma ampla gama de tipos e condições de vegetação. O WAVI respondeu melhor a características de fundo e, portanto, é melhor atuando na representação da densidade da vegetação aquática, enquanto o NDAVI é mais sensível a certas características da vegetação, mostrando-se útil para a separabilidade. Os valores de NDAVI e WAVI foram superiores ao NDVI e SAVI.

Os autores ainda asseguram que a integração destes índices com dados *in situ* e laboratoriais, ou seja, nutrientes, pigmentos e biomassa, podem contribuir com a compreensão da dinâmica da vegetação em ecossistemas aquáticos e com programas de gestão e conservação.

Para a inferência de carbono orgânico, Rahman et al. (2000) integraram o Índice de Reflectância Fotoquímica (PRI), que representa a eficiência do uso da luz na fotossíntese, com o NDVI, que representa o vigor da vegetação fotossinteticamente ativa. Verificaram que este modelo pôde capturar a maior parte da variação nos fluxos líquidos de CO₂ na formação boreal de coníferas, sendo que a comparação entre os resultados obtidos por meio da modelagem com dados AVIRIS e os medidos no campo apresentou um elevado coeficiente de determinação de 0,78.

O PRI pode ser relacionado com a taxa fotossintética a partir da relação entre a feição de absorção no azul (531nm) e o pico de reflectância do verde (570 nm) (RAHMAN et al, 2000). O PRI proposto por Gamon et al. (1992), é sensível às alterações nos pigmentos de carotenóides (principalmente a xantofila) nas folhas. Tais pigmentos são indicativos da eficiência do uso da luz fotossintética ou da taxa de dióxido de carbono armazenada pela vegetação por unidade de energia absorvida. Esse índice, Equação 4, é usado em estudos de estresse e de produtividade da vegetação. Os valores variam entre -1 e 1, para vegetação sadia, e entre -0,2 e 0,2 para vegetação senescente (GAMON *et al.*, 1992).

$$PRI = \frac{(\rho_{Verde} - \rho_{Azul})}{(\rho_{Verde} + \rho_{Azul})} \quad (4)$$

Em que: ρ_{Verde} é a reflectância no verde; ρ_{Azul} é a reflectância no azul.

Segundo Gamon et al. (1997), quanto mais próximo de zero for o índice, maior a capacidade de utilização da luz pela fotossíntese e, portanto, maior deve ser a eficiência da planta em realizá-la. Trazendo essa informação para o contexto do carbono atmosférico, quanto melhor a utilização da radiação e quanto maior for a fotossíntese, maior a possibilidade de a planta utilizar o carbono atmosférico para os processos fotossintéticos e, conseqüentemente, maior a quantidade de carbono estocado.

Baptista (2003) nomeou o índice integrado criado por Rahman et al. (2000) de CO₂flux e utilizou-o para o mapeamento do sequestro de carbono pela vegetação em ambientes tropicais do cerrado, por meio de imagens AVIRIS e HYPERION, relacionando-os com teores de CO₂ atmosférico. Os resultados obtidos apresentaram elevadas correlações entre o modelo proposto por Rahman et al. (2000) e o de determinação do sequestro de carbono pela vegetação. Mostraram também a relação inversa esperada entre o sequestro de carbono pela vegetação e os teores de CO₂ atmosférico, pois áreas com maior densidade florestal apresentam valores elevados de eficiência de fixação de carbono e baixos teores de CO₂ atmosférico.

De acordo com Baptista (2003, 2004), a integração do NDVI e PRI pode ser facilmente compreendida, pois, quanto maior for a atividade fotossintética, maior serão as feições de absorção nas faixas do azul e do vermelho. Logo, quanto maior for a diferença de contraste entre a região do visível e o infravermelho próximo, maior será a biomassa da vegetação na área imageada e maior o potencial de fixação de carbono.

Salienta-se, porém, que os dados de PRI devem ser reescalados para valores positivos, evitando dados negativos, sendo denominado de sPRI. O reescalamento para valores positivos é necessário para normalizar os dados de “verdor” da vegetação. O sPRI, Equação 5, é obtido por meio do PRI, adicionando uma unidade e dividindo o resultado por dois (RAHMAN et al., 2000). O CO₂flux, Equação 6, é obtido a partir da multiplicação do NDVI com o sPRI (BAPTISTA, 2003).

$$sPRI = \frac{(PRI + 1)}{2} \quad (5)$$

$$CO_2flux = (NDVI \times sPRI) \quad (6)$$

A partir do estudo de Baptista (2003), o CO₂flux tem sido utilizado em AUs para investigar a capacidade de sequestro de carbono na vegetação (LEITE, 2015) e para estimar o fluxo de CO₂ em reservatórios (FERREIRA, 2015). E também em outros ecossistemas mostrando-se eficiente na mensuração do estoque de carbono em diferentes tipologias de vegetação, correlacionado com dados espectrais e biofísicos, bem como com fluxo de CO₂ atmosférico (CERQUEIRA; FRANCA-ROCHA, 2007; MARTINS; BAPTISTA, 2013; SILVA, 2014; POLÔNIO, 2015).

A utilização da região de borda vermelha (*Red Edge*) vem se intensificando a partir do lançamento das missões dos satélites Sentinel-2 e Rapideye, uma vez que alguns estudos abordaram a importante relação entre a reflectância do *red edge* com clorofila e outros nutrientes presentes na estrutura celular da planta (FRAMPTON et al., 2013; JU et al., 2010; CLEVERS; GITELSON, 2013) com Índice de Área Foliar (XIE et al., 2018) e biomassa vegetal (SIBANDA; MUTANGA; ROUGET, 2015; GUERINI FILHO, 2018).

Entre os trabalhos que exploram esta região do espectro em AUs para estimativa de biomassa destaca-se o de Mutanga, Adam e Cho (2012), onde os autores utilizaram como base o modelo do índice NDVI para compor índices do tipo *Red edge* Razão simples sob imagens do sensor World View 2; e o de Baloloy et al. (2018) que utilizaram o índice composto por Gitelson e Merzlyak (1994), a partir da razão entre as bandas nas faixas 740 mn e 705mn dos sensores Sentinel-2 e Rapideye.

Assim como o índice NDVI também é utilizado para estimativa de carbono na vegetação (FRANK; KARN, 2003; LILLESAND et al., 2007; SCHILE et al., 2013), os índices *Red edge* Razão simples podem ser utilizados com a mesma finalidade por sua comprovada eficiência na estimativa de conteúdo de clorofila (DELEGIDO et al., 2011; CLEVERS; GITELSON, 2013; CLEVERS; KOOISTRA, 2013).

2.4.2.1 Modelos de Inferência de variáveis biofísicas utilizando dados espectrais

Modelos de previsão de variáveis biofísicas como biomassa e carbono podem ser desenvolvidos através da integração de sensoriamento remoto, dados de campo e modelos estatísticos. A correlação é o instrumento adequado para descobrir e medir a relação existente entre as variáveis. Os diagramas de dispersão entre as variáveis analisadas, juntamente com o coeficiente de correlação de *Pearson* (r) apontam a força da dependência entre elas, denotando que o aumento nos valores de uma está associado ao aumento proporcional nos valores da outra variável.

Estabelecida esta relação, o coeficiente de determinação (R^2) pode ser entendido como a contribuição de uma variável na previsão da outra a partir de uma equação de regressão (MORETTIN; BUSSAB, 2004).

Análises de correlação e regressão têm sido usadas com frequência para comparar e estimar biomassa e carbono na vegetação a partir de dados espectrais (RAHMAN et al., 2000; CASSOL, 2013; BYRD et al., 2014; SILVA; BAPTISTA, 2015; TRENTIN, 2015; GAO et al., 2017).

Análises de regressão são realizadas em AUs com o objetivo avaliar e comparar o potencial preditivo de bandas multiespectrais e índices de vegetação como variáveis independentes, em conjunto com variáveis biofísicas, que entram nos modelos como variáveis dependentes ou variável resposta. São especialmente úteis para monitoramento nestes ambientes em função da inacessibilidade que ocorre, muitas vezes, diante dos períodos de inundação.

Entre os tipos de regressão utilizadas encontram-se análise de regressão linear múltipla por passos (*stepwise*) (Barbosa, 2006), regressão de mínimos quadrados parciais (PLS) (BYRD et al., 2014), comparação entre algoritmo de regressão *Random Forest* e linear múltipla por *stepwise* (MUTANGA, ADAM, CHO, 2012), comparação de modelos de regressão não lineares como *Multivariate Adaptive Regression Spline* (MARS) com lineares simples e múltiplas (BALOLOY et al., 2018).

As equações de regressão simples e múltiplas são validadas por testes estatísticos e análises do coeficiente de determinação (R^2) ou ajustado ($R^2_{aj.}$), pelo Erro padrão da estimativa (S_{yx}) ou Erro Quadrático Médio (EQM) expressos na unidade métrica da variável dependente, e pela distribuição dos resíduos. A precisão das estimativas é geralmente feita por comparação entre os valores estimados e reais

observados. Alguns métodos como PLS e *Random Forest* também aplicam amostras de treinamento para gerar os modelos e outro grupo de amostras para sua validação.

3 METODOLOGIA

Os procedimentos metodológicos estão subdivididos em materiais e métodos.

3.1 MATERIAIS

Os materiais utilizados neste trabalho contemplam os dados e softwares utilizados, referentes principalmente ao uso de imagens de satélite, *softwares* de SIG e de estatística.

- i) Pacote *Office* 2016, desenvolvido pela empresa *Microsoft*;
- ii) Imagens ópticas Sentinel-2A *MSI* e *PlanetScope*;
- iii) Imagem de Radar de Abertura Sintética (RAS) Sentinel 1;
- iv) Dados pluviométricos, Estação Pluviométrica de Glorinha (Cód. 02950016), localizada no limite norte do Banhado Grande (-29°87' Lat, -50°74' Long);
- v) Programa SNAP (*Sentinel Application Platform*), desenvolvido pela ESA (*European Space Agency*) para o tratamento de imagens Sentinel;
- vi) Programa *ArcGIS* 10.3, desenvolvido pela ESRI (*Environmental Systems Research Institute*);
- vii) Programa *QGIS* 3.5, software livre e de código aberto;
- viii) Programa estatístico SPSS 18.0 desenvolvido pela IBM para análises de dados estatísticos, análise ad hoc, análise geoespacial e análise preditiva.

3.2 MÉTODOS

Os métodos que compõem esta pesquisa partem de quatro eixos principais de trabalho, explicitados entre as subseções 3.2.1 e 3.2.4. Aborda-se inicialmente sobre o experimento de campo e amostragem da vegetação; em seguida sobre a obtenção, especificações técnicas e tratamento do conjunto dos dados orbitais; após, sobre o mapeamento da cobertura vegetal no Banhado Grande, ressaltando a delimitação da área ocupada pela *Scirpus giganteus*; e, por fim, sobre a estimativa das variáveis biofísicas a partir das correlações e modelos de regressão.

3.2.1 Experimento de campo e amostragem

A escolha do local das coletas foi definida em função da acessibilidade e da disponibilidade de infraestrutura de transporte (barco), além de contemplar uma extensa área com monodominância da *Scirpus giganteus*. Foram selecionadas três áreas amostrais e definidas três parcelas por estaqueamento em cada área, com 60 m de comprimento e 20 m de largura, totalizando 9 parcelas, Figura 12.

As coletas foram realizadas no final das estações de verão, inverno e primavera do ano de 2018, respectivamente nas datas 14/03, 17/08 e 22/11. Estes períodos foram escolhidos visando verificar as possíveis variações de biomassa e carbono entre as estações. Na estação de outono não foi possível acessar o local devido à falha mecânica no barco.



Figura 12. Projeção simplificada das parcelas. Imagem aérea obtida por drone. Fonte: Fundação Municipal do Meio Ambiente de Gravataí, dez/2017.

Realizou-se uma coleta de vegetação aleatoriamente em cada parcela, a partir do “método do quadro” utilizando um quadrado de madeira de 50 x 50 cm (0,25m²). Foi cortado o material vegetal rente ao solo, com auxílio de uma tesoura de jardinagem, de acordo com a metodologia proposta por Pompêo e Moschini-Carlos

(2003), Figura 13. Em cada trabalho de campo foram coletadas nove amostras, uma por parcela, totalizando vinte e sete amostras no estudo.

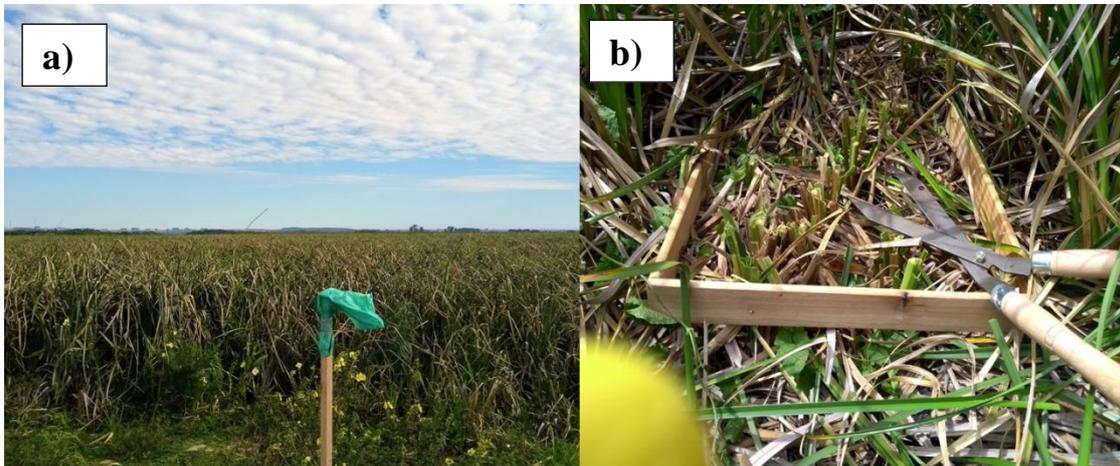


Figura 13. A) Imagem com ponto de localização de uma parcela; b) imagem pós corte da vegetação, data: 14/03/2018, Banhado Grande, RS. Fonte: Autora

O material vegetal foi armazenado em sacos plásticos e pesado com uma balança simples, com a finalidade de se obter a biomassa verde ou peso fresco, Figura 14. Após cada trabalho de campo o material era armazenado em sacos de papel até que fossem levados as estufas para obtenção da biomassa seca.



Figura 14. Amostras coletadas. Fonte: Autora

Procurou-se realizar as coletas no dia da passagem do satélite a fim de se obter a melhor validação possível entre os dados espectrais e os dados de campo. As parcelas foram posicionadas com GPS modelo *Etrex Legend*, com margem de erro de 3 m. A escolha da distância entre parcelas está relacionada com a resolução espacial das imagens ópticas do sensor Sentinel-2A, as quais foram utilizadas as bandas multiespectrais com resolução espacial de 10 x 10 m e 20 x 20 m.

Em todas as datas de amostragem foi medido o nível do rio próximo ao local das coletas com auxílio de uma haste de madeira. A precipitação acumulada também foi verificada para 60, 30, 20 e 5 dias anteriores às datas das coletas de vegetação, com dados da Estação Pluviométrica de Glorinha (Cód. 02950016, coord -29°87'S, -50°74'O).

Considerando o tempo disponível, o esforço de trabalho de campo e os recursos de transporte e financeiros necessários para as coletas e as análises, entende-se que essa é uma grade amostral suficiente para atingir os objetivos da pesquisa.

3.2.1.1 Análises e procedimentos em laboratório

Para obter a biomassa seca, o material vegetal foi seco em estufa a uma temperatura de 62°C, permanecendo por no mínimo 72h até atingir o peso constante (POMPÊO; MOSCHINI-CARLOS, 2003). Após foi pesado em balança de precisão para obtenção do peso seco, Figura 15. O resultado final foi expresso em gramas por m².

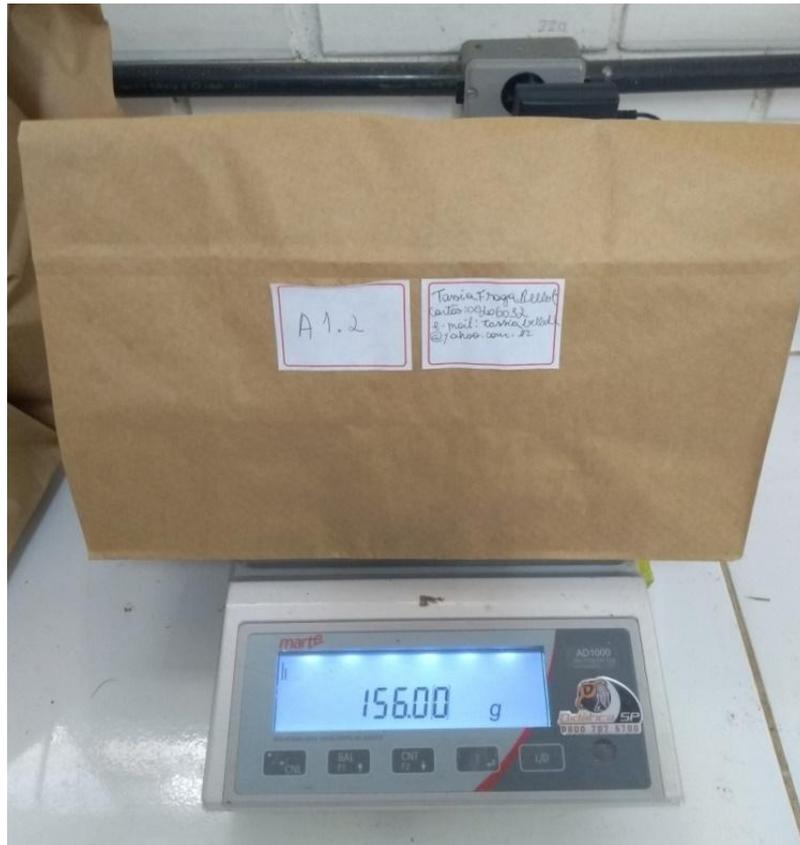


Figura 15. Obtenção da biomassa seca das amostras. Fonte: Autora

A concentração de carbono orgânico foi obtida pelo método da combustão úmida (*Walkley Black*), que se baseia na oxidação das amostras de biomassa seca trituradas com dicromato de potássio em meio ácido, com aquecimento externo a 150°C (TEDESCO *et al.*, 1995). A análise ocorreu no Laboratório de Análises de Solos da Faculdade de Agronomia (LABSOLOS/UFRGS). Os laudos encontram-se nos Anexos A, B e C. Este método apresenta os resultados em teor (%) de carbono orgânico em 100 gramas de amostra de peso seco. Esse fator foi utilizado para converter os dados de peso de biomassa seca (g/m^2) para estoques de carbono (g/m^2) através de proporção direta (SIFLEET *et al.*, 2011).

Foram avaliadas estatísticas descritivas das amostras (mínimo, máximo, média, erro e desvio-padrão) e bivariadas (Levene, ANOVA e teste Tukey) no programa estatístico SPSS 18.0.

Foram buscadas fontes oficiais de referência para assimilação de carbono em áreas úmidas junto ao Painel Intergovernamental de Mudanças Climáticas (IPCC), mas só foram encontradas para florestas de Mangue. Na falta de estudos com estimativas de valores de carbono orgânico para folhas de *S. giganteus* adotou-se como valores

de referência os verificados por Means et al. (2015) nas espécies emergentes *Carex vulpinoidea* e *Juncus effusus*, de porte semelhante a *S.giganteus*, também a partir do método de combustão.

Utilizando metodologia semelhante (coletas em parcelas monoespecíficas da vegetação e cálculo do peso seco) Protolongo e Kandus (2005) analisaram a dinâmica da biomassa de *S. giganteus* em uma ilha no baixo delta do rio Paraná, Argentina. Os valores médios variaram entre 377 a 500 g/m² e foram utilizados como valores de referência neste estudo, para fins comparativos.

3.2.2 Imagens utilizadas e pré-processamentos

Para o mapeamento da área da espécie no Banhado Grande foi utilizada uma imagem do sensor Sentinel-2A, de 09/02/2018, nas 13 bandas do sensor *Multispectral Instrument* (MSI), resolução espacial de 10 m, pré-processada para o nível 2A. E uma imagem do Radar de Abertura Sintética (RAS), banda C, de 25/02/2018, produto *Ground Range Detected* (GRD) do satélite Sentinel 1, resolução espacial de 10 m e pré-processamento de nível 1 nas polarizações VV e VH.

Para as correlações com os dados biofísicos e geração das equações de regressão foram utilizados dois sistemas sensores que operam na faixa do espectro EM do visível e infravermelho próximo (Sensor PlanetScope) e do infravermelho de ondas curtas (Sentinel-2A). Foram usadas três imagens Sentinel-2A, pré-processada para o nível 2A, com 20 m de resolução espacial, e três do sensor PlanetScope, com 3 m de resolução espacial, pré-processadas no nível 3B. Na Tabela 1 são apresentadas as datas das imagens utilizadas para as correlações e das coletas em campo. Apenas no mês de agosto não foi possível adquirir imagem Sentinel-2A sem nuvens, mais próxima da data de coleta. Nos três itens a seguir são apresentadas características gerais dos sensores utilizados nas duas etapas do estudo e processamentos aplicados nas imagens.

Tabela 1. Imagens utilizadas para extração dos dados espectrais e correlações com os dados biofísicos.

Sensor	Março/ 2018	Agosto/ 2018	Novembro/ 2018
Sentinel-2A	11/03	28/08	16/11
PlanetScope	13/03	17/08	21/11
Data das coletas	14/03	17/08	22/11

3.2.2.1 *Sensor Sentinel-2MSI (MultiSpectral Instrument)*

A missão Sentinel-2 compreende uma constelação de dois satélites (Sentinel-2A e 2B) de órbita polar colocados na mesma órbita sincronizada com o Sol, divididos em 180 ° entre si. A resolução temporal de cada sensor é 10 dias, sendo que o S2B atinge a mesma posição do S2A após 5 dias de sua passagem. Fornece imagens terrestres de média resolução espacial, espectral e temporal e visa assegurar a continuidade das observações Landsat e SPOT. Em comparação com os últimos sensores, o Sentinel-2 incorpora três novas bandas espectrais na região da borda vermelha, que são centradas em 705, 740 e 783 nm.

Possui 13 bandas espectrais entre as faixas do espectro visível, borda vermelha, infravermelho próximo e infravermelho de ondas curtas, com resoluções espaciais de 10m, 20m e 60 m, respectivamente e resolução radiométrica de 12 bits. As imagens deste sensor são distribuídas pela ESA (*European Space Agency*) com resolução de 16 bits e nível 1C de correção, que inclui correções radiométricas e geométricas ortorretificação e registro espacial em um sistema de referência global com precisão de subpixel.

Para este estudo foram utilizadas imagens reamostradas a 20 m usando o método *Nearest*, na plataforma SNAP. O pré-processamento das imagens *Sentinel-2* incluiu a correção atmosférica para converter os valores de reflectância do Topo da Atmosfera (TOA) em valores de reflectância da Base da Atmosfera (BOA) corrigidos. Para a correção atmosférica, foi utilizado o *plug-in* Sen2Cor da ESA, na Plataforma de Aplicação do *Sentinel* (*Sentinel Application Platform – SNAP*). Sen2Cor é um processador para geração e formatação de produtos Sentinel-2 Nível 2A; ele realiza a correção atmosférica, do terreno e de cirrus a partir dos dados de entrada do Nível 1C do Topo da Atmosfera.

O Sen2Cor cria imagens de reflectância corrigidas, opcionalmente em terreno e cirrus, bem como espessura óptica de aerossol, vapor de água, mapas de classificação de cena e indicadores de qualidade para probabilidades de nuvens e neve (CHATZIANTONIOU et al., 2017; SENTINEL TECHNICAL GUIDES, 2018).

3.2.2.2 *Sensor Sentinel-1 (Radar de Abertura Sintética - RAS)*

O *Sentinel-1* é uma missão de imagens de radar, composta por uma constelação de dois satélites em órbita polar, Sentinel-1A e 1B, que fornece imagens contínuas para todos os climas, dia e noite, na banda C a uma frequência de 5.405 GHz. O sistema tem a capacidade de operar nos modos de dupla polarização (HH/HV ou VV/VH) e polarização única (HH ou VV). Os produtos são distribuídos em três níveis de processamento: Nível-0, Nível-1 e Nível-2. Os produtos de Nível-1 incluem pré-processamento, estimativa centroide Doppler, focalização complexa de aparência única e imagem e pós-processamento para geração dos produtos SLC e GRD. Os produtos SLC preservam as informações de fase e são processados no espaçamento natural de pixels, enquanto os produtos GRD contêm a amplitude detectada e são multifacetados para reduzir o impacto do ruído *speckle*.

Para converter para valores de retroespalhamento (ou a medida de reflexão dos alvos da superfície para o SAR), foram aplicados os pré-processamentos: calibração radiométrica, filtragem do ruído *speckle* (com o filtro de Lee Sigma) e a correção do terreno, utilizando a SNAP.

A calibração radiométrica corrige os valores dos pixels com intuito de representar verdadeiramente o retroespalhamento da superfície imageada, assim os valores foram convertidos para intensidade. O ruído *speckle* causa o cancelamento (interferência destrutiva) ou a soma do sinal (interferência), gerando imagens com efeito “sal e pimenta”. Para amenizar esse efeito, foi aplicado o filtro de Lee sigma, com uma janela móvel de 5x5.

Devido à geometria lateral da imagem RAS, a imagem é gerada no plano inclinado (*Slant Range Domain*). A correção do terreno converte a imagem do plano inclinado para nível do terreno (*Ground Range Geometry*) e define um sistema cartográfico. Para a correção do terreno foram utilizadas imagens de altimetria do *Shuttle Radar Topography Mission* (SRTM), com resolução espacial de 30 m e o sistema de projeção *Universal Transversa de Mercator* (UTM), fuso 22, hemisfério sul e datum horizontal SIRGAS/2000 (ABDIKAN et al. 2016).

3.2.2.3 *Sensor PlanetScope*

As imagens PlanetScope são obtidas pela constelação de nanosatélites que possuem o mesmo tipo de sensor, são adquiridas por mais de 130 satélites, com 04 bandas espectrais (visíveis e infravermelho próximo) e resolução radiométrica de 12 bits, são ortorretificadas e possuem 3 metros de resolução espacial, com revisitas diárias a partir de 2016.

Os produtos Planet são distribuídos no Brasil pela empresa Santiago e Sintra Consultoria (SCCON) e também podem ser acessados através de cadastro como pesquisador na Plataforma API Planet. São distribuídos em valores de radiância (*Planet Analytic Product*) e em valores de reflectância (*Planet Surface Reflectance – SR*).

O produto SR é derivado do produto *Planet Analytic* padrão, é processado em reflectância na atmosfera superior (TOA) e depois corrigido para reflectância na atmosfera inferior (BOA) a partir do algoritmo 6S, V2.1. O produto SR é fornecido como uma imagem GeoTIFF de 16 bits com valores de reflectância e garante a consistência em todas as condições atmosféricas localizadas, minimizando a incerteza da resposta espectral ao longo do tempo e localização (*PLANET SURFACE REFLECTANCE PRODUCT*, 2018).

O produto SR é fornecido ao usuário com correção dos efeitos relacionados ao sensor, a partir da telemetria de atitude do sensor e dos melhores dados de efemérides disponíveis (posição e velocidade ao longo do tempo). As bandas são co-registradas e ortorretificadas usando GCPs e DEMs finos (30 m a 90 m) para precisão posicional de erro médio <10 m (*PLANET PRODUCT SPECIFICATIONS*, 2018).

Na Tabela 2 são apresentadas as principais características dos sensores e bandas ópticas utilizados no estudo. Não foram encontradas informações sobre os comprimentos de onda iniciais e finais de cada banda do sensor Sentinel-2, apenas o comprimento central.

Tabela 2. Características das bandas ópticas.

Sensor	Bandas Espectrais	Resolução Espectral (μm)	Resolução Temporal	Resolução Espacial	Resolução radiométrica
Sentinel-2A	B2 azul	0.496	10 dias	10 m	16 bits
	B3 verde	0.560			
	B4 vermelho	0.665			
	B5 RE'	0.704			
	B6 RE	0.740			
	B7 RE	0.783			
	B8 NIR''	0.835			
	B8a RE	0.865			
	B11 SWIR'''	1.614			
	B12 SWIR	2.202			
PlanetScope	B1 azul	455-515	Diária	3 m	16 bits
	B2 verde	500-590			
	B3 vermelho	590-670			
	B4 NIR	780-860			

'Borda vermelha; '' Infravermelho próximo; '''Infravermelho de ondas curtas.

3.2.3 Mapeamento da área da espécie a partir de Análise de Imagens Baseada em Objetos Geográficos (GEOBIA) e mineração de dados

A área de cobertura da *S. giganteus* foi mapeada a partir de um mapa de uso e cobertura no Banhado Grande, onde as principais feições são tipologias de vegetação. Após, foram estimadas as variáveis biofísicas para a área de cobertura da espécie.

Foi utilizado o método de classificação a partir de Análise de Imagens Baseada em Objetos Geográficos (GEOBIA), utilizando o algoritmo de mineração de dados *Random Forest* para o reconhecimento de padrões e seleção das características de interesse, através de amostras de treinamento e validação fornecidas ao sistema. Os métodos que compõem esta etapa da pesquisa estão resumidos na Figura 16 e explicitados a seguir.

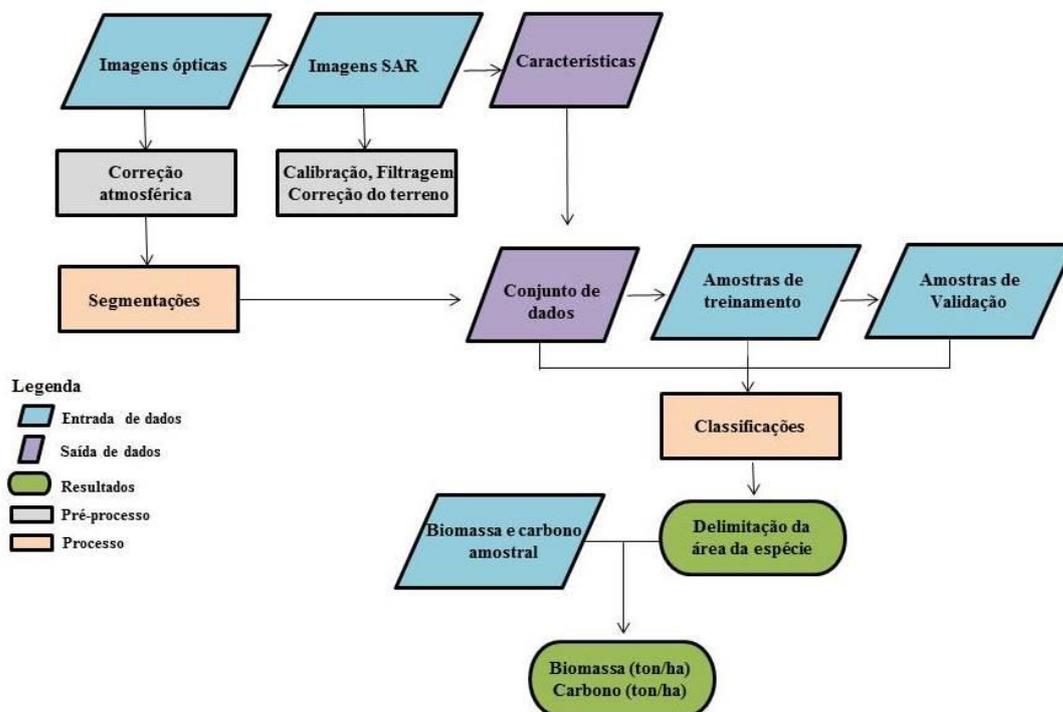


Figura 16. Fluxograma metodológico

A determinação das classes de vegetação foi baseada na metodologia de classificação de Maltchik et al. (2004), para as AUs do Rio Grande do Sul, adaptando os modelos desenvolvidos pelo *U.S. Fish and Wildlife Service* (COWARDIN et al., 1979) e pela *Ramsar Convention Bureau* (1990). Foram consideradas classes contidas no limite oficial do Banhado Grande (FZB, 2013), que contemplam a vegetação das áreas úmidas naturais e locais com cultivos agrícolas.

Maltchik et al. (2004) dividem o sistema Palustre de forma hierárquica em quatro níveis com base em fatores hidrogeomorfológicos e biológicos (subsistemas, tipos, classes e subclasses), agrupando diferentes tipos de AUs, além de pequenos corpos d'água permanentes ou intermitentes e lagoas. As áreas úmidas palustres situam-se à margem dos lagos, canais fluviais, estuários, várzeas de rios ou em encostas.

O Banhado Grande compreende o subsistema Palustre dos tipos permanente (áreas permanentemente alagadas), intermitentes (áreas inundadas pelo menos 4 meses do ano) e com falta de águas superficiais (presença de solos saturados). As classes são estabelecidas de acordo com características de cobertura vegetal semelhantes e padrão de espécies (MALTCHIK et al., 2004).

Embora 7 classes de cobertura tenham sido mapeadas, a classe de cobertura referente a *S. giganteus*, caracterizada por espécies de macrófitas Emergentes (EM), foi particularmente ressaltada no resultado. Esta classe compreende espécies fixas no solo, formando um estrato alto e denso com alturas entre 1,50 m e 1,70 m. Ocorre a predominância de *S. giganteus* de forma monoespecífica, mas estandes difusos com outras espécies podem ser encontrados. O restante das classes foram consideradas apenas na análise de acurácias do mapeamento e não consideradas na estimativa de biomassa e carbono.

Nestas classes são encontradas: Macrófitas Flutuantes (MF), em sua maior parte ciperáceas, que formam extensas coberturas verdes e homogêneas; Um conjunto indissociável de espécies emergentes, flutuantes e arbustivas, representadas pela classe de Transição Vegetativa (TV) que consistem em tipos de cobertura vegetal diversificadas devido às peculiaridades do terreno e diferenças de saturação na área de transição entre o ambiente terrestre e aquático; A classe campo úmido (CA), normalmente posicionada nas bordas dos banhados, é composta por estratos arbustivos e herbáceos, ambos de pequeno porte, que apresentam-se alagadas em grande parte do ano; Nas bordas do banhado, encontram-se formações Lenhosas e Arbustivas (LA); Na classe Agricultura (AGR) predominam o cultivo de arroz irrigado e soja, em áreas adjacentes ao Banhado Grande; e áreas de Água aberta (AGU), Tabela 3.

Tabela 3 - Classes, dominância de espécies e tipologias no Banhado Grande.

Classe	Espécies dominantes/ tipologia
Macrófitas Flutuantes (MF)	<i>Eichhornia crassipes</i> , <i>Eichhornea azurea</i> , <i>Salvinia auriculata</i> , <i>Hydrochleis nymphoides</i> , <i>Leersia sp.</i> , <i>Cabomba australis</i> , <i>Leersia sp.</i> , <i>Pontederia lanceolata</i> , <i>Nymphoides sp.</i> , <i>Hygrophila sp.</i> , <i>Polygonum spp.</i> , <i>Myriophyllum brasiliensis</i> .
Emergentes (EM)	Predominância de <i>Scirpus giganteus</i> , mas podem ser encontradas <i>Cyperus sp.</i> , <i>Zizaniopsis sp.</i> e <i>Eryngium pandanifolium</i> ,
Lenhosas e Arbustivas (LA)	<i>Cephalanthus sp.</i> , <i>Mimosa sp.</i> <i>Calliandra sp.</i> , <i>Erythrina sp.</i>
Campo úmido (CA)	<i>Erianthus sp.</i> , <i>Andropogon bicornis</i> , <i>Sida sp.</i> , <i>Mimosa bimucronata</i> , <i>Panicum prionitis</i> , e gramíneas
Transição Vegetativa (TV)	Macrófitas diversas, gramíneas e arbustivas
Agricultura (AGR)	Orizicultura e soja
Água (AGU)	Água

Para a caracterização da cobertura vegetal foram realizadas expedições pelo rio Gravataí e Banhado Grande com intuito de capturar fotografias terrestres georreferenciadas e avaliar a ocorrência de espécies de macrófitas. Também foram utilizados os pontos georreferenciados de coletas de biomassa. Esses levantamentos, juntamente com a ferramenta *Google Earth*, auxiliaram no reconhecimento de padrões das espécies vegetais.

3.2.3.1 Características (bandas)

Para a classificação foram utilizadas duas imagens. Uma imagem do satélite Sentinel-2A, de 09/02/2018, nas 13 bandas do sensor *Multispectral Instrument* (MSI), a imagem foi processada para remover os efeitos atmosféricos e converter os valores dos pixels para reflectância da superfície, conforme descrito no item anterior. Foram removidas as bandas 1 e 10, porque são sensores com o objetivo de armazenar radiações de aerossol costeiro e das nuvens do tipo Cirrus, respectivamente. E uma imagem do Radar de Abertura Sintética (RAS), banda C, de 25/02/2018, produto *Ground Range Detected* (GRD) do satélite Sentinel 1, resolução espacial de 10 m, nas polarizações VV e VH.

Os conjuntos de dados foram gerados calculando as médias e os desvios padrões para os objetos geográficos, considerando as bandas ópticas e RAS, Tabela 4.

Tabela 4 – Características

Estadísticas das características	Características
Valores médios (M) e Desvio Padrão (DP) das bandas ópticas para os objetos geográficos	(B2M, B3M, B4M, B5M, B6M, B7M, B8M, B8aM, B9M, B11M e B12M); (B1DP, B2DP, B3DP, B4DP, B5DP, B6DP, B7DP, B8DP, B8aDP, B9DP, B11DP e B12DP).
Valores médios (M) e Desvio Padrão (DP) das bandas RAS para os objetos geográficos	(VVM e VHM); (VVDP e VHDP).

3.2.3.2 Segmentação

Na etapa de segmentação foram utilizadas as bandas ópticas (2, 3, 4 e 8) com resolução espacial de 10 metros do Sentinel 2A. Foi utilizado o método de segmentação crescimento de regiões, disponível na ferramenta *i.segment* do programa *Geographic Resources Analysis Support System* (GRASS-GIS). O processo de segmentação inicia a partir de um conjunto de pixels sementes e análise das similaridades dos pixels com seus vizinhos. Pixels com valores similares são agrupados e assim, são formados os objetos geográficos (Espindola 2006). O limiar de similaridade controla o crescimento dos objetos geográficos e o parâmetro Número Mínimo de Pixels (NMP) determina o tamanho mínimo dos objetos geográficos.

Os pixels sementes foram iniciados de forma aleatória e foram avaliados os limiares de similaridades entre 0 a 1, variando 0.1. Também foram avaliados valores de NMP entre 200 a 600, variando 200 pixels.

3.2.3.3 Mineração de dados

A mineração de dados tem como propósito encontrar padrões em um grande conjunto de dados. O método RF exige um menor custo computacional para treinar os modelos e são menos sensíveis aos parâmetros de ajuste. *Random Forest* também determina as importâncias das feições na discriminação das classes do conjunto de dados (Ooi et al., 2013; Qian et al, 2015).

As amostras de treinamento foram compostas por pontos regulares gerados com equidistâncias de 300 m, totalizando 658 pontos. Desse total, 80% dos pontos foram utilizados como amostras de treinamento e 20% como amostras de validação. As classes dos pontos foram atribuídas por meio de visitas a campo, de um acervo de

fotos terrestres georreferenciadas e de imagens orbitais disponíveis no *Google Earth*.

As amostras de treinamento foram utilizadas para ajustar o método de mineração de dados RF, considerando as classes de uso e cobertura, apresentadas nos resultados. O RF divide as amostras de treinamento em subconjuntos e gera uma árvore de decisão para cada subconjunto. Para cada novo subconjunto de treinamento utilizado para construir uma árvore de decisão, um terço das amostras é excluído aleatoriamente, essas amostras são denominadas como *out-of-bag*.

As amostras restantes (*in-the-bag*) são usadas para construir a árvore de decisão. As amostras *out-of-bag* são utilizadas para avaliar o desempenho do modelo e selecionar o subconjunto de treinamento com a maior acurácia. Após o modelo treinado, a classificação de um novo exemplo é obtida pela votação de cada árvore, assim, a amostra é classificada na classe mais votada. O crescimento da árvore de decisão é realizado selecionando vetores de feições que diminuem a impureza de cada nó da árvore. O método RF estima as importâncias das feições computando o decréscimo médio da impureza dos nós (BREIMAN, 2001; TIAN et al., 2016).

O número de árvores e a sua profundidade máxima são parâmetros ajustáveis, para ambos os parâmetros foram avaliados os valores, respectivamente, entre 5 a 50, variando 5. Foi utilizado como critério de divisão dos nós da árvore o índice *Gini Impurity* (ΔI), descrito na equação (7).

$$\Delta I = G(\tau) - plG(\tau l) - prG(\tau r) \quad (7)$$

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

Com as amostras de validação foram calculadas as acurácias das classificações por meio do índice de validação Proporção Correta (PC) proposto por Pontius e Millones (2011), Acurácia do Produtor (AP) e Acurácia do Usuário (AU) (CONGALTON, 1991). Para o cálculo de PC, inicia-se com a geração da matriz de confusão em relação aos dados de referência com a classificação, posteriormente e estimada a matriz populacional. Com a posse da matriz populacional, calcula-se o índice, conforme a Equação (8).

$$PC = \sum_{j=1}^J D_{jj} \quad (8)$$

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

Todos os conjuntos de dados foram avaliados em relação aos parâmetros do classificador, o melhor caso do método foi apresentado no resultado.

As classificações e as validações foram desenvolvidas na linguagem de programação Python 3. Com auxílio da biblioteca de mineração de dados *Scikit-Learn* foram elaboradas as rotinas das classificações (PEDREGOSA et al., 2011) e com a biblioteca *Numpy* de computação científica as validações (WALT; COLBERT; VAROQUAUX, 2011).

3.2.4 Estimativa de biomassa e carbono a partir de dados espectrais

Para estimativa das variáveis biofísicas a partir dos dados espectrais foram correlacionados os valores das amostras de vegetação com as bandas e índices de vegetação e, após, gerados modelos de regressão com imagens dos sensores Sentinel 2-A e PlanetScope. Os métodos que compõem esta etapa da pesquisa estão resumidos na Figura 17 e explicitados nas subseções a seguir.

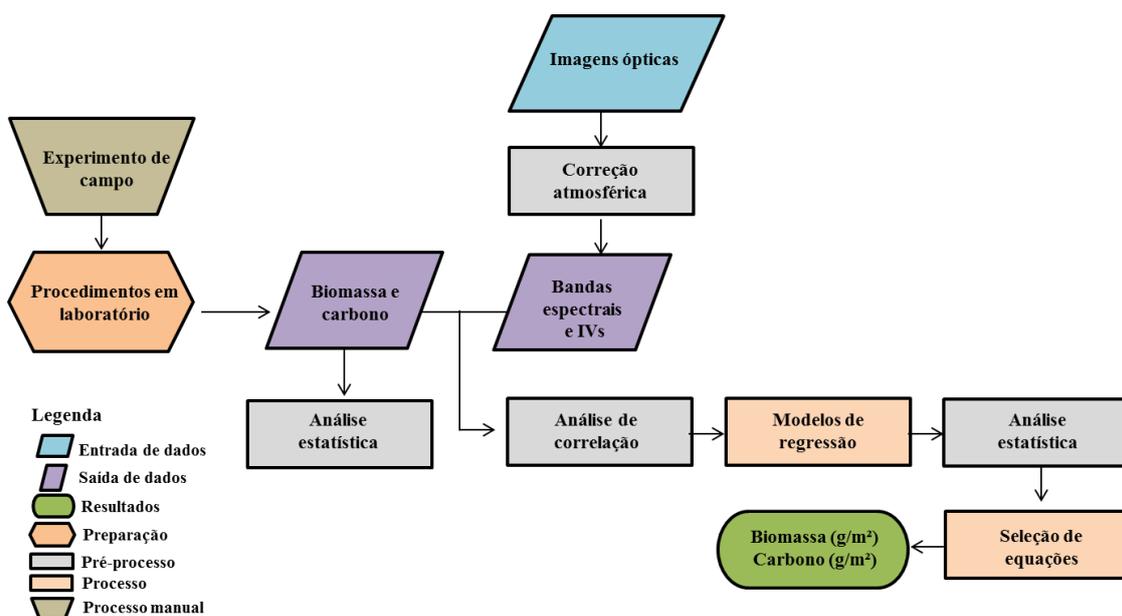


Figura 17. Fluxograma metodológico

3.2.4.1 Dados espectrais: cálculo dos índices de vegetação

De posse das imagens corrigida para valores de reflectância na base da atmosfera, procedeu-se com o cálculo dos índices de vegetação. Os IVs baseiam-se na matemática de bandas das imagens de reflectância dos sensores ópticos. Os índices foram calculados no software *Qgis*. Na Tabela 5 são apresentados os IVs utilizados e suas respectivas formulações.

Tabela 5. Índices de vegetação utilizados no estudo

Índice de Vegetação / Referência	Fórmula
NDVI - Diferença Normalizada Rouse et al., (1974)	$NDVI = \frac{(\rho IVP - \rho Verm)}{(\rho IVP + \rho Verm)}$
NDAVI - Aquática por Diferença Normalizada Villas et al., (2013)	$NDAVI = \frac{(IVP - \rho Azul)}{(IVP + \rho Azul)}$
WAVI - Ajustado a Água Villas et al., (2014)	$WAVI = (1 + L) \frac{(IVP - \rho Azul)}{(IVP + \rho Azul + L)}$
NDRE1 - Diferença Normalizada Red edge 1 Gitelson e Merzlyak (1994)	$NDRE1 = \frac{(\rho RE6 - \rho RE5)}{(\rho RE6 + \rho RE5)}$
NDRE2- Diferença Normalizada Red edge 2 Barnes et al.,(2000)	$NDRE2 = \frac{(\rho RE7 - \rho RE5)}{(\rho RE7 + \rho RE5)}$
NDRE3- Diferença Normalizada Red edge 3 Gitelson e Merzlyak (1994)	$NDRE3 = \frac{(\rho RE5 - \rho RE4)}{(\rho RE5 + \rho RE4)}$
NDRE4- Diferença Normalizada Red edge 4	$NDRE4 = \frac{(\rho RE8 - \rho RE5)}{(\rho RE8 + \rho RE5)}$
sPRI - Reflectância Fotoquímica Gamon et al., (1979)	$sPRI = \frac{(PRI + 1)}{2} \quad PRI = \frac{(\rho Verde - \rho Azul)}{(\rho Verde + \rho Azul)}$
CO ₂ flux - Integrado Rahman et al., (2000); Baptista (2003)	$CO_2flux = (NDVI \times sPRI)$
CO ₂ flux - Integrado NDAVI	$CO_2fluxNDAVI = (NDAVI \times sPRI)$

ρIVP = reflectância no Infravermelho Próximo; $\rho Verm$ = reflectância no Vermelho; ρRE = reflectância no Red Edge; $\rho Azul$ = reflectância no Azul. Os valores assumidos pelos algoritmos: WAVI: L= 0,5.

Como o CO₂flux é um índice integrado, foi testado neste trabalho sua formulação com a substituição do NDVI pelo NDAVI, caso o NDAVI apresente valores de reflectância mais altos que o NDVI. Também foi testada uma variação do índice NDVI com a inclusão da primeira banda da região da borda do vermelho do espectro, resultando no índice NDRE4.

3.2.4.2 Análise de correlação

O tratamento estatístico inicial foi o desenvolvimento da análise de correlação entre o conjunto amostral de biomassa seca (27 amostras) e os dados espectrais de cada sensor, e entre o conjunto amostral de carbono orgânico (27 amostras) e os dados espectrais de cada sensor. Inicialmente, foram estabelecidos dois grupos de correlações: o primeiro contempla a correlação entre as bandas espectrais e as variáveis biofísicas; e o segundo entre os IVs e as variáveis biofísicas.

A análise de correlação tem a finalidade de quantificar o grau de associação linear entre as variáveis e a estatística que descreve a intensidade desta associação é o coeficiente de correlação (WATZLAWICK et al., 2004). O coeficiente de correlação de Pearson (r) varia de -1 a 1, sendo que os extremos representam perfeita correlação entre variáveis e 0, a ausência. O grau de dependência entre variáveis pode ser facilmente visualizado pelo diagrama de dispersão entre os pontos coletados nas parcelas; alta dependência entre variáveis significa que o aumento nos valores de uma variável está associado ao aumento proporcional nos valores da outra variável. Esta se constitui na primeira etapa da análise de correlação (HO, 2006).

O coeficiente de determinação (R²) descreve esta relação, pode ser entendido como a proporção de variação de uma variável que é explicada pela variação da outra variável, ou seja, a contribuição de X na previsão de Y. Os valores de R² variam de 0 a 1 e quanto mais próximos de 1 e 0 melhor será o ajuste (MORETTIN; BUSSAB, 2004).

Os valores espectrais das bandas e IVs foram obtidos através dos pixels correspondentes a cada parcela de vegetação no Banhado Grande. Para a extração automática dos valores foi utilizada a ferramenta *Point Sampling Tool*, disponível no software *QGis*.

Em cada imagem foram utilizados os pontos de GPS das parcelas como ponto para a coleta do pixel correspondente. A existência do erro de navegação do GPS e

de posicionamento dos sensores é amenizada pelo fato dessas observações estarem sendo feitas em grandes parcelas monoespecíficas, tornando improvável que as coletas dos pixels nas imagens tenham sido fora da parcela com as plantas desejadas.

Destas correlações foram verificadas as bandas e os índices com correlação e contribuição mais significativa como variáveis preditoras, através do valor do coeficiente de correlação. Correlações com valor de r menor que 0,30 foram consideradas fracas correlações, de 0,40 a 0,60 moderadas e acima de 0,70 fortes (FIELD, 2009).

No caso da presença de valores *outliers*, o tratamento consiste na retirada de valores fora do intervalo [-3,3 desvios] (FIELD, 2009). Optou-se por não utilizar a biomassa verde nestas análises por não terem sido pesadas com balança de precisão.

3.2.4.3 Análise de regressão

A estimativa de biomassa e carbono orgânico foi realizada através de modelos estatísticos empíricos de regressão linear simples e múltipla. A análise de regressão envolveu as relações existentes entre o valor do pixel nas bandas espectrais e IVs em cada sensor, tratados como variáveis independentes e os valores de biomassa e carbono quantificados em g/m^2 como variáveis dependentes.

No SPSS foram testadas, inicialmente, as relações lineares múltiplas entre os dados espectrais e os valores de biomassa e carbono vegetal, dada pela equação genérica $y = (\beta_0 + \beta_1.x_1 + \beta_2.x_2 + \beta_n.x_n..) + \epsilon$, sendo que y são as variáveis biofísicas que se busca estimar, x são as variáveis independentes, β_0 , β_1 , β_2 , β_n são coeficientes desconhecidos e ϵ é o erro do modelo ou resíduo, que consiste na diferença entre o valor previsto por ele e o valor real observado. No caso em que a regressão múltipla não tenha atendido os pressupostos para uma regressão satisfatória, utilizou-se a regressão linear simples: $y = (\beta_0 + \beta_1.x_1) + \epsilon$.

O método de seleção de variáveis foi o Hierárquico com entrada em blocos, onde os previsores são selecionados pelo pesquisador com base em sua ordem de importância para prever a variável de saída (FIELD, 2009). O critério hierárquico utilizado foi inserir primeiro as variáveis com maior correlação com as variáveis de saída (biomassa e carbono). Depois de entrar com estes previsores, são adicionados os previsores com correlação mais baixa, seguindo a ordem hierárquica.

Foram feitos testes prévios com o método *Stepwise*, porém, ao avaliar os erros das equações geradas, verificou-se que estes eram maiores do que os gerados

pelo método anterior. O *Stepwise* procura pelo previsor (entre as variáveis) que apresenta o coeficiente de correlação mais alto com a variável de saída, de acordo com um nível de significância F de *Fischer* pré-estabelecido (FIELD, 2009). A ordem em que os previsores são acrescentados ao modelo é baseada puramente em critérios matemáticos.

3.2.4.4 Escolha do modelo e validação das regressões

A escolha dos melhores modelos se deu pelo atendimento as estatísticas teste *t student* e ANOVA com nível de significância $p < 0,005$, ao melhor valor de R^2 e R^2 ajustado, além do cumprimento dos pressupostos para uma regressão satisfatória: ausência de multicolinearidade, homocedasticidade, normalidade e independência dos resíduos e ausência de outliers.

O coeficiente de determinação ajustado ($R^2_{aj.}$) funciona de forma semelhante ao R^2 , porém este é utilizado quando são comparadas equações com diferentes números de coeficientes de entrada para alimentar as regressões múltiplas. É ajustado para desconsiderar o aumento ao acaso do r^2 que ocorre quando são inseridas novas variáveis no modelo.

A ANOVA testa o ajuste entre os modelos, a partir de teste de hipótese, comparando se o ajuste do modelo gerado é igual (H_0) ou diferentes do anterior (H_1) e também compara o modelo gerado com um modelo sem qualquer previsor. Desta forma, pode-se concluir se o modelo de regressão resulta em previsões melhores do que se utilizássemos o valor médio das variáveis dependentes (Field, 2009), no caso, biomassa e carbono. O teste *t* analisa se os coeficientes $\beta_0, \beta_1, \beta_2 \dots \beta_n$ gerados são relevantes para o modelo (H_1 diferentes de zero), ou seja, se as variáveis preveem significativamente ($p < 0,005$) um valor de saída.

A multicolinearidade é a alta correlação entre duas ou mais variáveis independentes. Foi avaliada pelo teste de colinearidade do SPSS, com as estatísticas FIV (Fator de Inflação da Variância) e tolerância (com a tolerância sendo 1 dividido pela FIV). Para não colinearidade os valores de FIV devem ser abaixo de 10 e de tolerância acima de 0,1. A independência dos resíduos ou não correlação entre eles, foi verificada pelo teste *Durbin-watson*, sendo que os resíduos são a diferença entre os valores previstos pelo modelo e o observado. A estatística teste pode variar entre 0 e 4, com 2 significando que os resíduos não são correlacionados, sendo aceitável valores entre 1,50 e 2,50 (FIELD, 2009).

A normalidade dos resíduos foi verificada por histogramas e p-p plot. O gráfico dos resíduos é construído plotando-se os valores estimados padronizados (eixo x) versus resíduos padronizados (eixo y). Uma boa dispersão gráfica dos resíduos ocorre quando os valores estimados flutuam uniformemente em torno do resíduo nulo, com pelo menos 95% dos valores dos resíduos dentro do intervalo [-3,3 desvios] (FIELD, 2009).

Homocedasticidade ocorre quando a distribuição dos resíduos é constante em cada ponto ao longo de qualquer variável previsora. Está também foi verificada por plotagem e forma da distribuição dos resíduos. Por padrão do software, foram considerados *outliers* os valores padronizados preditivos e dos resíduos que se encontram fora da faixa [-3, + 3] desvios padrão.

Para verificar a acurácia dos ajustes usou-se o coeficiente de determinação ajustado ($R^2_{aj.}$) e também o Erro Médio Quadrático (EQM) para avaliar a precisão dos modelos. O R^2_{aj} também serve para testar se o modelo de fato é generalizável. Esse valor ajustado significa a perda do poder de previsão ou encolhimento. O R^2 informa quanto da variância de Y pode ser creditada ao modelo de regressão amostral, e o R^2_{aj} nos informa quanta variância de Y pode ser creditada ao modelo se ele tiver sido derivado da população de onde a amostra foi retirada. O SPSS determina o valor R^2_{aj} utilizando a equação de Wherry (FIELD, 2009).

Desse modo, o R^2_{aj} pode ser usado como método de validação cruzada, na falta de um conjunto de dados suficiente para comparação por divisão, onde é gerada uma equação para cada metade dos dados e comparados os modelos resultantes.

O EQM também denominado de Erro Padrão da Estimativa é o erro cometido ao ajustar os resíduos aos valores reais observados. Determina o quanto em termos médios os valores estimados estão variando em relação aos observados. Quanto menor o EQM melhor o ajuste da equação.

4 RESULTADOS

4.1 QUANTIFICAÇÃO DAS VARIÁVEIS BIOFÍSICAS A PARTIR DAS COLETAS DE CAMPO

Foi estimada a biomassa e carbono orgânico para área de 1m², em um total de 27 amostras de *S. giganteus* coletadas em nove parcelas e em diferentes estações do ano, e avaliadas estatísticas descritivas no programa estatístico SPSS 18.0.

Os valores médios de biomassa seca foram superiores aos valores médios encontrados por Protolongo e Kandus (2005). O maior valor médio observado de biomassa foi de 862,98 g/m² ± 87,83 (± erro padrão) e ocorreu nas coletas realizadas na estação de primavera. O menor valor médio de biomassa foi 598,76 ± 70,89 e ocorreu nas coletas realizadas na estação de inverno, Tabela 6.

Tabela 6. Estatísticas das variáveis biofísicas.

	Biomassa seca (g/m ²)			Carbono orgânico (g/m ² e %)		
	Verão	Inverno	Primavera	Verão	Inverno	Primavera
Mínimo	443.96	340.24	422.92	190.9/ 41%	142.9/ 40%	173.4/ 39%
Máximo	686.28	1079.08	1289.28	288.6/ 43%	442.42/ 43%	502.82/ 46%
Média	609.61	598.76	862.98	257.2/ 42%	246.79/ 41%	354.87/ 41%
Erro padrão	24.28	70.89	87.83	9.83/ 0.22	29.22/ 0.32	34.84/ 0.77
Desvio padrão	72.84	212.68	263.5	29.5/ 0.66	87.67/ 0.97	104.52/ 2.33
Valor de Referência	377 a 500 g/m² *			370 a 702 g/m² e 40%**		

*Protolongo e Kandus (2005); ** Means et al, 2016; Sifleet et al, 2011.

O teor de carbono orgânico na biomassa seca apresentou valores em torno de 40%, tendo a maior variação para as coletas realizadas na primavera (de 39% a 46%).

Estudos sobre biomassa acima e baixo do solo e produtividade primária de áreas úmidas são mais facilmente encontrados a partir da década de 1970. No entanto, dados sobre o teor de carbono da biomassa vegetal são escassos (SIFLEET et al., 2011).

Nas pesquisas sobre este temática prevalece o método de combustão de amostras de biomassa seca para estimativa de carbono orgânico. Os valores de teor de carbono orgânico encontrados para espécies emergentes de áreas úmidas são equilibrados a 40% do peso da biomassa seca (FERREIRA, 2005; SIFLEET et al., 2011; MEANS, 2016).

Como o carbono fixado corresponde a aproximadamente 40% do peso de biomassa seca, era esperada que a distribuição dos valores médios entre estas duas variáveis fossem semelhantes. Igualmente, os valores máximos e mínimos ocorreram nas coletas de primavera e inverno, respectivamente. O maior valor médio observado de carbono orgânico foi de $354.87\text{g/m}^2 \pm 34.84$ e ocorreu nas coletas realizadas na estação de primavera. O menor valor médio foi 246.79 ± 29.22 e ocorreu nas coletas realizadas na estação de inverno.

Os valores médios de biomassa e carbono entre verão e inverno foram próximos, porém no período do verão distribuíram-se de forma simétrica, dentro de um intervalo de menor amplitude. No inverno apresentaram maiores desvios em relação à média do que no verão. Nas duas estações foram observados valores extremos. As maiores médias e maiores desvios nas variáveis ocorreram na primavera, com valores distribuídos em um intervalo de maior amplitude, sem presença de valores extremos, Figura 18.

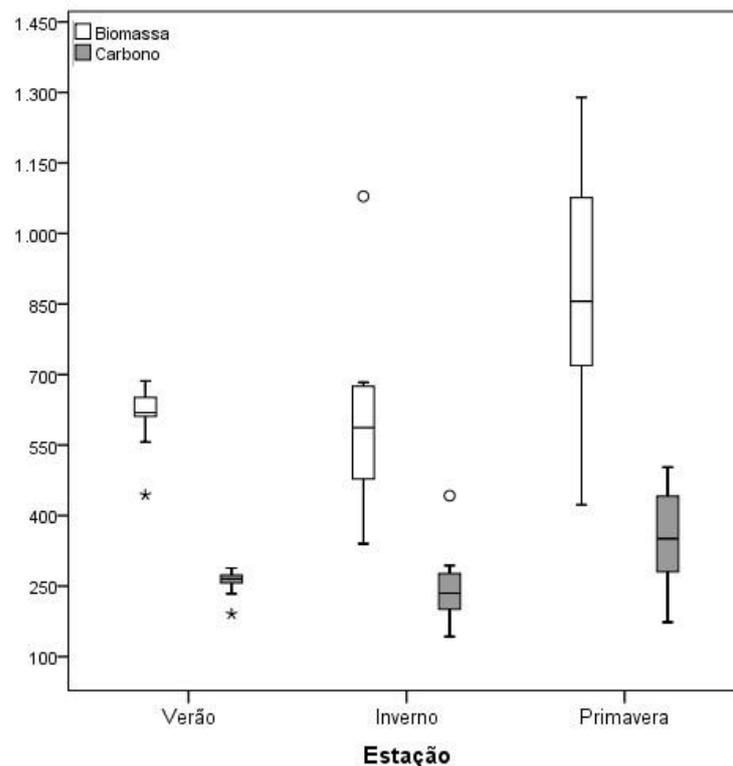


Figura 18. *Boxplot* das variáveis biofísicas. Fonte: Autora

A importância do teste de homogeneidade de variâncias em muitas áreas da experimentação é baseada na premissa de que muitos testes de hipóteses sobre médias ou efeitos de tratamentos são realizados pressupondo que as variâncias das

populações amostradas sejam iguais. A violação dessa hipótese pode afetar o desempenho do método e comprometer os resultados de diferentes formas. (NOGUEIRA; PEREIRA, 2013).

O teste de homogeneidade de variâncias (Teste de *Levene*) não foi significativo entre as estações (df 2, F 3,28, $p > 0,005$), ou seja, não foram observadas diferenças significativas nas variâncias dos valores de biomassa e carbono coletados entre as diferentes datas de amostragem. No entanto, através da Análise de Variância (ONEWAY) a média de ambas variáveis biofísicas diferiram consideravelmente entre as estações, $p < 0,005$.

Pelo Teste de Comparações Múltiplas de Tukey, verificou-se que a biomassa seca média da primavera diferiu significativamente da média do inverno ($p = 0,02$) e da média do verão ($p = 0,03$). Os valores médios de carbono orgânico mostraram diferença significativa apenas entre a estação de primavera e verão ($p = 0,03$).

Durante os três trabalhos de campo não foram observados períodos preferenciais de senescência ou mudança no crescimento (altura) das plantas. Porém notou-se a existência de novas folhas em maior quantidade no último trabalho de campo, que ocorreu na estação da primavera. Também não foi observado desenvolvimento de floração. Sobre isso, Protolongo et al. (2005) igualmente observaram a partir de coletas em área de *S.giganteus* uma elevada rotatividade foliar, com novas folhas verdes aparecendo mesmo durante os meses de inverno.

Protolongo e Kandus (2005) também não verificaram uma tendência estacional de senescência ou incremento de biomassa, mas verificaram crescimento foliar ao longo de todo o período da pesquisa (ciclo de um ano). Constataram maiores aumentos diários de biomassa no final de fevereiro, no fim do período de floração, e que o desenvolvimento máximo das estruturas florais ocorreu no mês de dezembro.

O estudo de Protolongo e Kandus (2005) também visou avaliar a produtividade primária da espécie, o que possibilitou o acompanhamento de todo seu ciclo. As autoras concluem que é possível que a dinâmica da biomassa nestes ambientes esteja regulada pelos movimentos de flutuação da água mais do que por fenômenos estacionais de crescimento ou senescência, pois relatam que os maiores valores de amostrados, ocorreram após uma forte ventania, que gerou movimentos com alta energia nas águas do rio Paraná.

Essa compatibilidade permitiu que esse estudo fosse utilizado como referência para esta pesquisa. Cabe destacar, entretanto, que nos períodos indicados pelas autoras, como de máxima floração e de aumento de biomassa, não houve expedições para coletas no Banhado Grande, impossibilitando verificar que o mesmo comportamento da vegetação possa ter ocorrido.

Como mencionado no referencial teórico, o regime hidrológico é um dos fatores mais importantes para as macrófitas, pois provoca alterações diretamente na biomassa, entre outros fatores. Os pulsos de inundação trazem em si o aporte de sedimentos e nutrientes que influenciam o acúmulo de biomassa pelas macrófitas.

Barbosa (2006) também menciona que para avaliar biomassa de plantas de áreas periodicamente inundadas da região amazônica, a diferença na quantificação de biomassa encontrada para uma mesma espécie em estudo deve levar em consideração as diferenças da cota de água nos diferentes períodos de coleta.

O nível do rio nas datas das coletas foi respectivamente: 1,10 cm em março; 1,62 cm em agosto e 1,30 cm novembro. É importante destacar que a área das coletas não estava inundada em nenhuma das datas de amostragem. A precipitação acumulada verificada para 60, 30, 20 e 5 dias anteriores as datas das coletas de vegetação é apresentada na Figura 19.

No mês de março ocorreu maior precipitação acumulada em 20 e 30 dias (respectivamente 70 mm e 123,4 mm), seguido do mês de novembro (116,6 mm). As maiores precipitações acumuladas para 5 e 60 dias anteriores as coletas ocorreram para o mês de novembro, coincidindo com os maiores valores coletados de biomassa.

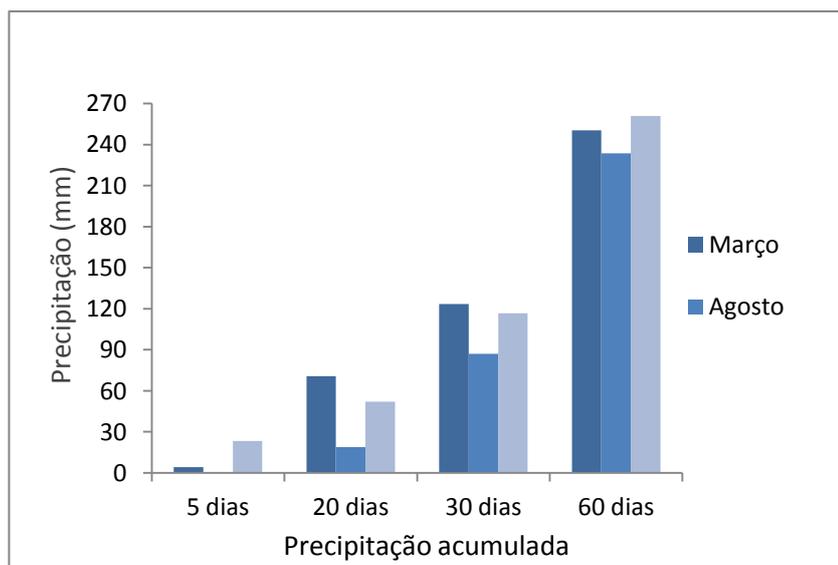


Figura 19. Precipitação acumulada para 5, 20, 30 e 60 dias anteriores as datas das coletas de vegetação. Fonte: Autora

Simioni et al. (2017) caracterizou os padrões de variação do nível da água das Áreas Úmidas e da precipitação na Área de Proteção Ambiental do Banhado Grande a partir de uma série de dados de 41 anos. Concluiu que entre os meses de junho e novembro ocorre maior possibilidade de ocorrência de pulsos de inundação e as maiores precipitações. No mês de julho ocorre a maior média de precipitação com localização bem marcada sobre o Banhado Grande.

Outro fator que pode colaborar no incremento de biomassa nas coletas do mês de novembro é relacionado ao carreamento de nutrientes presentes nos fertilizantes usados na orizicultura. Além disso, o aporte de sedimentos oriundos do preparo do solo para o plantio de arroz que, segundo Conab (2019), no Rio Grande do Sul ocorre de setembro a dezembro. Identificações recorrentes de alteração da qualidade da água do rio Gravataí foram verificadas no mês de outubro, nos anos de 2013, 2014 e 2016 (BELLOLI, 2017) relacionados aos resíduos das lavouras de arroz.

Segundo Biudes e Camargo (2008), a presença da cultura do arroz e dos insumos agrícolas utilizados para a contribuição do processo de produção primária do arroz pode interferir, significativamente, na presença e até na diversidade dos padrões mistos de macrófitas aquáticas. Pesquisas apontam que fatores químicos podem influenciar o acúmulo de biomassa pelas macrófitas e que a produtividade total pode ser aumentada pela adição de nitrogênio ao meio ambiente (MITSCH et al., 1994; ENNABILI et al., 1998).

Chagas (2010) verificou os estoques de carbono na macrófita aquática *Typha domingensis* em um estande alagado próximo a lagoa do Campelo e nas lagoas costeiras do PARNA de Jurubatiba/RJ. O maior valor obtido para as folhas de *T. domingensis* foi $2.757,1\text{g/m}^2 \pm 192,6$ no período seco, porém, o estoque total de carbono (soma das folhas, rizoma, raiz e detritos) foi significativamente maior no período chuvoso $5.316,8\text{g/m}^2 \pm 332,6$. O volume total estimado para o alagado no período seco foi de 23.177 m^3 e no período chuvoso 61.548 m^3 .

A *T. domingensis* possui mais de 1m de altura, porém sua densidade e biomassa é maior que a da *S.gigantes*. O valor de carbono bem mais alto que o verificado para *S.giganteus* também pode se dever pela diferença na metodologia, pois Chagas utilizou um Analisador de elementos CHNS/O Perkin Elmer (2400 Series II) e o valor da biomassa total da macrófita (g PS.m^2) foi utilizado para estimar o estoque de carbono no banco da macrófita.

4.2 DELIMITAÇÃO DA ÁREA DE OCUPAÇÃO DA ESPÉCIE E ESTIMATIVA DAS VARIÁVEIS BIOFÍSICAS

A delimitação da área de ocupação das macrófitas na região de estudo permite determinar os estoques de biomassa e nutrientes e inferir sobre o potencial da planta como estocadora de nutrientes (POMPÊO *et al.*, 1999). Para Barbosa (2006) o entendimento de variáveis que compõem os ciclos biogeoquímicos também requer estimativas de área da cobertura atual no terreno. Assim, foi delimitada a área de ocupação da espécie *S.giganteus* a partir de uma classificação de uso e cobertura no Banhado Grande com uso de Análise de Imagens Baseada em Objetos Geográficos (GEOBIA) e mineração de dados.

As maiores acurácias foram obtidas para segmentações com limiares de similaridades iguais a 0.1 e 0.2. As classes de vegetação contidas no banhado apresentam alta variabilidade espectral, conseqüentemente, os objetos geográficos gerados para os maiores valores de similaridades agregaram diferentes classes, dificultando sua discriminação e resultando em classificações menos acuradas. Para o parâmetro NMP foram obtidas altas acurácias para os três valores avaliados (200, 400 e 600 pixels), inferindo que os objetos geográficos com tamanhos menores que 600 pixels possibilitaram a discriminação das classes.

Avaliar os parâmetros da segmentação propicia uma seleção mais adequada de seus valores, evitando a utilização de uma subsegmentação ou de uma supersegmentação. Neste estudo, o melhor caso das segmentações foi obtido com limiar de similaridade igual a 0.2 e com NMP igual a 600 pixels.

As menores acurácias foram obtidas para os parâmetros árvores e profundidade máxima iguais a 5, retornando valores de Índice de Proporção Correta (PC) menores que 72,0%. Aumentando os valores dos parâmetros há um acréscimo das acurácias, obtendo a maior acurácia para o número de árvores igual 35 e a profundidade máxima igual a 50, resultando em um PC igual a 91,3%.

A discriminação de classes com alta mistura espectral, característico de áreas úmidas, demandam modelos mais complexos. RF aumenta sua complexidade com o aumento dos valores dos parâmetros número de árvores e profundidade máxima. Esse pode ser o motivo pelas menores acurácias resultarem dos menores valores dos parâmetros.

RF possibilita o cálculo das importâncias das características para um determinado modelo. Para o melhor caso do método *Random Forest* (número de

árvores = 35 e profundidade máxima = 50), considerando as bandas ópticas, as maiores importâncias foram obtidas para as médias das bandas: azul, verde, vermelho, borda vermelha e uma banda do infravermelho de ondas longas (B2M, B3M, B4M, B5M e B11M), obtendo os seguintes valores 4.3%, 6.6%, 5.3%, 6.3% e 6.2%, respectivamente. As médias das bandas RAS obtiveram as duas maiores importâncias das características resultando em uma importância de 9.7% para VHM e de 8.9% para VVM.

Amani et al. (2017) verificaram que as maiores diferenças das reflectância com imagens Sentinel-2A em áreas de *marshes* estão nas bandas 4 (vermelha) e 8A (borda vermelha), sendo estas as mais indicadas para o delineamento deste tipo de área úmida. Imagens com bandas no infravermelho de ondas longas são sensíveis à umidade na vegetação e aos solos, contribuindo na discriminação de espécies vegetais das AUs (BAJGAIN et al., 2015; MOBASHERI; AMANI, 2016; AMANI et al., 2018). Henderson e Lewis (2008) verificaram que ondas de polarização cruzada são mais apropriadas para distinção entre tipos de AUs, consonante a maior importância verificada neste estudo para a polarização cruzada VH da imagem RAS.

Aplicando uma classificação baseada em objetos com as característica ópticas mais importantes (B2M, B3M, B4M, B5M, B11M), por meio do melhor caso do método *Random Forest* (Número de árvores = 35 e profundidade máxima = 50) e da segmentação (limiar de similaridade = 0.2 e NMP = 600 pixels), foi obtida uma acurácia de 86,2%. Quando inseridos as características RAS mais importantes, VVM e VHM, a acurácia aumentou para 91,3%. Quando utilizados as características ópticas e RAS, a acurácia se aproximou ao melhor caso de classificação deste trabalho.

Para construir uma árvore de decisão são selecionados vetores de características que minimizam as impurezas dos nós, ou seja, intervalos de valores específicos do vetor de características que melhor discriminam as classes. Isso pode explicar as importâncias obtidas para as características B2M, B3M, B4M, B5M, B11M, VVM e VHM, e alta acurácia alcançada na classificação baseada em objetos por meio delas (CP=91,3%).

Verificou-se a influência da resolução espectral na classificação baseada em objetos por RF, sendo que as bandas ópticas 2, 3, 4, 5 e 11 apresentaram as maiores importâncias na classificação, mesmo possuindo diferentes resoluções espaciais. A resolução espacial não se mostrou relevante para a classificação, pois as maiores

importâncias foram encontradas tanto em bandas com 10 m, como também com 20 m de resolução espacial.

Na classificação baseada em objetos pelo método RF, Figura 20, observa-se na área central do Banhado a presença de macrófitas emergentes e flutuantes. Nas áreas de borda do banhado, verifica-se a presença de campos úmidos e de lavouras de arroz e soja. Observa-se, principalmente, nos limites norte e leste a pressão das áreas agrícolas sobre as áreas de banhado (GUASSELLI et al., 2015; BELOLLI, 2017).

A segmentação utilizada para a classificação retornou 23250 objetos geográficos, com uma área média de 2578 m² e mediana de 201 m². Uma redução de aproximadamente 99% no campo de análise quando comparado com o número de pixels da imagem (1617 x 1383 pixels). A combinação de GEOBIA e RF possibilitou a discriminação de objetos geográficos isolados, como os objetos da classe Emergentes contidos na classe Macrófitas flutuantes.

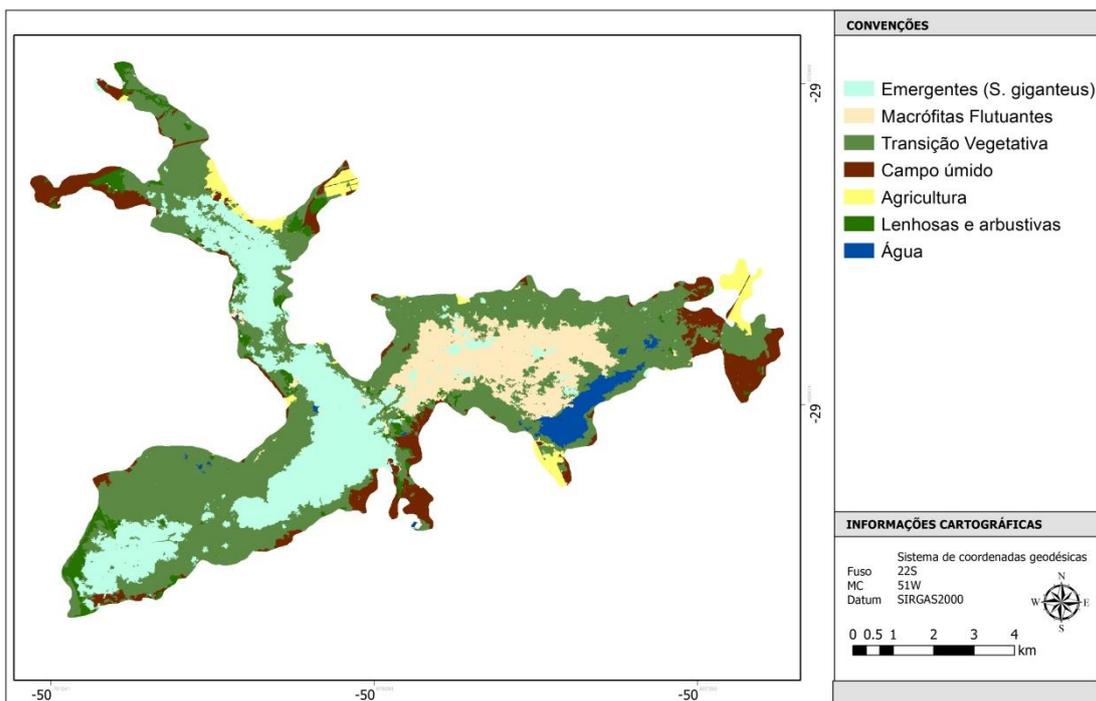


Figura 20. Classificação baseada em objetos no Banhado Grande. Fonte: Autora

A Tabela 7 mostra a matriz de confusão da classificação com as amostras de validação e a área de ocupação de cada classe. No total foram utilizadas 132 amostras de validação. A reduzida quantidade de amostras está relacionada com a

dificuldade de obtenção de dados *in situ*, devido a impossibilidade de acesso ao interior do banhado.

A classe de agricultura (AGR) foi confundida com Campo úmido (CA), apresentando uma PA de apenas 38%. No mês de fevereiro às áreas de arroz e de soja estão em estágio de colheita, assemelhando-se à classe CA.

Tabela 7. Matriz de confusão

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

AGRI: agricultura; CA: campo úmido; EM: emergentes; TV: transição vegetativa; LA: lenhosa arbustiva; AGU: água; AU: Acurácia do Usuário; AP: Acurácia do Produtor.

Para a classe CA as maiores confusões foram identificadas com a classe TV, resultando em um AP igual a 76%. CA apresenta diferentes espécies de vegetação e variações no teor de umidade, o que causa confusão com as demais classes.

A classe Emergentes (EM) apresentou resultados mais satisfatórios, alcançando AP de 91%, com alguns equívocos em relação à classe TV. A EM é a segunda classe mais representativa em área no banhado (25,3%), portanto foram obtidas um maior número de amostras de treinamento e conseqüentemente, obtendo maiores acertos. O mesmo foi observado com a classe TV, das 48 amostras de validação, 90% foram classificadas corretamente. TV está localizada nas bordas do banhado, e apresenta uma composição de diferentes tipos e portes de vegetação, sendo a classe predominante em área (40,7%). Água (AGU) recebeu apenas 2 amostras de validação e resultou em AP de 100%. A classe MF ocorre no interior do banhado, composta por vegetação flutuante de difícil classificação, resultando em um valor de AP igual a 67%.

Cordeiro e Rossetti (2015) aplicaram GEOBIA e mineração de dados com imagens ópticas e RAS para classificar a vegetação no norte da Amazônia, obtendo

uma acurácia de 88%. Para Franklin e Ahmed (2017) a integração entre imagens RADARSAT (RAS) e Landsat 8 OLI (óptico) apresentou uma acurácia global de 86.1%, enquanto, ao adicionarem na segmentação dados morfométricos, chegou-se a uma acurácia de 91% para o classificador RF.

Grenier et al. (2008) aplicaram classificação baseada em objetos geográficos para mapear AUs, identificar classes e adicionar a elas uma descrição de seus componentes, como estrutura da vegetação, para atribuir posteriormente valores médios de carbono regional. Alcançaram acurácia global de 84% e concluíram que imagens Landsat-ETM combinadas com imagens RADARSAT-1 demonstraram sua capacidade de identificar adequadamente as AUs em termos de tipo e extensão, porém, imagens com resolução mais fina, como a SPOT facilitou a identificação de área de água aberta e difusas e os projetos de mapeamento podem ser otimizados, ajudando a validar os resultados.

A classificação gerada para o Banhado Grande foi utilizada para estimar os estoque de biomassa vegetal e carbono orgânico para a área da classe Emergente, com ocupação predominante da espécie *S. giganteus*. A classificação das imagens Sentinel resultou em uma área de ocupação da *S.giganteus* de 1.507 ha. Assim, em 2018 a área ocupada pela vegetação apresentava um estoque de biomassa e carbono orgânico aproximado, respectivamente, de 13.005 ton e 5.334 ton, considerando os valores unitários de 8,63 ton/ha e 3,54 ton/ha, respectivamente. Esses dados são referentes ao maior valor médio de biomassa seca e carbono orgânico, obtidos nas amostras coletadas na primavera, assumidos para a área da classe.

Valor semelhante de biomassa foi encontrado por Piedade et al. (1992, 1994) para *Echinochloa polystachya* na Amazônia central. Constataram que a biomassa acumulada chega a 8 ton/ha e essa produção é menor somente entre 1-3 meses por ano, durante a fase terrestre. Avaliando o potencial das plantas aquáticas emergentes como fontes de biomassa, Pratt et al. (1984) verificaram para *Scirpus fluviatilis* valores de biomassa seca entre 7,5 a 12,6 ton/ha em áreas naturais. Constataram que esta espécie foi a mais produtiva entre as cinco outras analisadas (*Spartina pectinata*, *Carex atherodes*, *Phragmites australis* e *Sparganium eurycarpum*).

Chaves (2010) também estimou o estoque total de carbono no banco de macrófitas de *T. domingensis* no RJ, multiplicando os valores médios em cada fração pelo valor da área total do banco. A fração folhas verdes não demonstrou diferenças entre os períodos hidrológicos seco e chuvoso, ficando em 7.069 ton e 6.628 ton,

respectivamente, para a área de 3,9 ha.

Barbosa *et al.* (2008) utilizou classificação não supervisionada (método MAXVER) para mapear e classificar a área de vegetação herbácea na ilha da Marchantaria, várzea da Amazônia, e inferir sobre os estoques de biomassa e carbono orgânico a partir dos dados coletados *in situ*. Alcançou acurácia de 95% e estimou o estoque de 11.271 Mg de biomassa seca e 5.796,95 Mg de carbono orgânico para área da herbácea *Echinochloa polystachya* (1330,98 ha).

Vicari *et al.* (2011) analisou os efeitos de perda da reserva de carbono causado pela substituição de banhados de *S.giganteus* e *S. californicus* por reflorestamento de salicáceas, no baixo delta do rio Paraná, Argentina. Para tanto, mapeou a área ocupada pelas espécies, a partir de classificação não supervisionada, com o algoritmo ISODATA. Estimou biomassa acima do solo e matéria orgânica no solo para a área de cada um dos tipos de cobertura. Verificou que a perda de carbono orgânico no solo devido a troca de ecossistemas foi de 64,47 kg. Cabe destacar que o total de matéria orgânica no solo para área da espécie *S.giganteus* (634km²) foi de 95kg.

A partir destes estudos verifica-se que a extrapolação de dados biofísicos coletados *in situ* para área de cobertura vegetal verificada por mapeamentos acurados é uma alternativa viável quando não se tem acesso a uma quantidade maior de amostras que possibilitem estabelecer uma relação forte entre as variáveis biofísicas e medidas espectrais.

A seguir, apresenta-se o estudo das associações das variáveis biofísicas com os dados espectrais dos sensores Sentinel-2 e PlanetScope e suas estimativas por meio de análise de regressão.

4.3 COMPARAÇÃO DOS DADOS ESPECTRAIS DOS SENSORES E CORRELAÇÃO COM AS VARIÁVEIS BIOFÍSICAS.

Na Tabela 8 têm-se as estatísticas das vinte e sete medidas de reflectância verificadas nas parcelas, ao longo do ciclo anual, que descrevem as variações dos valores de reflectância das bandas e índices espectrais comuns aos dois sensores. As variáveis espectrais apresentaram comportamento bastante semelhante, pois os valores médios observados nos índices e bandas de um sensor foram muito próximos aos do outro.

Os valores médios observados no sensor Sentinel-2A foram levemente maiores que no Planet, assim como os valores de CV%, que apontam maior heterogeneidade nos valores espectrais deste sensor. O CV% mede a dispersão percentual dos dados em torno da média dos valores observados; é dado pela razão percentual entre o desvio padrão (DP) e a média.

Tabela 8. Estatísticas das variáveis espectrais nas parcelas em cada um dos sensores.

	PlanetScope				Sentinel 2-A			
	Max-min	Média	DP	CV%	Max-min	média	DP	CV%
Azul	0.03	0.06	0.01	12.01	0.04	0.04	0.01	25.63
Verde	0.02	0.07	0.01	9.35	0.03	0.07	0.01	13.60
Vermelho	0.03	0.07	0.01	12.24	0.07	0.07	0.02	29.93
NIR	0.19	0.29	0.05	18.58	0.24	0.31	0.05	16.63
NDVI	0.29	0.60	0.09	15.34	0.40	0.64	0.12	19.41
NDAVI	0.26	0.66	0.09	13.00	0.27	0.75	0.08	11.04
WAVI	0.04	0.98	0.13	13.00	0.41	1.13	0.12	11.04
SPRI	0.05	0.55	0.01	2.38	0.13	0.62	0.04	6.16
Co2Flux	0.18	0.33	0.06	17.04	0.32	0.32	0.09	26.88
Co2FluxNDAVI	0.17	0.36	0.05	14.85	0.26	0.47	0.08	16.90

* NIR: banda correspondente ao Infravermelho Próximo do espectro EM

O IV NDVI nos dois sensores mostrou-se ser mais sensível as variações de biomassa, com alcance respectivamente de 0,29 e 0,40 entre os valores máximos e mínimos, seguidos dos índices NDAVI no sensor PlanetScope e WAVi no sensor Sentinel-2.

Era esperado que a diferença entre as resoluções espaciais trouxesse maiores variações entre os dados dos sensores e também por disparidades inerentes às características de cada sensor e os possíveis efeitos ambientais durante a aquisição das cenas. Os valores espectrais próximos uns dos outros podem se dever a mesma

resolução radiométrica de aquisição e distribuição das cenas, aos números digitais estarem em um mesmo parâmetro físico e minimizados os efeitos geométricos e atmosféricos nas cenas.

Sobre isso, Curran e Hay (1986) colocam que a maioria dos erros nos dados obtidos de SR ópticos é removida ou atenuada pela transformação radiométrica das cenas, pela correção atmosférica e eventualmente pela razão de bandas. Infelizmente, o erro referente à discretização do sinal permanece, porque é dependente do comprimento de onda, mas este tem pequena ordem de grandeza.

A matriz de correlação da Tabela 9 mostra o grau de associação entre as variáveis biofísicas observadas em campo e as variáveis espectrais nos dois sensores avaliados através do coeficiente de correlação de Pearson (r).

Conforme verificado na análise da matriz, as variáveis biofísicas apresentaram correlações fracas, médias e moderadas com as bandas espectrais.

Destaca-se na Tabela 9 que as variáveis biomassa e carbono foram fortemente correlacionadas ($r=0,99$), visto que a quantidade de carbono orgânico deriva de um valor proporcional do peso seco da biomassa. Isso refletiu na correlação semelhante para ambas as variáveis em relação as bandas e índices avaliados.

As bandas NIR e Azul do sensor Planet apresentaram, respectivamente, maior correlação moderada direta e inversa com a biomassa e o carbono vegetal ($r = 0,60$; $0,61$ e $r = -0,50$; $-0,51$). As bandas Verde e Vermelho apresentaram fraca correlação inversa.

Tabela 9 - Matriz de correlação entre as bandas espectrais e variáveis biofísicas em cada sensor. Em negrito, as mais altas correlações.

		Biom	Carb	Azul	Verde	Verm	NIR	RE5	RE6	RE7	RE8A	SWIR1	SWIR2
Planet Scope	Biom	1											
	Carb	0.99	1										
	Azul	-0.50	-0.51	1									
	Verde	-0.27	-0.28	0.90	1								
	Verm	-0.36	-0.35	0.93	0.97	1							
	NIR	0.60	0.61	0.76	-0.49	-0.55	1						
Sentinel 2-A	Azul	0.07	0.07	1									
	Verde	0.33	0.35	0.84	1								
	Verm	0.04	0.06	0.97	0.79	1							
	NIR	0.45	0.47	0.59	-0.12	-0.67	1						
	RE5	0.21	0.02	0.87	0.93	0.83	0.22	1					
	RE6	0.48	0.50	0.68	-0.24	-0.75	0.96	0.33	1				
	RE7	0.43	0.46	0.68	-0.24	-0.75	0.96	0.33	0.98	1			
	RE8A	0.46	0.48	0.68	-0.24	-0.74	0.95	0.35	0.98	0.98	1		
	SWIR1	0.42	0.41	0.72	0.80	0.61	0.01	0.76	0.16	0.16	-0.18	1	
SWIR2	0.22	0.19	0.86	0.78	0.78	0.33	0.78	0.47	0.47	-0.50	0.93	1	

*Biom: Biomassa seca; Carb: carbono orgânico; Verm: banda correspondente ao vermelho do espectro EM; NIR: banda correspondente ao Infravermelho próximo; RE: banda correspondente à faixa de borda vermelha; SWIR: banda correspondente ao Infravermelho de ondas curtas.

Entre as bandas espectrais do sensor Sentinel-2, as correspondentes à faixa de borda vermelha RE6 e RE8A apresentaram maior correlação com biomassa e carbono, ($r = 0,48$; $0,50$ e $r = 0,46$; $0,48$, respectivamente), seguidas das bandas NIR e RE7 com $r = 0,45$; $0,47$ e $r = 0,43$; $0,46$, respectivamente. Entre as bandas do espectro visível, apenas a banda verde apresentou correlação fraca com os dados, sendo a correlação com as demais inexpressivas. Destaca-se a banda SWIR 1 com correlação moderada. Não foram observadas correlações inversas.

Entre as bandas possíveis de comparação entre os sensores (visíveis e NIR), nota-se que as respostas entre as variáveis espectrais e as variáveis biofísicas na banda NIR foram próximas, na banda verde também próximas, porém inversas, e distintas nas bandas azul e vermelha. As bandas que melhor descreveram as variações das variáveis biofísicas em um sensor não foram as mesmas daquelas observadas no outro.

Embora as bandas de borda vermelha do sensor Sentinel-2A tenham se destacado nas análises, apresentando associação moderada entre as variáveis biofísicas e espectrais, as bandas NIR e Azul do sensor PlanetScope apresentaram

maior correlação moderada entre eles, demonstrando maior dependência e grau de associação entre os dados. Essa resposta repercutiu também em correlações mais altas nos índices de vegetação gerados a partir deste sensor.

A maior associação entre as bandas NIR e Azul do sensor PlanetScope refletem sua sensibilidade aos valores de biomassa da espécie. A relação moderada inversa com a banda Azul se deve a maior absorção da radiação pelos pigmentos nesta região do espectro, bem como na região do vermelho. A absorção da REM aumenta proporcionalmente com o aumento do conteúdo de clorofila (PONZONI; SHIMABUKURO; KUPLICH, 2012; MOREIRA, 2012) que é proporcional ao aumento da biomassa nesta região do espectro (SALES et al., 2011). Resposta espectral contrária ocorre na região do Infravermelho próximo, onde a reflectância aumenta com o aumento de biomassa.

Baloloy et al. (2018) avaliaram a eficiência das bandas multiespectrais e índices de vegetação derivadas dos sensores RapidEye, PlanetScope e Sentinel-2 na previsão de biomassa de mangue. Igualmente avaliou que a banda NIR é a faixa de previsão mais eficaz para os dados do sensor PlanetScope com os melhores valores de r e R^2 , respectivamente 0,70 e 0,49. Os menores valores também ocorreram para a banda verde (0,44 e 0,20, respectivamente).

Para os dados Sentinel, Baloloy et al. (2018) verificaram que maiores correlações com a biomassa de mangue foram obtidas com as bandas azul, vermelha e NIR ($r= 0,69$; $0,67$; e $0,66$, respectivamente) e menores correlações com SWIR 1, SWIR 2 e *Red edge* ($r=0,18$, $0,02$ e $0,62$, respectivamente). A baixa correlação com as bandas *red edge* e SWIR e a biomassa em mangue pode se dever ao tipo de vegetação e a proporção de inundação (TURPIE, 2013), pois Mutanga, Adam e Cho (2012) exploraram bandas *red edge* em índices espectrais sob vegetação emergente semelhante a *S.giganteus* e comprovaram sua eficiência para estimativa de biomassa em AUs, com R^2 de 0,76.

Sobre a correlação moderada com a banda SWIR e as variáveis biofísicas, Byrd et al. (2014) verificaram que as bandas de infravermelho de ondas curtas são benéficas para o mapeamento de biomassa da vegetação emergente *Typha latifolia* e *Schoenoplectus acutus* com base em seus altos valores de carga nos modelos de espectrômetro de campo Hyperion e Landsat 7.

Quanto a correlação das bandas espectrais com conteúdo de carbono orgânico, a correlação moderada inversa da banda azul com carbono no sensor Planet

($r=-0,50$) demonstra a região de absorção dos pigmentos carotenóides e xantofila que indicam a eficiência do uso da luz fotossintética ou da taxa de dióxido de carbono utilizada e armazenada pela vegetação (GAMON et al., 1992; RAHMAN et al, 2000).

A correlação com as bandas verde e borda vermelha no sensor Sentinel-2 refletem o conteúdo de clorofila relacionado ao vigor da vegetação fotossinteticamente ativa (CLEVERS; KOOISTRA, 2012; CLEVERS; GITELSON, 2013).

Schile et al. (2013) estimaram a fração de radiação fotossinteticamente ativa absorvida (f APAR), um parâmetro-chave para modelar a produtividade primária bruta (GPP), em uma área úmida restaurada a partir de imagens World View. O índice TBVI incorporando faixas simuladas de verde e infravermelho próximo correlacionou-se significativamente com f APAR (R^2 0,45), podendo ser aplicado para estimativas de produtividade e potencial de fixação de carbono.

Ambos os sensores apresentaram correlação positiva moderada nas bandas NIR que refletem a biomassa da estrutura foliar na área imageada e, conseqüentemente, o potencial de fixação de carbono.

Na Tabela 10 é apresentada a matriz de correlação entre os índices espectrais e variáveis biofísicas em cada sensor. No sensor PlanetScope o índice espectral sPRI obteve o maior r encontrado para a biomassa e carbono (0,66 e 0,68, respectivamente), seguido do CO_2 fluxNDAVI (0,61; 0,62). As correlações também foram moderadas e os valores de r tiveram pouca variação entre os índices.

Tabela 10. Matriz de correlação entre os índices de vegetação e variáveis biofísicas em cada sensor. Em negrito, as mais altas correlações.

		Biom	Carb	NDVI	NDAVI	WAVI	SPRI	CO ₂ Flux	CO ₂ flux NDAVI
Planet Scope	Biom	1							
	Carb	0.99	1						
	NDVI	0.55	0.55	1					
	NDAVI	0.57	0.58	0.99	1				
	WAVI	0.57	0.58	0.99	1.00	1			
	SPRI	0.66	0.68	0.69	0.76	0.76	1		
	CO ₂ Flux	0.59	0.59	0.99	1.00	1.00	0.77	1	
	CO ₂ Flux NDAVI	0.61	0.62	0.97	0.99	0.99	0.83	0.99	1
Sentinel- 2A	NDVI	0.24	0.26	1					
	NDAVI	0.25	0.28	0.99	1				
	WAVI	0.25	0.28	0.99	1	1			
	SPRI	0.19	0.22	0.94	0.97	0.97	1		
	CO ₂ Flux	0.66	0.65	0.16	0.10	0.10	-0.04	1	
	CO ₂ Flux NDAVI	0.30	0.33	0.83	0.86	0.86	0.83	0.15	1

No sensor Sentinel apenas o índice CO₂flux obteve correlação moderada com as variáveis biofísicas ($r=0,66$; $0,65$), seguido do índice CO₂fluxNDAVI com fraca correlação ($r= 0,30$; $0,33$). As correlações com os demais índices obtiveram valor de r muito fracos, menores que $0,30$.

Nos dois sensores, os índices NDAVI e WAVI apresentaram correlação ligeiramente maiores do que NDVI com as variáveis biofísicas. Este resultado vai ao encontro do aferido por Villa et al. (2014), ao verificar que NDAVI e WAVI foram melhores que os IVs “terrestres” na diferenciação de vegetação de AUs, além de corroborar com a hipótese do autor, de que o NDAVI pode ser associado com dados biofísicos da vegetação e utilizado para monitorar sua dinâmica. Além disso, a substituição do NDVI pelo índice NDAVI na formulação do índice CO₂flux, resultando no índice CO₂fluxNDAVI, também obteve correlação ligeiramente maior para os dados do sensor PlanetScope.

Byrd et al. (2014) coloca que o NDVI pode não obter os melhores resultados para inferência de biomassa devido a saturação com alta densidade desta, que vai depender das espécies de vegetação e tipos de dossel. Assim, o NDVI pode não

estimar bem a biomassa a 100% de cobertura, que é uma característica comum das AUs de marismas, por exemplo.

Destaca-se as correlações mais altas dos índices sPRI e CO₂flux com conteúdo de carbono orgânico. O índice sPRI, derivado da razão das bandas verde e azul obteve a maior correlação com conteúdo de carbono orgânico neste estudo. Este resultado corrobora com os achados de Rahman et al. (2000), que verificou forte coeficiente de determinação ($r^2=0,78$) entre o sPRI e dados de fluxo de carbono de torre, indicando um potencial considerável para mapear fluxos fotossintéticos em grandes paisagens.

Leite (2015) investigou a capacidade de armazenamento de carbono na vegetação constituinte da *wetland* do afluente Riacho Fundo, em Brasília, aplicando o índice CO₂flux em imagens geradas por um sensor Multispectral Scanner (MSS). Após classificar a imagem resultante em intervalos, o autor verificou as regiões de maior fluxo de CO₂. Concluiu que a vegetação da *wetland* possui um índice de sequestro de carbono superior aos outros alvos terrestres presentes.

Ferreira (2015) estimou o fluxo de CO₂ na fase rio e no entorno do reservatório da represa UHE Serra do Facão, em Minas Gerais e Goiás, aplicando o CO₂flux em imagens Landsat TM e OLI em análise temporal entre os anos de 2009 a 2014. Concluiu que as áreas com maior atividade vegetativa mostraram os valores mais elevados de fluxo de CO₂. Concluiu também que o método de determinação do fluxo de CO₂ utilizando imagens orbitais constitui uma forma de mensuração indireta que permite estimar o comportamento do gás no processo de fotossíntese da planta, sem a necessidade de derrubada de árvores como amostras para obtenção de dados.

Adicionalmente foram verificadas as correlações das variáveis biofísicas com formulações de IVs que incorporam as bandas de borda vermelha do sensor Sentinel-2A, Tabela 11. Os índices de borda vermelha apresentaram correlações fracas com as variáveis de biomassa e carbono, destacando-se o NDRE4 ($r= 0,30$; $0,32$, respectivamente) e o NDRE1.

Tabela 11. Matriz de correlação entre os índices espectrais de borda vermelha e variáveis biofísicas. Em negrito, a mais alta correlação.

	Biom	Carb	NDRE1	NDRE2	NDRE3	NDRE4
NDRE1	0.29	0.30	1			
NDRE2	0.27	0.29	0.99	1		
NDRE3	0.13	0.15	0.92	0.92	1	
NDRE4	0.30	0.32	0.98	0.98	0.92	1.00

A maior correlação se deu para o índice NDRE4, formulado com a banda de borda RE5 e NIR. Os índices formulados apenas com bandas de borda vermelha não alcançaram correlação significativa. Entre os trabalhos realizados em AUs que testam as bandas de borda vermelha para estimativa de parâmetros biofísicos, Mutanga, Adam e Cho (2012) alcançaram um r^2 de 0,79 para o NDVI com as bandas NIR1 e *Red edge* (405 a 745 nm) do Sensor World View para a estimativa de biomassa de *Cyperus papyrus*, espécie emergente.

Baloloy et al. (2018) verificou o potencial preditivo dos índices *Red edge* Simple Ratio (SRre), compostos com as bandas NIR e de borda dos sensores Sentinel e RapdEye para estimar biomassa de mangue na província de Zambales, Filipinas. Encontrou valores de $r = 0,71$ para SRre Rapdeye e 0,62 para SRre Sentinel, sendo que o modelo de regressão composto com SRre Sentinel foi o segundo melhor para a estimativa de biomassa de mangue, $R^2=0,89$.

Esperava-se encontrar maior correlação do conjunto dos NDREs gerados com as variáveis biofísicas, visto que são verificadas boas correlações e potencial desses índices como variáveis predictoras para biomassa de AUs, biomassa em pastagem (GUERINE FILHO, 2018) e índice de área foliar em diferentes cultivos (XIE et al., 2018; DELEGIDO et al., 2012).

Turpie (2013) verificou mudança na posição da banda de borda vermelha com o aumento da inundação em um experimento na AU do *National Wildlife Refuge*, o que poderia reduzir a eficácia dos índices NDRE em aplicações de sensoriamento remoto. Entretanto, não foram usadas imagens com presença de inundação neste estudo, tão pouco com altos índices pluviométricos próximos a data de captura da cena.

Mutanga e Skidmore (2004) colocam que a estrutura vertical da vegetação emergente contribui para altas taxas fotossintéticas aumentando a penetração da luz dentro dos dosséis. Todavia, a morfologia vertical do caule também aumenta a

dispersão e absorção de luz nos espaços entre a vegetação, levando a uma menor refletância geral da copa.

4.4 ANÁLISE DOS MODELOS DE REGRESSÃO PARA ESTIMATIVA DAS VARIÁVEIS BIOFÍSICAS

Observando a existência de correlação entre as variáveis obtidas por sensoriamento remoto com biomassa e carbono orgânico da vegetação, realizaram-se posteriormente as análises de regressão pelo método hierárquico com entrada em blocos. Os diferentes índices e bandas espectrais em cada um dos sensores foram testados para estimar as variáveis biofísicas mediante análise de regressão linear.

O método hierárquico gera diferentes modelos com adição de diferentes variáveis preditoras (índices e bandas) e seus respectivos R^2_{aj} , EQM e valor de significância para ANOVA e teste t, dentro outros coeficientes utilizados para verificar os pressupostos das regressões, citados na metodologia desta pesquisa. O p-valor abaixo de 0,005 para ANOVA significa que incluir esses previsores melhorou a qualidade do modelo. Na Tabela 12 são apresentadas as equações obtidas para cada sensor seguidas de seus coeficientes.

Tabela 12. Equações de regressão. Em negrito os coeficientes com melhores ajustes.

	Var. Biofísica	Equação	R ²	R ² _{aj}	EQM *	p-valor**
Planet Scope	Biomassa (g/m ²)	=4896,287 + 10168,022 * SPRI	0.44	0.42	157,10	0,000
	Carbono (g/m ²)	=2030,075+4217,391*SPRI	0.46	0.44	62.77	0,000
Sentinel -2A	Biomassa (g/m ²)	=78,034+1409,939*CO2flux+ 1212,366*RE6	0.46	0.41	166.73	0,001
	Carbono (g/m ²)	=29,054+536,955*CO2flux+ 550,291*RE6	0.45	0.40	67.47	0,001

* EQM em g/m²; **p-valor significativo (p<0,005, IC 95%).

A equação de regressão mostrou a relação existente entre as variáveis e, posteriormente, quando aplicada sobre as imagens, possibilitou estimar a quantidade de biomassa aérea e carbono orgânico da *S.giganteus* a partir das imagens ópticas.

Foram comparados o desempenho das regressões na predição de biomassa e carbono orgânico, Tabelas 11 e 13. As regressões simples geradas com dados PlanetScope produziram um erro médio quadrático de predição de 157,10 g/m²

(23,8% da biomassa média observada) e 62,77 g/m² (23% do carbono médio observado) em comparação com a regressão linear múltipla gerada a partir dos dados Sentinel-2 que produziram um EQM de 166,73 g/m² (25,3% da biomassa média observada) e 67,47 g/m² (24,6% do carbono médio observado).

Mesmo com baixos valores de R² e R²_{aj}, as variáveis biofísicas foram estimadas para *S.gigantes* no Banhado Grande. Na Tabela 13 são apresentadas as estimativas geradas a partir das regressões lineares e os valores observados em campo.

Tabela 13. Estimativas das variáveis biofísicas em g/m², geradas a partir das regressões lineares vs valores observados *in situ*.

	PlanetScope		Sentinel-2A		V. Observado	
	Biomassa	Carbono	Biomassa	Carbono	Biomassa	Carbono
Min	421.81	175.71	525.43	220.10	340.24	142.9
Max	886.39	368.41	1055.41	427.90	1289.28	502.82
Max-min	464.58	192.70	529.98	207.80	949.04	359.92
Média	656.33	270.81	682.40	283.24	658.32	273.82
DP	136.28	56.52	145.24	57.44	201.35	81.81
CV%	20.70	20.64	21.28	20.28	30,58	29,87

Os valores médios estimados foram bem próximos dos valores observados, apresentando pouca diferença principalmente para as equações geradas a partir dos dados espectrais do sensor PlanetScope. Os valores mínimos e máximos foram respectivamente superestimados e subestimados por ambas as equações. Os valores de CV% e DP mostram que as variações nos dados estimados foram inferiores às variações observadas em campo. Estes, juntamente com a diferença entre os valores máximos e mínimos, apontam a tendência dos modelos em subestimar os valores de biomassa e carbono.

O modelo com melhor ajuste nas equações a partir do sensor PlanetScope ocorreu apenas com o índice sPRI como variável preditora, pois os modelos gerados com mais variáveis apresentaram valores mais baixos de R²_{aj} e maiores EQMs.

O contrário ocorreu para as equações geradas a partir do sensor Sentinel-2A onde, com a adição da banda de borda vermelha RE6 ao índice CO₂flux, ocorreu o aumento de R²_{aj} e menores EQMs. Como resultado foram obtidas respectivamente equações de regressão linear simples para o sensor PlanetScope e múltipla para o

sensor Sentinel-2A, sendo que as equações lineares simples apresentaram os melhores ajustes para a estimativa das variáveis biofísicas.

Na Figura 21 é apresentada a dispersão dos valores estimados vs os valores reais observados. O uso das equações de regressão simples e múltiplas forneceram uma previsão moderada para biomassa e carbono orgânico na espécie *S.gigantes*.

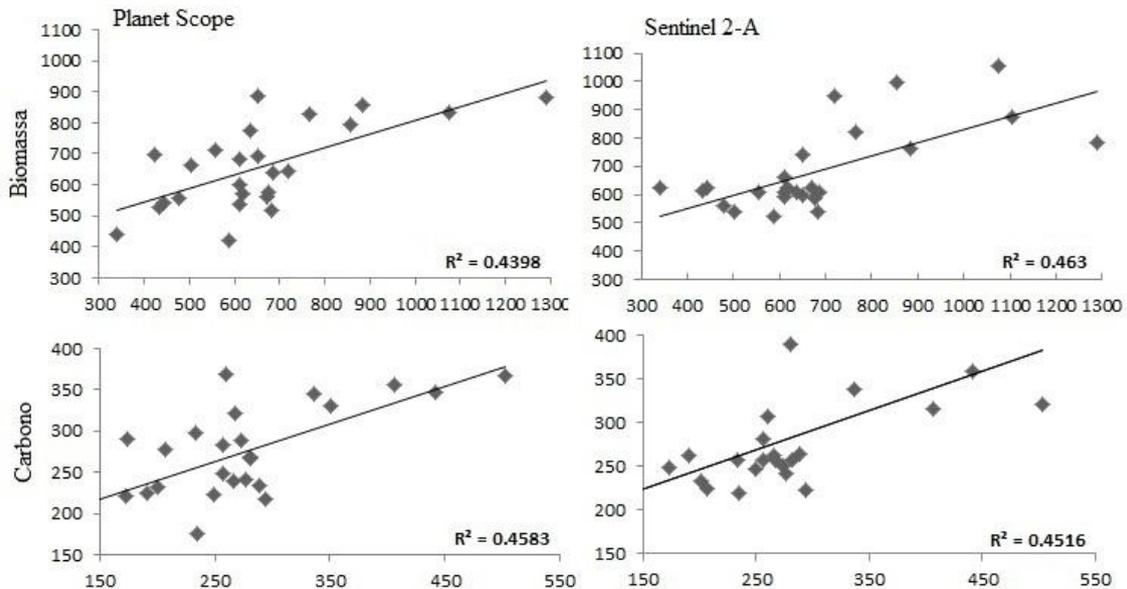


Figura 21. Dispersão dos valores estimados pelas equações vs observados em conjunto com a reta de regressão. Fonte: Autora

As duas variáveis que melhor se ajustaram ao modelo de predição no sensor Sentinel foram respectivamente o índice CO_2flux e a banda RE6, os mesmos que melhor se correlacionaram com as variáveis biofísicas. Mutanga, Adam e Cho (2012) verificaram que o melhor modelo de regressão múltipla *stepwise* para estimativa de biomassa ocorreu com um modelo combinado das bandas de borda vermelha (banda 6) e NIR1 do sensor World View. A banda 6 deste sensor possui faixa espectral de 705 nm a 745 nm, a mesma das bandas RE5 e RE6 do sensor Sentinel-2. O modelo dos autores produziu um R^2 de 0,69 e EQM de 546 g/ m², 16% da biomassa média observada. Em comparação, a regressão *Random Forest* produziu o mais alto R^2 (0.76) e o mais baixo EQM (441 g/m², 13% da biomassa média observada).

Baloloy et al. (2018) verificaram que a eficiência dos dados dos satélites PlanetScope e Sentinel-2 como preditores de biomassa são relativamente maiores com o uso de índices de vegetação. A regressão linear simples para as bandas

Sentinel-2 e PlanetScope gerou R^2 de 0,49, para os índices espectrais, o R^2 foi de 0,53 e 0,56, respectivamente. Assim como verificado nesta pesquisa, o mais alto R^2 (0,56) gerou o menor EQM (11,75 mg/ha) e ocorreu para a regressão linear do sensor PlanetScope a partir de um índice espectral. Maiores valores de R^2 para equações com índices de vegetação se devem ao seu potencial para destacar as propriedades intrínsecas da planta que estão bem relacionadas com o acúmulo de biomassa, como o esverdeado e o vigor das folhas (BALOLOY et al., 2018).

A partir dos valores de R^2_{aj} , pode-se dizer que os modelos gerados com o sensor PlanetScope tem contribuição e confiabilidade de 42% na predição de biomassa e 44% na predição de carbono orgânico e alcançou as maiores acurácias em relação ao sensor Sentinel-2 ao estimar estas variáveis para a espécie. Respectivamente, os modelos gerados a partir do sensor Sentinel-2A tem confiabilidade de 41% e 40% na previsão de biomassa e carbono orgânico da espécie *S.giganteus*.

Considerando a quantidade de amostras utilizadas e a variação dos erros em relação aos valores médios nas amostras de campo, os modelos forneceram estimativas relativamente acuradas das variáveis biofísicas.

5 CONCLUSÕES

Estimativas confiáveis de biomassa vegetal em AUs é um dos dados básicos necessários para a avaliação de estoques de carbono em estudos que visam monitoramento e conservação destes ambientes, diante dos impactos ambientais negativos e das mudanças climáticas. Adicionalmente, o conhecimento preciso da área de ocupação da AU usando sensoriamento remoto enfatiza os diferentes tipos de AUs e composições vegetais, o que permite a ampliação de medições de fixação e de fluxos de carbono feitas diretamente.

A partir da integração entre imagens ópticas do sensor Sentinel-2 e RAS do sensor Sentinel 1, aliada ao uso de GEOBIA e a técnica de mineração de dados *Random Forest*, foi possível classificar com precisão as classes de vegetação do BG, com interesse especial na delimitação da área ocupada pela espécie *Scirpus giganteus*, tendo esta apresentado maior acurácia de classificação (91%) em relação as demais classes.

As feições mais relevantes para o modelo de classificação entre as bandas ópticas foram obtidas para as médias das bandas: azul, verde, vermelho, borda vermelha 5 e SWIR1 do infravermelho de ondas longas. As imagens RAS apresentaram as maiores relevâncias na classificação, sendo que, as polarizações VH e VV obtiveram juntas 18.6% de relevância. O melhor caso das segmentações foi obtido com limiar de similaridade igual a 0.2 e com NMP igual a 600 pixels. A maior acurácia ocorreu para o número de árvores igual a 35 e profundidade máxima igual a 50, resultando em um PC igual a 91,3%.

A partir da classificação das imagens Sentinel foi obtida a área de ocupação da espécie *S.giganteus* no Banhado Grande, com aproximadamente 1.507 ha no ano de 2018. Considerando os valores amostrais observados e estimados para a área de 1ha, obteve-se um estoque de biomassa de aproximadamente 8,63 ton/ha e de 3,54 ton/ha de carbono orgânico. Considerando a área total delimitada da classe Emergente (1.507 ha), os estoques alcançam, respectivamente, 13.005 ton e 5.334 ton.

As relações entre as variáveis biofísicas e o conjunto de variáveis preditoras foram estabelecidas. Este estudo demonstrou a eficiência das bandas espectrais, índices de vegetação e variáveis biofísicas derivados de dois sensores relativamente novos e ainda pouco explorados dentro desta temática: Sentinel-2 e PlanetScope. Os

índices de vegetação foram mais correlacionados e preferíveis como variáveis preditoras para os modelos. As mais altas correlações foram obtidas com o IV sPRI para PlanetScope e com Co₂flux para Sentinel-2. A banda NIR apresentou maior correlação com as variáveis biofísicas para o Sensor PlanetScope, enquanto para o Sentinel-2 a maior correlação foi com a banda de borda vermelha RE6. Foram observadas correlações fracas entre os índices NDRE e as variáveis biofísicas. No entanto, a adição da banda de borda RE6 aumentou o R²ajs do modelo para o sensor Sentinel-2, demonstrando sua capacidade como indicador quantitativo das variáveis biofísicas.

Mesmo com menor número de bandas espectrais, comprovou-se a eficiência do sensor PlanetScope para predição das variáveis. O modelo que gerou a melhor estimativa das variáveis biofísicas a partir dos dados espectrais foi o ajustado com os dados PlanetScope e a partir de uma regressão linear simples, o que não é comum, visto que na maioria dos trabalhos os modelos de regressão múltiplos fornecem os menores erros.

Assim, o sensor com resolução espacial mais alta obteve maior contribuição na predição das variáveis biofísicas, gerando uma estimativa média de 656.33 g/m² de biomassa seca e de 270.81 g/m² de carbono orgânico para a espécie *Scirpus giganteus* no Banhado Grande, e um erro médio quadrático de predição de 157,10 g/m² (23,8% da biomassa média observada) e 62,77 g/m² (23% do carbono médio observado).

Destaca-se que as bandas verde, RE 5 e SWIR 1 do Sensor Sentinel-2 foram relevantes para a classificação GEOBIA e apresentaram correlação significativa com as variáveis biofísicas de biomassa e carbono. Comparando-se o método de delimitação da classe da espécie e estimativa das variáveis para a área da classe, com a estimativa a partir dos modelos de regressão, conclui-se que valores mais acurados são encontrados com a utilização dos modelos de regressão gerados. Também que os dois métodos utilizados são complementares, visto que se faz necessário o conhecimento sobre a delimitação, tanto em nível de espécie vegetal, quanto de área total do ecossistema de banhado, para uma espacialização e estimativa destas variáveis biofísicas a partir de imagens espectrais.

5.1 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

Considerando o tamanho do conjunto amostral e os erros de estimativa verificados, os resultados apresentaram estimativas relativamente acuradas de biomassa seca e carbono orgânico para a espécie e seus estoques totais relativos à sua área de ocupação.

Além de proverem estimativas atuais de estoque de carbono com relativa confiabilidade, o uso de dados ópticos e RAS se mostraram especialmente úteis para o monitoramento, verificação e inventário dos estoques de carbono, cruciais para projetos de compensação de emissões e crédito de carbono, semelhantes aos programas de REDD. Contribui também com o reconhecimento da função ambiental desta AU como ecossistema de Carbono azul.

Escassos estudos compararam o desempenho dos sensores Sentinel-2 e PlanetScope usando modelos de previsão desenvolvidos a partir dos mesmos dados de campo, com foco nas bandas comuns, índices e fatores biofísicos que podem ser derivados desses sistemas. Tratando-se de ecossistemas de banhado no RS, este trabalho é um dos pioneiros sobre predição de biomassa emergente e estoques de carbono a partir de dados espectrais. Desse modo, as constatações nas relações destas variáveis biofísicas e reflectância da cobertura vegetal nestes ecossistemas estão começando.

A melhoria do resultado com os modelos estatísticos baseados nos sensores também é recomendada, como a avaliação de outros índices de vegetação. Também é necessária uma grade amostral maior para possível melhora nas acurácias de predição e avaliação de *outliers*.

Para trabalhos futuros com classificação GEOBIA, sugere-se a utilização de imagens temporais, aplicação de outros métodos de mineração de dados, como as Redes Neurais Artificiais e *Support Vector Machine*, por exemplo, e também a inserção de outras camadas, como índices de vegetação, de solo e da água. Como complemento as estimativas a partir dos modelos de regressão, propõem-se a confecção de mapas a partir das equações que obtiveram os melhores resultados, e comparação destes com as estimativas realizadas a partir da área da classe Emergente, bem como avaliação de erros.

6 REFERÊNCIAS

ABDIKAN, S. F.; SANLI, B.; USTUNER, M.; CALÒ, F. Land Cover Mapping Using Sentinel 1 SAR Data. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. XXIII ISPRS Congress, Prague, Czech Republic, v. xli-b7, p. 757–761, 2016. doi:10.5194/isprsarchives-XLI-B7-757-2016.

ACCORDI, I. A.; HARTZ, S. M.; OHLWEILER, A. O sistema Banhado Grande como uma área úmida de importância internacional. In: II Simpósio de Áreas Protegidas - conservação no âmbito do Cone Sul. 2003. Pelotas. **Anais**. p. 56-63, 2003.

ADAM, E.; MUTANGA, O.; RUGEGE, D. “Multispectral and Hyperspectral Remote Sensing for Identification and Mapping of Wetland Vegetation: A Review.” *Wetlands Ecology and Management* 18 (3): 281–296. doi:10.1007/s11273-009-9169-z.

ALONG, D. M. Carbon sequestration in mangrove forests. **Carbon Management**, n. 3(3) 2012. 313–322.

AMANI, M.; SALEHI, B.; GRANGER, J. Spectral analysis of wetlands in newfoundland using sentinel 2a and landsat 8 imagery. in IGTF 2017, Baltimore, Maryland, USA.

AMANI, M.; SALEHI, B.; MAHDAVI, S.; BRISCO, B. Spectral Analysis of Wetlands Using Multi-Source Optical Satellite Imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 144, p. 119–136, 2018. doi:10.1016/j.isprsjprs.2018.07.005.

ARAGÃO, L. E. O. e C. de; SHIMABUKURO, Y. E. Perspectivas para o estudo da biogeoquímica do carbono em macro-escala integrando diferentes técnicas: modelagem ecológica, sensoriamento remoto e SIG. **Relatório Técnico**, INPE: São José dos Campos, 2004.

BALOLOY, B.; BLANCO, A. C.; CANDIDO, R. J. L. Estimation of mangrove forest aboveground biomass using multispectral bands vegetation indices and biophysical variables derived from optical satellite imagery RapidEye, PlanetScope and Sentinel-2. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume IV-3, 2018 ISPRS TC III Mid-term Symposium “Developments, Technologies and Applications in Remote Sensing”, 7–10 May, Beijing, China.

BAJGAIN, P.; ROUSE, M. N.; BULLI, S.; BHAVANI, T.. 2015. “Association Mapping of North American Spring Wheat Breeding Germplasm Reveals Loci Conferring Resistance to Ug99 and Other African Stem Rust Races.” **BMC Plant Biology** 15 (1). BioMed Central: 249. doi:10.1186/s12870-015-0628-9.

BAKER, C.; LAWRENCE, R.; MONTAGNE, C.; PATTEN, D. Mapping wetlands and riparian areas using Landsat ETM+imagery and decision-tree-based models. *Wetlands* **2006**, 26, 465–474.

BAPTISTA, G. M. M. Mapeamento do sequestro de carbono e de domos urbanos de CO₂ em ambientes tropicais, por meio de sensoriamento remoto hiperespectrais. **Geografia**, Rio Claro, v. 29, n. 2, 2004. 189-202.

BAPTISTA, G. M. M. Validação da Modelagem de sequestro de carbono para ambientes tropicais de cerrado, por meio de dados AVIRIS HYPERION. In: Simpósio Brasileiro de Sensoriamento Remoto, (SBSR), 2003, Belo Horizonte. **Anais...** Sao Jose dos Campos: INPE, 2003. p. 1037-1044.

BARBOSA, K. M. N. **Monitoramento Espacial de Biomassa e Carbono Orgânico da Vegetação Herbácea de Várzea na Amazônia Central**. 2006. 131 f. Tese. (Doutorado em Ciências florestais). Programa de Pós-Graduação em Engenharia Florestal, Universidade Federal do Paraná. Curitiba, 2006.

BARBOSA, K. M. N.; PIEDADE, M.T.F.; KIRCHNER, F.F. Estudo temporal da vegetação herbácea da várzea da Amazônia central. **Floresta**, Curitiba, PR, v. 38, n. 1, jan./mar. 2008.

BARNES, E.M., CLARKE, T.R., RICHARDS, S.E., COLAIZZI, P.D., HABERLAND, J. Random forest in remote sensing: A review of applications and future directions. *ISPRS J. Photogramm. Remote Sens.* **2016**, 114, 24–31.

BELLOLI, T. F. **Impactos ambientais decorrentes da produção orizícola, Área de Proteção Ambiental do Banhado Grande - RS**. 2016. 80 f. Monografia (Trabalho de Conclusão de Curso). Instituto de Geociências. Curso de Bacharelado em Geografia. Universidade Federal do Rio Grande do Sul, 2016.

BERHANE, T. M.; CHARLES, R. L.; WU, Q.; BRADLEY, C. Autrey 2, LIU, H. Decision-Tree, Rule-Based, and Random Forest Classification of High-Resolution Multispectral Imagery for Wetland Mapping and Inventory. **Remote Sens.** 2018, 10, 580; doi:10.3390/rs10040580
2018.

BIANCHINI, J. I. **Aspectos do processo de decomposição nos ecossistemas aquáticos continentais. Perspectivas da limnologia no Brasil**. São Luís: Gráfica e Editora União, p. 21 – 43, 1999.

BIUDES, J.F.V.; CAMARGO, A. F. M. (2008) Estudo dos fatores limitantes à produção primária por macrófitas aquáticas no Brasil. **Oecol. Bras.**, 12 (1): 7-19, 2008.

BRASIL. Constituição (2012). Decreto nº 7.830, de 17 de outubro de 2012. Dispõe Sobre o Sistema de Cadastro Ambiental Rural, **Cadastro Ambiental Rural**. Brasília, DF, 2012.

BREIMAN, L. Random forests. *Mach. Learn.* **2001**, 45, 5–32.

BREIMAN, L., 1999, Random forests—random features. Technical Report 567, Statistics Department, University of California, Berkeley, <ftp://ftp.stat.berkeley.edu/pub/users/breiman>.

BRIX, H.; SORRELL, B, K.; LORENZEN, B. Are Phragmites-dominated wetlands a net source or net sink of greenhouse gases? **Aquatic Botany**. n. 69, 2001. 313–324.

BURGER, M. I. Situação e ações prioritárias para a conservação de banhados e áreas úmidas da zona costeira. Base de Dados Tropical. Porto Seguro, 2000.

BYRD, K, B.; O'CONNELL, J. L.; DI TOMMASO, S.; KELLY, M. Evaluation of sensor types and environmental controls on mapping biomass of coastal marsh emergent vegetation. **Remote Sensing of Environment**. n.149, 2014. 166–180.

CASSOL, H. L. **Estimativa de biomassa e estoque de carbono em um fragmento de floresta ombrófila mista com uso de dados ópticos de sensores remotos**. 2013. 143 f. Dissertação (Mestrado em Sensoriamento Remoto). Programa de Pós-graduação em Sensoriamento Remoto. Universidade Federal do Rio Grande do Sul. Porto Alegre, 2013.

CERQUEIRA, D. B.; ROCHA, W. F. Relação entre tipos de vegetação e fluxo de CO₂ no Bioma Caatinga: Estudo de caso em Rio das Contas-BA. In: Simpósio Brasileiro de Sensoriamento Remoto, (SBSR), 2007, Florianópolis. **Anais...** São José dos Campos: INPE, 2007. p. 2413-2419.

CHAGAS, G. G. Uso de macrófitas lemnáceas no polimento e valorização dos efluentes de suinocultura e na fixação de carbono. 2010. 218 f. Tese (Doutorado em Ecologia e recursos naturais). Universidade Estadual do Norte Fluminense Darcy Ribeiro. Rio de Janeiro, 2010.

CHATZIANTONIOU, A.; PETROPOULOS, G.; PSOMIADIS, E. Co-Orbital Sentinel 1 and 2 for LULC Mapping with Emphasis on Wetlands in a Mediterranean Setting Based on Machine Learning. **Remote Sens.** 2017, 9, 1259; doi:10.3390/rs9121259.

CHOMENKO, L. Recursos Hídricos e Áreas úmidas: ambientes a serem preservados. In: **Conservação e uso sustentável da água: múltiplos olhares.** Sônia Balvedi Zakrzewski. (org.). Erechim, RS. EdiFapes, 2007. 138 p.

CLEVERS, J.; DE JONG, S. EPEMA, G.; VAN DER MEER, F.; BAKKER, W.; SKIDMORE, A.; SCHOLTE, K. 2002. Derivation of the red edge index using the MERIS standard band setting. **International Journal of Remote Sensing** 23: 3169-3184.

_____.; GITELSON, G.P.W.; GITELSON, A.A. Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3. *International Journal of Applied Earth Observation and Geoinformation.* 23 (2013) 344–351.

_____.; KOOISTRA, L. Retrieving canopy chlorophyll content of potato crops using Sentinel-2 bands. In Proceedings of ESA Living Planet Symposium, Edinburgh, UK, 9–13 September 2012; pp. 1–8.

CONAB. Calendário Agrícola ano 2019. Disponível em: <<https://www.conab.gov.br/institucional/publicacoes/outras-publicacoes/item/7694-calendario-agricola-plantio-e-colheita>>. Acesso em 15 mai 2019.

CONGALTON, R. G. 1991. “A Review of Assessing the Accuracy of Classifications of Remotely Sensed Data.” *Remote Sensing of Environment* Volume 37 (1): 35–46. doi:10.1016/0034-4257(91)90048-B.

CONVENÇÃO DE DIVERSIDADE BIOLÓGICA – SECRETARIADO (CDB). Panorama da Biodiversidade Global 3. Brasília: MMA/SBF, 2010. 94 p.

CONCORAN, J.; KNIGHT, J.; GALLANT, A. Influence of multi-source and multi-temporal remotely sensed and ancillary data on the accuracy of random forest classification of wetlands in Northern Minnesota. *Remote Sens.* **2013**, 5, 3212–3238.

CORDEIRO, C. O.; ROSSETTI, D. F. 2015. “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* 36 (13). Taylor & Francis: 3397–3422. doi:10.1080/01431161.2015.1060644.

COSTA, M. P. F.; NIEMANM, O.; NOVO, E. M. L. M.; AHERN, F. 2002. “Biophysical Properties and Mapping of Aquatic Vegetation during the Hydrological Cycle of the Amazon Floodplain Using JERS-1 and Radarsat.” *International Journal of Remote Sensing* 23: 1401–1426. doi:10.1080/01431160110092957.

COWARDIN, L. M.; CARTER, F. C.; GOLET, E.; LAROE, T. Classification of wetlands and deepwater habitats of the United States. U.S. Fish and Wildlife Service. FWS/OBS-79/31. Washington, DC, 1979.

CPRM. COMPANHIA DE PESQUISAS EM RECURSOS MINERAIS. Mapa litológico. Georref. Disponível em: <http://geobank.cprm.gov.br/>. Acesso em: 07 ago. 2016

CROOKS, S.; EMMETT-MATTOX, E.; FINDSEN, J. Findings of the National Blue-Ribbon Panel on the development of a greenhouse gas offset protocol for tidal wetlands restoration and management: action plan to guide protocol development. Available online at: <https://www.estuaries.org/images/stories/rae-action-plan-tidal-wetlandshgoffset-protocol-aug-2010.pdf>

CROOKS, S.; HERR, J.; TAMELANDER, D.; LAFFOY, J.; Vandever, J. 2011. “Mitigating Climate Change through Restoration and Management of Coastal Wetlands and Near-shore Marine Ecosystems: Challenges and Opportunities. **Environment Department Paper**. n. 121, World Bank, Washington, DC. 2011.

CURRAN, P.J; HAY, A.M. The importance of measurement error for certain procedures in remote sensing at optical wavelengths. **Photogrammetric Engineering and Remote Sensing**, v. 52. n. 2. p. 229-241. 1986.

DARONCH, M. C.; PAIVA, E. M. C. D.; CABRAL, I. L. L.; PRADO, R. J. **O impacto de atividades humanas nos banhados do Rio Grande do Sul**. 2004. 13 f. Artigo (Especialização). Universidade Federal de Santa Maria. Centro de Tecnologia, Curso de Especialização para Gestores Regionais de Recursos Hídricos, Santa Maria, 2004.

DAVIDSON, N. C. How much wetland has the world lost? Long-term and recent trends in global wetland area. **Marine and Freshwater Research**, Victoria – AUS, n. 65, 2014. 934–941.

Delegido, J., Verrelst, J., Alonso, L., Moreno, J., 2012. Evaluation of sentinel-2 red-edge bands for empirical estimation of green LAI and chlorophyll content. **Sensors** 11, 7063–7081.

DÍAZ, B.M.; BLACKBURN, G.A. Remote sensing of mangrove biophysical properties: evidence from a laboratory simulation of the possible effects of background variation on spectral vegetation indices. **International Journal of Remote Sensing**, vol.24, n.01, 2003. 53-73.

DIEGUES, A. C. S. (org.). **Povos e águas: inventário de áreas úmidas**. Núcleo de Apoio a Pesquisa sobre Populações Humanas e Áreas Úmidas Brasileiras. 2ª ed. São Paulo: USP, 2010. 597p.

Dixon, B.; Candade, N. Multispectral landuse classification using neural networks and support vector machines: One or the other, or both? **Int. J. Remote Sens.** **2008**, 29, 1185–1206.

DOI 10.1007/s13157-009-0003-4.

DRONOVA, I. 2015. “Object-Based Image Analysis in Wetland Research: A Review.” **Remote Sensing**. doi:10.3390/rs70506380.

EMMETT-MATTOX, E.; CROOKS, S. Coastal Blue Carbon as an Incentive for Coastal Conservation, Restoration and Management: A Template for Understanding Options. Disponível em:

http://www.conservationsoftheearth.org/uploads/4/7/3/1/47314411/what_is_blue_carbon.pdf.

Acesso em: 18 mar 2018.

ENGESAT. Soluções em imagens e geoprocessamento. Satélites, Sentinel2 - Características . Acesso em 20 de jun de 2019. Disponível em < <http://www.engesat.com.br/sentinel-2/>>.

ENNABILI, A.; ATER, M.; RADOUX, M. 1998. Biomass production and NPK retention in macrophytes from wetlands of the Tingitan Peninsula. *Aquatic Botany* 62 (1): 45-56.

ESPINDOLA, G M. 2006. “Ajuste de Parâmetros Em Algoritmos de Segmentação de Imagens Por Crescimento de Regiões.” Instituto Nacional de Pesquisas Espaciais. http://www.dpi.inpe.br/gilberto/teses/dissertacao_giovana.pdf.

ESTEVEES, B. S. **Biomassa, produtividade primária e composição nutricional de *Typha domingensis* na Lagoa do Campelo, RJ.** 2006. 82 f. Dissertação (Mestrado em Ecologia e Recursos Naturais). Universidade Estadual do Norte Fluminense Darcy Ribeiro, 2006.

ESTEVEES, F. A. **Fundamentos de Limnologia.** Rio de Janeiro: Interciência, 1998.

ETCHELAR, C. B. **Processos erosivos em áreas úmidas, APA do Banhado Grande - RS.** Dissertação (Mestrado em Sensoriamento Remoto). 2017. 106 f. Programa de Pós-graduação em Sensoriamento Remoto. Universidade Federal do Rio Grande do Sul. Porto Alegre, 2017

FERREIRA, S. P. **Estimativa de emissões de gases de efeito estufa em reservatórios de hidrelétricas utilizando técnicas de sensoriamento remoto.** 2015. 85 f. Tese (Doutorado em Sensoriamento Remoto). Universidade Federal do Rio Grande do Sul. Porto Alegre, 2015.

FERREIRA, T. F. **Ecologia e aplicabilidade de métodos para avaliação da produção primária *Zizaniopsis bonariensis*: uma macrófita aquática emergente, no sistema hidrológico do Taim.** 2005, 161f. Dissertação (Mestrado em ecologia) - Instituto de Biociências - Programa de Pós-Graduação em ecologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2005.

FIELD, A. **Descobrimos a estatística usando o SPSS**, 2. ed. – Dados eletrônicos. – Porto Alegre : Artmed, 2009.

FITELLA, I.; PENNUELAS, J. 1994. The red edge position and shape as indicators of plant chlorophyll content, biomass and hydric status. *International Journal of Remote Sensing* 15: 1459-1470.

FLORENZANO, T. G. **Imagens de satélites para estudos ambientais.** São Paulo: Oficina de Textos, 2002, 98p.

FRAMPTON, W. J. *et al.* Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. **ISPRS Journal of Photogrammetry and Remote Sensing**, 2013. v. 82, p. 83–92. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2013.04.007>>.

FRANK, A.B; KARN, J.F. Vegetation indices, CO2 flux, and biomass for Northern Plains Grasslands. *JOURNAL OF RANGE MANAGEMENT* 56(4) July 2003

FRANKLIN, S. E.; AHMED, O. S. 2017. “Object-Based Wetland Characterization Using Radarsat-2 Quad-Polarimetric SAR Data, Landsat-8 OLI Imagery, and Airborne Lidar-Derived Geomorphometric Variables.” **Photogrammetric Engineering & Remote Sensing** 83 (1): 27–36. doi:10.14358/PERS.83.1.27.

_____.; ERIK, M. S.; STEFANUK, M. A.; AHMED, O. S. 2018. “Wetland Classification Using Radarsat-2 SAR Quad-Polarization and Landsat-8 OLI Spectral Response Data: A Case Study in the Hudson Bay Lowlands Ecoregion.” **International Journal of Remote Sensing**. 39 (6). Taylor & Francis: 1615–1627. doi:10.1080/01431161.2017.1410295.

FRANTZ, D.G.; CLOVIS, C.C.; ROBERTO, V; MARY ANNE, T.G. Caracterização de ambientes paludais da Planície Costeira do Rio Grande do Sul em imagens orbitais TM Landsat 5. 1990. Disponível em:<<http://bibdigital.sid.inpe.br/rep-/dpi.inpe.br/marte@80/2008/08.18.14.23>. Acesso em: 10 nov. 2017.

FZB. FUNDAÇÃO ZOOBOTANICA DO RIO GRANDE DO SUL. Parecer resultante da amostragem da fauna e flora do “Complexo Banhado Grande” RS. Porto Alegre, 1983. 12p.

GALO, M.L.B.T.; VELINI, E.D.; TRINDADE, M.L.B.; SANTOS, S.C.A. Uso do sensoriamento remoto orbital no monitoramento da dispersão de macrófitas nos reservatórios do complexo Tiete. **Planta Daninha**, Viçosa-MG, v.20, 2002. 7-20. Edição Especial

GAMON, J. A.; PEÑUELAS, J.T.; FIELD, C. B. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. **Remote Sensing of Environment**. Volume 41, Issue 1, July, 1992. 35-44.

GAMON, J. A.; SERRANO, L.; SURFUS, J. S. “The photochemical reflectance index: an optical indicator of photosynthetic radiation use efficiency across species, functional types, and nutrient levels”. **Oecologica**, vol. 112, 1997. 492-501.

GAO, Y.; GAO, J.; WANG, J.; SHUANGSHUANG, W.; LI, Q.; ZHAI, S.; ZHOU, Y. Estimating the biomass of unevenly distributed aquatic vegetation in a lake using the normalized water-adjusted vegetation index and scale transformation method. **Science of the Total Environment**, n. 601–602, 2017. 998–1007.

GIOVANINI, S. G. T. 2004. 267 f. **Estudo de variabilidade espacial da vegetação no banhado do Taim**. Universidade Federal do Rio Grande do Sul, Tese (Doutorado) em Recursos Hídricos e Saneamento Ambiental. Porto Alegre, 2004

GITELSON, A.; MERZLYAK, M.N. 1994. Spectral reflectance changes associated with autumn senescence of *A. hippocastanum* L. and *A. platanoides* L. Leaves. Spectral features and relation to chlorophyll estimation. *Journal of Plant Physiology*.143, pp286.

GOETZ, S.; DUBAYAH, R. (2011). Advances in remote sensing technology and implications for measuring and monitoring forest carbon stocks and change. *Carbon Management*, 2, 231–244.

GUASSELLI, L. A. 2005. 157 f. **Dinâmica da Vegetação no Banhado do Taim, RS. Universidade Federal do Rio Grande do Sul**. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental). Porto Alegre, 2005

LEITE, M. G.; GUASSELLI, L. A. Dinâmica espaço-temporal das macrófitas aquáticas no Banhado Grande, bacia hidrográfica do Rio Gravataí, RS. **Para Onde!?**, n. 7 (1), jan./jul 2013. 17-24.

_____.; BELLOLI, T.F; ETCHELAR, C.B. Questões ambientais associadas a produção de arroz, Região Metropolitana de Porto Alegre. In: GUASSELLI, L.A; MEDEIROS, R.M.V (org). Impactos da produção de arroz na Região Metropolitana de Porto Alegre. Análise

territorial e ambiental. Porto Alegre: **Imprensa Livre**. 2015. p. 53-72.

GUERINI FILHO, M. **Estimativa de variáveis biofísicas de vegetação campestre sob manejo pastoril por meio de sensoriamento remoto**. 2018. 64 f. Dissertação (Mestrado em Sensoriamento Remoto). Programa de Pós-graduação em Sensoriamento Remoto. Universidade Federal do Rio Grande do Sul. Porto Alegre, 2018.

GUIMARÃES, C. D. M. **A influência da convenção de RAMSAR para a política de conservação de ecossistemas úmidos no Brasil**. 2014. 46 f. Trabalho de conclusão de curso (Especialização). Curso de Pós-Graduação Lato Sensu em Direito Ambiental. Universidade Federal do Paraná. Departamento de Economia Rural e Extensão. 2014.

GUO, M.; Li, J.; Sheng, C.; Xu, J.; Wu, L. A Review of Wetland Remote Sensing. **Sensors**, n. 17, 2017. Art No. 777.

HARDINSKY, M.A.; KLEMAS, V.; MICHAEL SMART, R. The influence of soil salinity, growth form, and leaf moisture on the spectral radiance of *Spartina alterniflora* canopies. **Photogrammetric Engineering and Remote Sensing**, n. 49, 1983. 77–83.

HENDERSON, F.M.; LEWIS, A.J. 2008. Radar detection of wetland ecosystems: a review. *International Journal of Remote Sensing* 29: 5809-5835.

YESOU, H.; POTTIER, E.; MERCIER, G.; GRIZZONED, M.; FAIVRE, R. Synergy of Sentinel-1 and Sentinel-2 imagery for wetland monitoring information extraction from continuous flow of sentinel images applied to water bodies and vegetation mapping and monitoring. 2016. IEEE International Geoscience and Remote Sensing Symposium (IGARSS) Beijing, China doi: 10.1109/IGARSS.2016.7729033.

HO, R. **Handbook of univariate and multivariate data analysis and interpretation with SPSS**. New York: Taylor & Francis Group. 2006. 393p.

HOA, N. H. Comparison of various spectral indices for estimating mangrove covers using PlanetScope data. Comparison of various spectral indices for estimating mangrove cover using PlanetScope. *Management of Forest Resources and Environment. Journal of forestry Science and technology*. n. 5 – 2017. p. 74-83

HORLER, D.N.H.; DOCKRAY, M.; BARBER, J. 1983. The red edge of plant leaf reflectance. **International Journal of Remote Sensing** 4, 273–288.

HUANG, W, DEVRIES, B, HUANG, C, MEGAN, CREED, I. F.; MARK, L. Carroll Automated Extraction of Surface Water Extent from Sentinel-1 Data. **Remote Sens**. 2018, 10, 797; doi:10.3390/rs10050797.

HUETE, A.; LIU, H. Q.; BATCHILY, K.; VAN LEEUWEN, W.J.D.A. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, 1997. 40-45.

IPCC – Painel Intergovernamental Sobre Mudanças do Clima. Mudança do Clima 2007: A Base das Ciências Físicas – Sumário Para os Formuladores de Políticas. 2007.

IPH. Instituto de Pesquisas Hidráulicas. **Identificação das alternativas possíveis e prováveis para regularização das vazões do Rio Gravataí**: Relatório Final. Porto Alegre: IPH/CPRM, 2002. 207 p.

IRGANG, B. E. Vegetação natural de banhado inclusive turfeiras, respectivamente como o Chico Lomã e a Turfeira de Águas Claras. Porto Alegre, MINTER-DNOS, 15ª DR. Relatório não publicado. 1982.

IRGANG, B. E.; GASTAL JÚNIOR, C. V. **Macrófitas aquáticas da planície costeira do RS**. Porto Alegre: CPG Botânica/UFRGS, 1996. 290p.

ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci., IV-4/W4, 271-277, <https://doi.org/10.5194/isprs-annals-IV-4-W4-271-2017>, 2017.

ITURRASPE, R. Las turberas de Tierra del Fuego y el cambio climático global. Buenos Aires: Fundación para la Conservación y el Uso Sustentable de los Humedales, 1ªed, 2010. 32 p.

JAKUBAUSKAS, M.; KINDSCHER, K.; FRASER, A.; DEBINSKI, D.; PRICE, K. P. Close-range remote sensing of aquatic macrophyte vegetation cover. **International Journal of remote sensing**, vol. 21, n. 18, 2000. 3533–3538. JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 3. ed., New Jersey: Prentice-Hall, 2005. 526 p.

Jensen, J.R. **Introductory Digital Image Processing**, 3rd ed.; Prentice Hall: Upper Saddle River, NJ, USA, 2005.

JOOSTEN, H. Y. J. Peatlands and Carbon. En: PARISH, F. A. SIRIN, D.C.; JOOSTEN, H MININAYEVA, T.; SILVIUS, M.; STRINGER, L. (Eds): **Assessment on Peatlands, Biodiversity and Climate Change: Main Report**. Global Env. Centre, K. **Lumpur y Wetlands International**, Wageningen, 2008. 99-117.

JU, C. H. *et al.* Estimating leaf chlorophyll content using red edge parameters. **Pedosphere**, 2010. v. 20, n. 5, p. 633–644. Disponível em: <[http://dx.doi.org/10.1016/S1002-0160\(10\)60053-7](http://dx.doi.org/10.1016/S1002-0160(10)60053-7)>.

JUNK, W. J. , PIEDADE, M.T.F. Biomass and primary production of herbaceous plant communities in the Amazon floodplain. **Hidrobiologia**, vol. 263, 1993. 155-162.

_____; **Áreas Úmidas (AUs) Brasileiras: Avanços e Conquistas Recentes**. Boletim ABLimno, v. 41, n. 2, 2015. p. 20-24.

_____; PIEDADE, M.T.F.; LOURIVAL, R.; WITTMANN, F.; KANDUS, P.; LACERDA, L.D.; BOZELLI, R. L.; ESTEVES, F. A.; NUNES DA CUNHA, C.; MALTCHIK, L.; SCHÖNGAR, J.; SCHAFERNOVELLI, Y.; AGOSTINHO, A.A.; NÓBREGA, R.L.B. **Definição e classificação das Áreas Úmidas (AUs) brasileiras: base científica para uma nova política de proteção e manejo sustentável**. Cuiabá: CPP/INAU, 2012. Disponível em: <<http://www.cppantanal.org.br/wp-content/uploads/2015/06/14-12-2012.pdf>>. Acesso em 02 ago. 2016.

_____; BAYLEY, P.B.; SPARKS, R.E. The Flood Pulse Concept in River-Floodplain Systems. In: D.P. Dodge (Ed) **Proceedings of the International Large River Symposium**. Canadian Journal of Fisheries and Aquatic Sciences, n. 106, 1989. 110-127.

JUSTICE, C.O.; VERMOTE, E.; TOWNSHEND, J.R.G.; DEFRIES, R.; ROY, D.P.; HALL, D.K.; SALOMONSON, V.V.; PRIVETTE, J.L.; RIGGS, G.; STRAHLER. The Moderate Resolution Imaging Spectroradiometer (MODIS): land remote sensing for global change research. **IEEE Transactions on Geoscience and Remote Sensing**, v.36, 1998. 1228-1249.

KAMAL, M.; PHINN, S. 2011. "Hyperspectral Data for Mangrove Species Mapping: A Comparison of Pixel-Based and Object-Based Approach." **Remote Sensing** 3: 2222–2242. doi:10.3390/rs3102222.

KAPLAN, G. J.; AVDAN, Z. Y.; AVDAN, U. Estimation of wetland biomass using Sentinel-2 Images. Digital Proceeding of ICOCEE –Cappadocia 2017. Nevsehir, Turkey. p 1539-1545.

Kaplan, G.; Avdan, U. Mapping and monitoring wetlands using Sentinel -2 Satellite imagery.

KATARYNA, D. Z.; MUSIAL, J.; MALINSKA, A.; BUDZYNSKA, M. KAVZOGLU, T. YILDIZ, M. 2014. "Parameter-Based Performance Analysis of Object-Based Image Analysis Using Aerial and QuikBird-2 Images." *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences II-7*: 31–37. doi:10.5194/isprsannals-II-7-31-2014.

KAYRANLI, B.; SCHOLZ, M.; MUSTAFA, A.; HEMARK, A. Carbon Storage and Fluxes within Freshwater Wetlands: a Critical Review. **Wetlands** (2010) 30:111–124

KEARNEY, M. S.; STUTZER, D.; TURPIE, K.; STEVENSON, J. C. The Effects of Tidal Inundation on the Reflectance Characteristics of Coastal Marsh Vegetation. **Journal of Coastal Research**, Vol. 25, n. 6, 2009. 1178-1186.

KLAMT, E.; KÄMPF, N.; SCHNEIDER, P. **Solos de várzea no estado do Rio Grande do Sul**. Universidade Federal do Rio Grande do Sul, Faculdade de Agronomia, Departamento de Solos. Porto Alegre. Boletim Técnico n. 4. 1985. 43 p

KUFNE, D C L.; SCREMIN-DIAS, E.; GUGLIERI-CAPORAL, A. Composição florística e variação sazonal da biomassa de macrófitas aquáticas em lagoa de meandro do Pantanal. **Rodriguésia**, n. 62(4), 2011. 803-812.

LEITE, B. R. A.; BAPTISTA, G.M.M. Avaliação da importância ambiental da wetland do Riacho Fundo para o Lago Paranoá e comunidades vizinhas. **Revista Brasileira de Geografia Física**, V. 08 n. 05. 2015. 1524-1540.

LEITE, M. G. **Análise espaço-temporal da dinâmica da vegetação no Banhado Grande, Bacia Hidrográfica do rio Gravataí, RS**. 2011. 96 f. Trabalho de Conclusão de curso (Bacharelado em Geografia). Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

LEK, S.; GUEGAN, J. Artificial neural networks as a tool in ecological modeling, an introduction. *Ecol. Model.* **1999**, 120, 65–73.

LIETH, H. Historical survey of primary productivity research, In: H. LIETH & R.H. WHITTAKER (Editors), *Primary Productivity of the Biosphere*. **SPRINGER-VERLAG**, Nova York, 1975. 7-16.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. Digital image processing. In: *Remote sensing and image interpretation*. New York: John Wiley. 6th ed, 2007. 491-503.

MAHDAVI, S.; BAHRAM, S, JEAN, G.; MEISAM, A.; BRIAN, B.; WEIMIN, H. Remote sensing for wetland classification: a comprehensive review. **GIScience & Remote Sensing**. 2017. 1-77.

MALTCHIK, L.. Áreas úmidas: importância, inventários e classificação. In: **Biodiversidade e conservação de áreas úmidas**. Ed. UNISINOS. São Leopoldo. 2003, p. 13–22.

_____.; ROLON, A. S.; GUADAGNIN, D. L.; STENERT, C. Wetlands of Rio Grande do Sul, Brazil: a classification with emphasis on plant communities. **Acta Limnologica Brasiliensia**, v. 16, n. 2, 2004. 137–151.

GRENIER, M.; LABRECQUE, S.; GARNEAU, M.; TREMBLAY, A. Object-based classification of a SPOT-4 image for mapping wetlands in the context of greenhouse gases emissions: the case of the Eastmain region, Québec, Canada. **Can. J. Remote Sensing**, Vol. 34, Suppl. 2, pp. S398–S413, 2008

PARMUCHI, M. G.; KARSZENBAUM, H.; KANDUS, P. Mapping wetlands using multi-temporal RADARSAT-1 data and a decision-based classifie. **Can. J. Remote Sensing**, Vol. 28, No. 2, pp. 175–186, 2002.

PROTOLONGO, P.; KANDUS, P. Dinámica de la biomassa aérea en pajonales de *Scirpus giganteus* y juncales de *shoenoplectus californicus* em la zona frontal del bajo delta del rio Paraná (Argentina). **ECOTROPICOS** 18(1):30-37 2005. Sociedad Venezolana de Ecología

PROTOLONGO, P.; VICARI, R.; KANDUS, P.; MALVAREZ, I. A new method for evaluating net aboveground primary production (NAPP) of *Scirpus giganteus*. **WETLANDS**, Vol. 25, No. 1, March 2005, pp. 228–232

MARTINS, L. N.; BAPTISTA, G. M. M. Análise Multitemporal do Sequestro Florestal de Carbono no Projeto de Assentamento Carão, Acre. **Revista Brasileira de Geografia Física**, Pernambuco, V. 06, n. 06, 2013. 1648-1657.

MATZENAUER, Ronaldo ; RADIN, Bernadete ; ALMEIDA, Ivan Rodrigues de (Ed.). **Atlas Climático: Rio Grande do Sul**. Porto Alegre: Secretaria da Agricultura Pecuária e Agronegócio; Fundação Estadual de Pesquisa Agropecuária (FEPAGRO), 2011.

MAUHS, J.; MARCHIORETTO, M. S.; BUDKE, J. Riqueza e biomassa de macrófitas em uma Área úmida na planície costeira do Rio Grande do Sul. Brasil. **Pesquisas botânicas**, São Leopoldo, Instituto Anchieta de Pesquisas, n. 57, 2006. 289-302.

MCLEOD, E.; CHMURA, G. L.; BOUILLON, S.; SALM, R.; BJÖRK, M.; DUARTE, C. M.; LOVELOCK, C. E.; SCHLESINGER, W. H.; SILIMAN, B. R. A blueprint for blue carbon: toward an improved understanding of the role of vegetated coastal habitats in sequestering CO₂. **Frontiers of Ecology and the Environment**, n. 9, 2011. 552–560.

MEANS, M.M.; AHN, C.; KOROL, A.R.; WILLIAMS, L.D. Carbon storage potential by four macrophytes as affected by planting diversity in a created wetland. **Journal of Environment Management**, n. 165, 2016. 133–139.

MELLO, L.P. **Percepção da paisagem e conservação ambiental no Banhado Grande do Rio Gravataí (RS)**. 1998. 365f. Tese (Doutorado em Geografia) Departamento de Geografia, Universidade de São Paulo. São Paulo. 1998.

MENEGHETI, J. O. Lagunas uruguayas y sur de Brasil. In: CAVENARI, P.; DAVIDSON, I.; BLANCO, D.; CASTRO, G.; BUCHER, E. (eds). **Los humedales de America del Sur, una agenda para la conservación de La biodiversidad y políticas de desarrollo**. Buenos Aires: Wetlands International. 1998. 49p.

MENEZES, C.F.S. **Biomassa e produção primária de três espécies de macrófitas aquáticas na Represa do Lobo (Broa), SP.** 1984. 253 f. Dissertação (Mestrado em Ecologia de Recursos Naturais). Universidade Federal de São Carlos, São Carlos. 1984.

CROWSON, M.; WARREN, E.; HILL, J. K.; BAMBANG, H.; AGUS, F.; SAAD, A.; KEITH, C.; JENNY, A.; WINDA, D. A. Comparison of satellite remote sensing data fusion methods to map peat swamp forest loss in Sumatra, Indonesia. **Remote Sensing in Ecology and Conservation**. doi: 10.1002/rse2.102

MIRANDA, J. C. S.; COSTA, S. M. F. Estudo de macrófitas aquáticas utilizando imagens orbitais em um trecho do rio Paraíba do Sul. In: Simpósio Brasileiro de Sensoriamento Remoto, (SBSR), 2015, Paraíba. **Anais...** João Pessoa: INPE, 2015. p. 3972- 3979.

MISHRA, N. B. Wetlands: Remote Sensing. In **Encyclopedia of Natural Resources: Land**. p. 566-574, 2014. DOI: 10.1081/E-ENRL-K12411_120049156.

MITSCHE, W. J.; BERNAL, B.; NAHLIK, A. M.; MANDER, U.; ZHANG, L.; ANDERSON, C. J.; JORGENSEN, E.; BRIK, H. Wetlands, carbon, and climate change. **Landscape Ecology**, n. 28, 2013. 583–597.

_____. GOSELINK, J. G. **Wetlands**. 5ª ed. New Jersey: John Wiley & Sons, 2015. 747p.
MMA. Ministério do Meio Ambiente. Cuidar das Zonas Úmidas - uma resposta às mudanças climáticas. 2016, p 28. Disponível em: <http://www.mma.gov.br/estruturas/205/_publicacao/205_publicacao29112010033202.pdf>. Acesso em: 05 out. 2017.

_____. Gerência de Biodiversidade Aquática e Recursos Pesqueiros. Panorama da conservação dos ecossistemas costeiros e marinhos no Brasil. Brasília: MMA/SBF/GBA, 2010. 148 p.

_____. Inter-relações entre biodiversidade e mudanças climáticas. Recomendação para integração das considerações sobre biodiversidade na implementação da convenção-quadro das Nações Unidas sobre mudanças do clima e seu protocolo de Kyoto. Tradução. Brasília: MMA, 2007, 220 p.

MOBASSHERI, M. R.; AMANI, M. 2016. “Soil Moisture Content Assessment Based on Landsat 8 Red, near-Infrared, and Thermal Channels.” **Journal of Applied Remote Sensing**. 10 (2). International Society for Optics and Photonics: 026011. doi:10.1117/1.JRS.10.026011.

MOFFETT, K. B.; GORELICK, S. M. 2013. “Distinguishing Wetland Vegetation and Channel Features with Object-Based Image Segmentation.” **International Journal of Remote Sensing** 34 (4). Taylor & Francis : 1332–1354. doi:10.1080/01431161.2012.718463.

MOHEDANO, R. A. **Uso de macrófitas lemnáceas no polimento e valorização dos efluentes de suinocultura e na fixação de carbono.** 2010. 270 f. Tese (Doutorado em Engenharia Ambiental). Universidade Federal de Santa Catarina. 2010

MOREIRA, M.A. **Fundamentos do Sensoriamento Remoto e Metodologias de aplicação.** 4. ed., Viçosa/Mg-UFV, 2012. 421p.

MORETTIN, P. A.; BUSSAB, W. O. **Estatística Básica.** 5ed. São Paulo: Saraiva, 2004. 537p.

Mountrakis, M.; Im, J.; Ogole, C. Support vector machines in remote sensing: A review. **ISPRS J. Photogramm. Remote Sens.** 2011, 66, 247–259

MUI, A.; HE, Y.; WENG, Q. An Object-Based Approach to Delineate Wetlands across Landscapes of Varied Disturbance with High Spatial Resolution Satellite Imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 109, p. 30-46, 2015. doi:10.1016/j.isprsjprs.2015.08.005.

MUTANGA, O & SKIDMORE, A. K. (2004). Narrow band vegetation indices overcome the saturation problem in biomass estimation. **International Journal of Remote Sensing**, 25, p. 3999–4014.

MUTANGA, O.; ADAM, E. ; CHO, M. A. High Density Biomass Estimation for Wetland Vegetation Using WorldView-2 Imagery and Random Forest Regression Algorithm. **International Journal of Applied Earth Observation and Geoinformation**, n. 18: p.399-406, 2012. doi:10.1016/j.jag.2012.03.012.

NAVARRO, J.A.; Algeet, N.; Fernández-Landa, A.; Esteban, J.; Rodríguez-Noriega, P.; Guillén-Climent, M.L. Integration of UAV, Sentinel-1, and Sentinel-2 Data for Mangrove Plantation Aboveground Biomass Monitoring in Senegal. **Remote Sens.** 2019, 11, 77. <https://doi.org/10.3390/rs11010077>

NEIFF, J.J. El régimen de pulsos em ríos y grandes humedales de Sudamérica. In: ALAVAREZ, A.I.; KANDUS, P. (eds.). **Tópicos sobre grandes humedales sudamericanos**. ORCYT- UNESCO, Montevideo, 1997. 99-149.

NOGUEIRA, D. A.; PEREIRA, G. M. Desempenho de testes para homogeneidade de variâncias em delineamentos inteiramente casualizados. **Sigmae**, Alfenas, v.2, n.1, p. 7-22. 2013.

OLIVEIRA, M. L. A. A.; SENNA, R. M.; NEVES, M. T. M. B. Sessão 2, diagnóstico de flora e vegetação. Biodiversidade. Regiões da Lagoa do Casamento e dos Butiazais de Tapes, planície costeira do Rio Grande do Sul / Ministério do Meio Ambiente. – Brasília: MMA / SBF, 2006. 388 p. : il. color. ; 42 cm + 1 CD-ROM ¾. (Série Biodiversidade, 25).

OLIVEIRA, M. de L. A. A. de, BALBUENO, R. A. e SENNA, R. M. Levantamento florístico de fragmentos florestais na bacia hidrográfica do Rio Gravataí, Rio Grande do Sul, Brasil. **IHERINGIA, Sér. Bot**, Porto Alegre, v. 60, n. 2, p. 269-284. 2005.

OOI, H. L., S. C.S. C. Ng, and LIM, E. 2013. “ANO Detection with K-Nearest Neighbor Using Minkowski Distance.” *International Journal of Signal Processing Systems* 1 (2): 208–211. doi: 10.12720/ijsp.1.2.208-211.

OUYANG, Z. M.; ZHANG, X.; SHEN, Q.; GUO, H.; ZHAO, B. 2011. “A Comparison of Pixel-Based and Object-Oriented Approaches to VHR Imagery for Mapping Saltmarsh Plants.” *Ecological Informatics* 6: 136–146. doi:10.1016/j.ecoinf.2011.01.002.

Ozesmi SL, Bauer ME (2002) Satellite remote sensing of wetland. **Wetl Ecol Manage** 10:381–402

KANDUS, P.; MINOTTI, P. G.; MORANDEIRA, N. S.; GRIMSON, R.; TRILLA, G. G.; GONZALEZ, E. B.; MARTIN, L. S.; GAYOL, M. P. (2018) Remote sensing of wetlands in South America: status and challenges, **International Journal of Remote Sensing**, 39:4, 993-1016, DOI: 10.1080/01431161.2017.1395971

PEDREGOSA, F.; VAROUQUAUX, G.; GRAMFORT, A.; MICHEL, V. Scikit-Learn: Machine Learning in Python. **Journal of Machine Learning Research**, n. 12, p.2825–2830, 2011.

PENUELAS, J.; GAMON, J.A.; GRIFFIN, K.L.; FEILD, C.B. Assessing community type, plant biomass, pigment composition, and photosynthetic efficiency of aquatic vegetation from spectral reflectance. **Remote Sensing Environment**, n. 46, 1993. 110–118.

PEREIRA, O. J. R.; MELF, A. J.; MONTES, C. R. Image fusion of Sentinel-2 and CBERS-4 satellites for mapping soil cover in the Wetlands of Pantanal. **International Journal of Image and Data Fusion Volume** 8, 2017 - Issue 2. <https://doi.org/10.1080/19479832.2016.1261946>

PETTORELLI, N., et. al. Using the satellite-derived NDVI to assess ecological responses to environmental change. **TRENDS in Ecology and Evolution**, v.20, n.9, 2005. 1-8.

PIEIDADE, M. T. F.; JUNK, W. J.; LONG, S. P. The productivity of the c-4 Grass *Echinochloa polystachya* on the amazon floodplain. **Ecology**, v. 72, n. 4, 199. 1456-1463.

PIEIDADE, M.T.F.; JUNK, W.J.; MELO, J.A.N. A floodplain grassland of the central Amazon. In: Long, S.P.; Jones, M.B.; Roberts, M.J. (Eds.) **Primary Productivity of Grass Ecosystems of the Tropics and Subtropics**. Chaman & Hall/UNEP. London: 127-158. 1992.

PIEIDADE, M.T.F.; LONG, S.P.; JUNK, W.J. Leaf and Canopyphotosynthetic CO₂ uptake of a stand of *Echnochloa polystachya* on the Central Amazon Floodplain. **Oecologia** 97:193-201. 1994.

PLANET IMAGERY PRODUCT SPECIFICATIONS. Planet ortho scenes product specifications. January, 2018.

PLANET SURFACE REFLECTANCE PRODUCT. Atmospheric Correction Methodology, February, 2018.

POLÔNIO, V. D. **Índices de vegetação na mensuração do estoque de carbono em áreas com cana-de-açúcar**. 2015. 85 f. Dissertação. (Mestrado em Agronomia) Faculdade de Ciências Agrônômicas. Universidade Estadual Paulista - UNESP. São Paulo, 2015.

POMPÊO, M. L. M.; MOSCHINI, C.V. Biomassa das macrófitas aquáticas: o método do quadro. In: **Macrófitas aquáticas e perifiton, aspectos ecológicos e metodológicos**. São Carlos: RiMa, 2003. 137p.

POMPÊO, M. Monitoramento e manejo de macrófitas aquáticas, **Oecol. Bras**, v. 12, n. 3, 2008. 406-424.

PONTIUS, R. G.; MILLONES, M. 2011. “Death to Kappa: Birth of Quantity Disagreement and Allocation Disagreement for Accuracy Assessment.” **International Journal of Remote Sensing** 32 (15): 4407–4429. doi:10.1080/01431161.2011.552923.

PONZONI, F. J.; DISPERATI, A. Sensoriamento remoto: reflectância de alvos naturais. In: MENESES, P. R.; NETTO, J. S. M. **Comportamento espectral da vegetação**, 2001, p. 157–199.

_____; SHIMABUKURO, Y. E.; KUPLICH, M. T. **Sensoriamento remoto da vegetação**. 2º ed. São Paulo: Oficina de textos, 2012. 176p.

POWERS, R. P.; GEOFFREY, J. H.; CHEN, G. 2012. “Remote Sensing of Environment How Wetland Type and Area Differ through Scale: A GEOBIA Case Study in Alberta ’ s

Boreal Plains.” **Remote Sensing of Environment**, v.117. Elsevier Inc.: 135–145. doi:10.1016/j.rse.2011.07.009.

PROTEGER. Programa Técnico Para o gerenciamento da Região Metropolitana de Porto Alegre. Geomorfologia da Bacia do rio Gravataí. Série Cartas Temáticas. Porto Alegre. Vol.1. 1994.

PU, R.; LANDRY, S.; YU, Q. Object-based urban detailed land cover classification with high spatial resolution ikonos imagery. **Int. J. Remote Sens**, n. 32, p. 3285-3308, 2011.

QIAN, Y.; ZHOU, W.; YAN, J.; LI, W. H.; HAN, L. 2015. Comparing Machine Learning Classifiers for Object-Based Land Cover Classification Using Very High Resolution Imagery. **Remote Sensing**, n 7, v, p.153-168, 2015. doi:10.3390/rs70100153.

RAHMAN, A.; GAMON, J.A.; FUENTES, D.A.; ROBERTS, D.A.; PRENTISS, D.; QIU, H. Modeling CO₂ flux of boreal forests using narrow-band indices from AVIRIS imagery. AVIRIS Workshop, JPL/NASA, Pasadena, Califórnia, 2000.

RAMOS, R. A.; PASQUALETTO, A. I.; BALBUENA, R. A.; AGRA, R.; QUADROS, E. L. L.; NEVES, D. D. mapeamento e diagnóstico de áreas úmidas no Rio Grande do Sul com o uso de ferramentas de geoprocessamento. **Base cartográfica digital do RS 1:250.000**. Fepam.

RAMSAR. The Ramsar Library. Information sheet on Ramsar Wetlands. Gland: The Ramsar Convention, 2013. Disponível em: <<http://www.ramsar.org/sites/default/files/documents/library/manual6-2013-e.pdf>>. Acesso em: 02 jul. 2016.

REFLORA - Herbário Virtual. Disponível em:<http://reflora.jbrj.gov.br/reflora/herbarioVirtual/ConsultaPublicoHVUC/ConsultaPublicoHVUC.do?idTestemunho=3309348>. Acesso em 24/5/2019.

REZENDE, A. V.; VALE, A.T.; SANQUETTA, C.R.; FILHO, A.F.; FELFILI, J.M. Comparação de modelos matemáticos para estimativa do volume, biomassa e estoque de carbono da vegetação lenhosa de um cerrado sensu stricto em Brasília, DF. **Scientia Forestalis**, n. 71, 2006. 65-76.

RIBEIRO, S. C. Quantificação de biomassa e estimativa de estoque de carbono em uma capoeira da zona da mata mineira. **Revista Árvore**, v.34, n.3, 2010. 495-504.

Ricardo Vicari, Patricia Kandus, Paula Prato Longo & Mariana Burghi. Carbon budget alteration due to landcover–landuse change in wetlands: the case of afforestation in the Lower Delta of the Paraná River marshes (Argentina). **Water and Environment Journal**. (2011) 378–386. doi:10.1111/j.1747-6593.2010.00233.x.

RICHEY, J.E.; MELACK, J.M.; AUFDENKAMPE, A.K.; BASSKESTERM V. M.; HESS, L.L. Outgassing from Amazonian rivers and wetlands as a large tropical source of atmospheric CO₂. **Nature**, n. 416, 2002. 617-620.

RINGUELET, R. A. **Ecologia acuática continental**. Buenos Aires: Eudeba 1962. 138p.

RIO GRANDE DO SUL. Constituição (2015). Decreto nº 52.431, de 23 de junho de 2015. Estabelece critérios que definem legalmente as características dos Banhados bem como especifica o enquadramento das peculiaridades do bioma pampa visando o preenchimento do CAR (cadastro Ambiental Rural). Porto Alegre, RS.

RIO GRANDE DO SUL. **Plano de Recursos Hídricos da Bacia Hidrográfica do rio Gravataí**. Relatório Final. Secretaria Estadual do Meio Ambiente. 2012. 582p.

ROLON, A. S.; MALTCHIK, L. Environmental factors as predictors of aquatic macrophyte richness and composition in wetlands of southern Brazil. **Hydrobiologia**, v. 556, n. 1, 2006. 221–231.

ROSSATO, M.S. **Os climas do Rio Grande do Sul: variabilidade, tendências e tipologias**. 2011. 240 f. Tese. (Doutorado em Geografia). Universidade Federal do Rio Grande do Sul, Porto Alegre, Rio Grande do Sul. 2011.

ROUSE, J. W.; HAAS, R.H., SCHELL, J.A.; DEERING, D.W. Monitoring Vegetation Systems in the Great Plains with ERTS". In: Proceeding of ERTS Symposium. **Anais ... NASA**, United States, n. 3. p. 309-317, 1973.

RUSSI, D. P.; TEN BRINK, A.; FARMER, T.; BADURA, D.; COATES, J.; FÖRSTER, R; KUMAR, and N. DAVIDSON. The Economics of Ecosystems and Biodiversity for Water and Wetlands. IEEP, Ramsar Secretariat, Gland, London and Brussels, p. 84, 2013.

SALES, L. M; Luiz Rogério Mantelli; Marisa Dantas Bitencourt. Determinação radiométrica de biomassa macrofítica e sua correlação com valores de reflectância obtidos por sensores remotos ópticos. **Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.5860.

SANTOS, J. S. DOS.; PEREIRA, G.; SHIMABUKURO, Y. E.; RUDORFF, B. F. T. Identificação de áreas alagadas no Bioma Pantanal - Brasil - utilizando dados multitemporais TERRA/MODIS. **Geografia**, Rio Claro, v. 34, Número Especial, dez. 2009. 745-755.

SCHILE, L. M.; BYRD, K. B.; WINDHAM-MYERS, L.; KELLY, M. Accounting for non-photosynthetic vegetation in remote-sensing-based estimates of carbon flux in wetlands. **Remote Sensing Letters**, Vol. 4, N. 6, 2013. 542–551.

SERRANO, L.; PENUELAS, J.; USTIN, S. L. Remote sensing of nitrogen and lignin in Mediterranean vegetation from AVIRIS data: Decomposing biochemical from structural signals. **Remote Sensing of Environment**, n. 81, 2002. 355–364.

SIBANDA, M.; MUTANGA, O.; ROUGET, M. Examining the potential of Sentinel-2 MSI spectral resolution in quantifying above ground biomass across different fertilizer treatments. **ISPRS Journal of Photogrammetry and Remote Sensing**, 2015. v. 110, p. 55–65. Disponível em: <<http://dx.doi.org/10.1016/j.isprsjprs.2015.10.005>>.

SIEBEN, E.J.J.; COLLINS, N.B.; MTSHALI, H.; Venter, C.E. The Vegetation of Inland Wetlands with Salt-Tolerant Vegetation in South Africa: Description, Classification and Explanatory Environmental Factors. **South African Journal of Botany**, n 104 (May). p. 199–207. 2011. doi:10.1016/J.SAJB.2015.11.004.

SIFLEET, S.; Linwood, P.; Murray, B.C. **State of the Science on Coastal Blue Carbon**. A Summary for Policy Makers, 2011. Nicholas Institute for Environmental Policy Solutions. Report, May 2011, NIR 11-06.

SHIKAMAKI, J.; SANCHIRICO, J.N.; JARDINE, S.L. Global economic potential for reducing carbon dioxide emissions from mangrove loss. **Proceedings of the National Academy of Sciences of the United States of America**. vol. 109, n.36, 2012. 14369-14374.

SILVA, S. C. P. **Modelagem espectral para determinação da concentração e fluxo de CO₂ em paisagens naturais e antrópicas na região amazônica**. 2014. 173 f. Tese (Doutorado em Geociências aplicadas). Pós-Graduação em Geociências Aplicadas. Universidade de Brasília. Brasília - DF, 2014.

SILVA, T.S.F.; COSTA, M.P.F.; MELACK, J.M. Assessment of two biomass estimation methods for aquatic vegetation growing on the Amazon floodplain. **Aquatic Botany**. n. 92, 2010. 161–167.

_____.; _____.; _____.; NOVO, E.M.L.M. Remote sensing of aquatic vegetation: theory and applications. **Environmental Monitoring Assessment**, Netherlands, vol. 140, 2008. 131–145.

Simard, M., Fatoyinbo, L. E. and Pinto, N. 2010. “Mangrove Canopy 3D Structure and Ecosystem Productivity Using Active Remote Sensing”. In: **Remote Sensing of Coastal Environment**, Edited by: Wang, J. 61–78. Boca Raton, FL: CRC Press.

SIMIONI, J. P. D.; WOLLMANN, C. A. Comportamento do NDVI obtido por sensor ótico ativo na Estação Ecológica do Taim, RS, no ano de 2009: análise durante o verão, outono, inverno e primavera. **Revista Interface**, Edição nº 11, maio de 2016. 216-231.

_____.; Guasselli, L.A., Nascimento, V.F. Ruiz, L. F. C; Belloli, F. B. 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. pp 1–18 **Environ. Dev. Sustain** (2019). <https://doi.org/10.1007/s10668-019-00442-0>.

_____.; _____.; ETCHELAR, C. B. 2017. Connectivity among Wetlands of EPA of Banhado Grande, RS. **Revista Brasileira de Recursos Hídricos**, v.22, n.15. p. 1-11.

_____.; _____. Banhados: Abordagem Conceitual. **Boletim Geográfico do Rio Grande do Sul**. Porto Alegre, n. 30, set. 2017. 33-47.

_____.; V. F. Nascimento, L. A. Guasselli, L. F. C. Ruiz, and G. De Oliveira. 2018. “Small Inner Marsh Area Delimitation Using Remote Sensing Spectral Indexes and Decision Tree Method in Southern Brazil.” **Revista de Teledetección**, no. 52: 55. doi:10.4995/raet.2018.10366.

SUTTON-GRIER, A. E.; MOORE, A. Leveraging Carbon Services of Coastal Ecosystems for Habitat Protection and Restoration, **Coastal Management**, Vol. 44, n. 3, 2016. 259–277.

TAALAB, K.; CHENG, T.; ZHANG, Y. Mapping landslide susceptibility and types using Random Forest. **Big Earth Data**, v. 2, n. 2, p. 159–178, 2018. DOI: 10.1080/20964471.2018.1472392

TABILO-VALDIVIESO, E. **El Beneficio de los humedales en América Central: el potencial de los humedales para el desarrollo**. 2a. ed. Turrialba, C.R. : WWF ; Heredia, C.R. : Universidad Nacional, Programa Regional en Manejo de Vida Silvestre, 1999. 58 p.

TEDESCO, M. J.; GIANELLO, C.; BISSANI, C.A.; BOHNEN, H.; VOLKWEISS, S.J. **Análise do solo, plantas e outros materiais**. 2. ed. Porto Alegre: Departamento de Solos da UFRGS, 1995. 174 p.

TEIXEIRA, M. B.; COURA NETO, A. B.; PASTORE, U.; RANGEL FILHO, A. R. L. Vegetação: as regiões fitoecológicas, sua natureza e seus recursos econômicos. Estudo Fitogeográfico. In: **RADAMBRASIL**, v. 33. Folha SH.22, Porto Alegre e parte das folhas SH.21, Uruguaiana e SI.22 Lagoa Mirim: geologia, geomorfologia, pedologia, vegetação, uso potencial da terra. Rio de Janeiro: IBGE, 1986.

THOMAZ, S. M.; ESTEVES, F. A. Comunidades de macrófitas aquáticas. In: ESTEVES, F. A. (Org.). **Fundamentos de limnologia**. Rio de Janeiro: Interciência, 2011. 790 p.

TIAN, S.; ZHANG, X.; TIAN, J.; SUN, Q.R. Random forest classification of wetland landcovers from multi-sensor data in the arid region of Xinjiang, China. **Remote Sens**. V.8, p. 954, 2016.

WALT, S. V. D.; S. C. COLBERT.; G. The NumPy Array: A Structure for Efficient Numerical Computation. **Computing in Science & Engineering**, v. 13, n 2, p. 22-30, 2011. doi:10.1109/MCSE.2011.37.

TOMAZELLI, L. J.; VILLWOCK, J. A. (2000). O Cenozóico no Rio Grande do Sul: Geologia da Planície Costeira. In: HOLZ, M.; DE ROS, L. F. (Ed.). **Geologia do Rio Grande do Sul**. Porto Alegre: CIGO/UFRGS. p. 375–406.

TRENTIN, C. B. **Estoques de carbono nas áreas de vegetação campestre na APA do Ibirapuitã**. Tese. (Doutorado em Sensoriamento Remoto). 2015. 98 f. Programa de Pós-graduação em Sensoriamento Remoto. Universidade Federal do Rio Grande do Sul. Porto Alegre, 2015.

TURPIE, K.R., 2013. Explaining the spectral red-edge features of inundated marsh vegetation. *Journal of Coastal Research*, 29(5), p. 1111–1117. **Coconut Creek** (Florida), ISSN 0749-0208.

TUZCU, A, TASKIN, G. M. COMPARISON OF OBJECT BASED MACHINE LEARNING CLASSIFICATIONS OF PLANETSCOPE AND WORLDVIEW-3 SATELLITE IMAGES FOR LAND USE / COVER. **Remote Sensing and Spatial Information Sciences**, Volume XLII-2/W13, 2019. ISPRS Geospatial Week 2019, June 2019, Enschede, The Netherlands. <https://doi.org/10.5194/isprs-archives-XLII-2-W13-1887-2019>

BEIJMA, V.; COMBER, A.; LAMB, A. Random forest classification of salt marsh vegetation habitats using quad-polarimetric airborne SAR, elevation and optical RS data. **Remote Sens. Environ**. 2014, 149, 118–129.

VILLA, P.; BRAGA, F.; BRESCIANI, M.; BOLPAGNI, R. Comparative Assessment of Broadband Vegetation Indices Over Aquatic Vegetation. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, Published online, 2014. 3117-3127.

VILLA, P.; LAINI, A.; BRASCIANI, M.; BOLPAGNI, R. A remote sensing approach to monitor the conservation status of lacustrine *Phragmites australis* beds. **Wetlands Ecology and Management**, Published online, 2013. 1-18.

VILLWOCK, J. A.; DENHARDT, E. A.; LOSS, E. L.; HOFMISTER, T. Turfas da província costeira do Rio Grande do Sul - Geologia do depósito Águas Claras. In: XXXI

Congresso Brasileiro de Geologia. Volume 1. **Anais...**Sociedade Brasileira de Geologia, Balneário Camboriú. 1980.

VIRGILIO, L. R. M. S.; SUSÇUARANA, M. S.; RAMALHO, W. P.; AFFONSO, G. A.; ANDERSON, L. O.; BROWN, I. F. Resposta espectral dos índices EVI e NDVI dos bancos de macrófitas em lagos de meandro abandonado na região do Rio Purus, AM. In: Simpósio Brasileiro de Sensoriamento Remoto, (SBSR), 2013, Paraná. **Anais...** Foz do Iguaçu: INPE, 2013. 3183- 3190

VIS, C.; HUDON, C.; CARIGNAN, R. An evaluation of approaches used to determine the distribution and biomass of emergent and submerged aquatic macrophytes over large spatial scales. **Aquatic Botany**, n. 77, 2003. 187–201.

WATZLAWICK, L. F.; BALBINOT, R.; SANQUETTA, C. R.; CALDEIRA, M. V. W. Teores de carbono em espécies da Floresta Ombrófila Mista. In: SANQUETTA, C. R.; BALBINOT, R.; ZILIO, M. A. B. Fixação de carbono: atualidades, projetos e pesquisas. Curitiba: AM Impresses, p. 95-109, 2004.

WEICHEL, H, Rosso P, Marx A, Reigber S, Douglass K, Heynen M. 2011. White Paper–The RapidEye Red Edge Band. RapidEye White Papers: 1-6.

WEN, X.; ZHOU, Z.; CHEN, B. Li, Z.; TANG, X. 2014. Research on the features of chlorophyll-a derived from rapideye and EOS/MODIS data in chaohu lake. in IOP Conference Series: Earth and Environmental Science, p. 012111. IOP Publishing.

WHITING G. J.; CHANTON, J. P. Greenhouse carbon balance of wetlands: methane emission versus carbon sequestration. **Tellus**, UK, 53B, 2001. 521–528.

WHYTE, Andrew, Konstantinos P. Ferentinos, and George P. Petropoulos. 2018. “A New Synergistic Approach for Monitoring Wetlands Using Sentinels -1 and 2 Data with Object-Based Machine Learning Algorithms.” **Environmental Modelling & Software**, v. 104 (June). Elsevier: 40–54. doi:10.1016/J.ENVSOF.2018.01.023.

WILDHOLZER, F. L. **Banhados. Marshes - Rio Grande do Sul/Brasil**. Riocell S.A, 1986. 78p.

WORLD WILDLIFE FUND. 2012. **Blue carbon: A new concept for reducing the impacts of climate change by conserving coastal ecosystems in the Coral Triangle**. WWF-Australia, Brisbane, Queensland, Australia. 20 p.

WRIGHT, C.; GALLANT, A. Improved wetland remote sensing in Yellowstone National Park using Classification trees to combine TM imagery and ancillary environmental data. **Remote Sens. Environ.** 2007, 107, 582–605.

XIE, Q., DASH, J., HUANG, W., PENG, D., QIN, Q., MORTIMER, H., YE, H. (2018). Vegetation Indices Combining the Red and Red-Edge Spectral Information for Leaf Area Index Retrieval. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, 11(5), 1482-1492. <https://doi.org/10.1109/JSTARS.2018.2813281>

ZHANG, X. On the estimation of biomass of submerged vegetation using Landsat thematic mapper (TM) imagery: a case study of the Honghu Lake, PR China. **International Journal of Remote Sensing**. n. 19, 1998. 11–20.

ZHOU, W.; TROY, A. An object-oriented approach for analysing and characterizing urban landscape at the parcel level. **Int. J. Remote Sens.** 2008, 29, 3119–3135.

ANEXO A

Laudo de análise de carbono orgânico. Amostras coletadas no primeiro trabalho de campo.



FACULDADE DE AGRONOMIA - DEPARTAMENTO DE SOLOS
LABORATÓRIO DE ANÁLISES

LAUDO DE ANÁLISES

NOME: TÁSSIA BELLOLI

MUN.: GLORINHA

Data de entrada: 24/04/18

EST.: RS

Data de expedição: 24/05/18

REG.: T-061/2018

MATERIAL: FOLHAS DE SCIRPUS GIGANTEUS

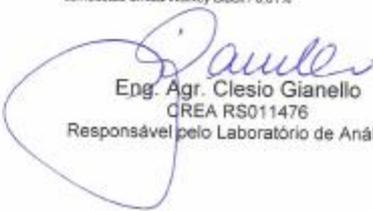
IDENT. DA AMOSTRA: FOLHAS DE MILHO

AMOSTRA	Carbono orgânico
	% (m/m)
01. A 1.1	41
02. A 1.2	42
03. A 1.3	43
04. A 2.1	42
05. A 2.2	42
06. A 2.3	43
07. A 3.1	42
08. A 3.2	43
09. A 3.3	42

Obs.: Resultados expressos no material seco a 65°C.

Parâmetros
Carbono orgânico

Metodologia aplicada / Limite de detecção:
combustão úmida/Walkley Block / 0,01%


Epg. Agr. Clesio Gianello
CREA RS011476
Responsável pelo Laboratório de Análises

ANEXO B

Laudo de análise de carbono orgânico. Amostras coletadas no segundo trabalho de campo.



FACULDADE DE AGRONOMIA - DEPARTAMENTO DE SOLOS
LABORATÓRIO DE ANÁLISES

LAUDO DE ANÁLISES

NOME: TÁSSIA BELLOLI

MUN.: GLORINHA

EST.: RS

Data de entrada: 13/09/18

Data de expedição: 28/09/18

REG.: T-097/2018

MATERIAL: FOLHAS DE SCIRPUS GIGANTEUS

AMOSTRA	Carbono orgânico
	% (m/m)
01. A 1.1	40
02. A 1.2	42
03. A 1.3	40
04. A 2.1	42
05. A 2.2	41
06. A 2.3	41
07. A 3.1	43
08. A 3.2	41
09. A 3.3	41

Obs.: Resultados expressos no material seco a 65°C.

Parâmetros
Carbono orgânico

Metodologia aplicada / Limite de detecção:
combustão úmida/Walkley Black / 0,01%


Eng. Agr. Clesio Gianello
CREA RS011476
Responsável pelo Laboratório de Análises

ANEXO C

Laudo de análise de carbono orgânico. Amostras coletadas no terceiro trabalho de campo.



FACULDADE DE AGRONOMIA - DEPARTAMENTO DE SOLOS

LABORATÓRIO DE ANÁLISES

LAUDO DE ANÁLISES

NOME: TÁSSIA BELLOLI

MUN.: GLORINHA

Data de entrada: 25/01/19

EST.: RS

Data de expedição: 06/02/19

REG.: T-005/2019

MATERIAL: FOLHAS DE SCIRPUS GIGANTEUS

AMOSTRA	Carbono orgânico	
	% (m/m)	
01. A 1.1	41	
02. A 1.2	41	
03. A 1.3	39	
04. A 2.1	39	
05. A 2.2	40	
06. A 2.3	40	
07. A 3.1	44	
08. A 3.2	41	
09. A 3.3	46	

Obs.: Resultados expressos no material seco a 65°C.

Parâmetros	Metodologia aplicada / Limite de detecção:
Carbono orgânico	combustão úmida/Walkey Black / 0,01%

Clesio Gianello
 Eng. Agr. Clesio Gianello
 CREA RS011476
 Responsável pelo Laboratório de Análises