



BEATRIZ CIRINO LUCCHETTA

**ESTIMAÇÃO DA CONCENTRAÇÃO DE CLOROFILA-A EM UM
SISTEMA DE AQUACULTURA A PARTIR DE IMAGENS
MULTIESPECTRAIS OBTIDAS VIA ARP**

DISSERTAÇÃO

PRESIDENTE PRUDENTE - SP

2024

BEATRIZ CIRINO LUCCHETTA

**ESTIMAÇÃO DA CONCENTRAÇÃO DE CLOROFILA-A EM UM
SISTEMA DE AQUICULTURA A PARTIR DE IMAGENS
MULTIESPECTRAIS OBTIDAS VIA ARP**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciências Cartográficas - PPGCC, da Universidade Estadual Paulista - Unesp, Faculdade de Ciências e Tecnologia - FCT, campus de Presidente Prudente, como parte dos requisitos para obtenção do título de Mestre em Ciências Cartográficas.

Orientador(a): Prof^a. Dr^a. Fernanda Sayuri Yoshino Watanabe

Co-orientador(a): Dr^a Nariane Marselhe Ribeiro Bernardo do Carmo

PRESIDENTE PRUDENTE - SP

2024

C578e	Cirino Lucchetta, Beatriz Estimação da concentração de clorofila-a em um Sistema de Aquacultura a partir de Imagens Multiespectrais obtidas via ARP / Beatriz Cirino Lucchetta. -- Presidente Prudente, 2024 115 p. Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Faculdade de Ciências e Tecnologia, Presidente Prudente Orientadora: Fernanda Sayuri Yoshino Watanabe Coorientadora: Nariane Marselhe Ribeiro Bernardo do Carmo 1. Sens. Remoto da Cor da Água. 2. Alta Resolução Espacial. 3. Modelagem Bio-Óptica. 4. Dados Radiométricos. 5. Monitoramento da Qualidade da Água. I. Título.
-------	---

DESCRIÇÃO DO IMPACTO ESPERADO NA SOCIEDADE

O presente estudo busca avançar na ciência e tecnologia do monitoramento da qualidade da água por meio do sensoriamento remoto (SR) com Aeronaves Remotamente Pilotadas (ARPs). O trabalho apresenta potencial inovador ao superar desafios ópticos e fotogramétricos, utilizando novos sensores (câmera *Agrowing*) para estimar concentrações de clorofila-a (chl-a), facilitando a tomada de decisões na gestão da piscicultura. A chl-a é um indicador essencial da qualidade da água, impactando diretamente a produtividade e sustentabilidade da atividade.

A pesquisa está alinhada aos Objetivos de Desenvolvimento Sustentável (ODS). Em relação ao ODS 6 (água potável e saneamento), contribui para a gestão eficiente dos recursos hídricos. No ODS 9 (indústria, inovação e infraestrutura), fomenta soluções tecnológicas para o monitoramento ambiental. Para mais, o ODS 14 (vida na água), promove a conservação e uso sustentável dos ecossistemas aquáticos.

O estudo tem forte inserção regional ao investigar corpos d'água no Centro Nacional de Pesquisa e Conservação de Peixes Continentais (CEPTA), referência na pesquisa e conservação da ictiofauna no Brasil, localizado em Pirassununga/SP. Sua posição estratégica permite o monitoramento de ecossistemas locais e a geração de dados relevantes para a biodiversidade.

O monitoramento contínuo de corpos d'água de pequenas dimensões, por meio do SR, pode servir de subsídio para que autoridades ambientais tomem decisões baseadas em dados preditivos para implementar políticas mais eficazes de conservação. A modelagem bio-óptica avançada (com o uso de algoritmos de aprendizado de máquina), otimizada pelo SR e tecnologias de automação, reduz custos operacionais e promove um controle ambiental mais acessível e eficiente.

Por fim, o estudo reforça a interdisciplinaridade entre ciência ambiental e inteligência artificial, consolidando-se como uma abordagem promissora para a gestão sustentável dos recursos hídricos e a conservação da biodiversidade aquática.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: **Estimação da concentração de clorofila-a em um sistema de aquicultura a partir de imagens multiespectrais obtidas via ARP**

AUTORA: BEATRIZ CIRINO LUCCHETTA

ORIENTADORA: FERNANDA SAYURI YOSHINO WATANABE

COORDINADORA: NARIANE MARSELHE RIBEIRO BERNARDO DO CARMO

Aprovada como parte das exigências para obtenção do Título de Mestra em Ciências Cartográficas, área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:

Documento assinado digitalmente
 **FERNANDA SAYURI YOSHINO WATANABE**
Data: 21/11/2024 22:53:42-0300
Verifique em <https://validar.iti.gov.br>

Documento assinado digitalmente
 **CLAUDIO CLEMENTE FARIA BARBOSA**
Data: 24/01/2025 16:54:11-0300
Verifique em <https://validar.iti.gov.br>

Documento assinado digitalmente
 **NILTON NOBUHIRO IMAI**
Data: 10/02/2025 17:28:45-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. FERNANDA SAYURI YOSHINO WATANABE (Participação Virtual)
Departamento de Cartografia / Universidade Estadual Paulista "Júlio de Mesquita Filho" - Faculdade de Ciências e Tecnologia

Prof. Dr. NILTON NOBUHIRO IMAI (Participação Virtual)
Departamento de Cartografia / Universidade Estadual Paulista "Júlio de Mesquita Filho" - Faculdade de Ciências e Tecnologia

Prof. Dr. CLÁUDIO CLEMENTE FARIA BARBOSA (Participação Virtual)
Divisão de Processamento de Imagens / Instituto Nacional de Pesquisas Espaciais - INPE

Presidente Prudente, 21 de novembro de 2024

Dedico aos meus pais, Silvia e Renato, ao meu irmão, Leonardo, e aos meus amigos, por todo apoio, confiança e paciência. Sem vocês nada seria possível.

AGRADECIMENTOS

A todos que contribuíram para a realização desse projeto, mesmo que direta ou indiretamente, deixo aqui o meu singelo agradecimento:

Primeiramente, agradeço à Deus por permitir que eu viva um sonho, por ajudar a enfrentar todos os desafios, porque sei que Ele está sempre comigo.

Aos meus pais, Silvia e Renato, ao meu irmão, Leonardo, e aos meus amigos, Fernanda, Ricardo, Gustavo Roncolato, Emanuele, Beatriz, Mariana, Breno, Gustavo Martines e Tatiana, pela paciência, apoio, confiança e incentivo. Por me lembrarem todos os dias que eu sou capaz de conquistar o que almejo. Sempre saberei que posso contar com vocês.

À minha orientadora, Prof^a Fernanda Sayuri Yoshino Watanabe, muito obrigada por confiar em mim todos esses anos, por todos os ensinamentos e por todas oportunidades alcançadas. Obrigada por ser meu exemplo, alguém que eu me espelho.

Aos meus colegas, Gustavo, Rafael, Renata e Otávio, pelo auxílio nas campanhas em campo, por enfrentarem os “perrengues” comigo, além de tudo, eu me diverti muito com vocês.

Aos membros da Inspectral, sobretudo, à Nariane e ao Alisson, pela confiança e suporte no desenvolvimento das partes teóricas e práticas desse projeto. Espero de alguma forma ter contribuído com vocês, de tal modo grandioso que me permitiram realizar esse trabalho.

Aos servidores do CEPTA/ICMBio, que nos receberam muito bem e não mediram esforços para o bom andamento dos trabalhos em campo. Fernando, Izabel, Davi, Carla, Luciana e os barqueiros, obrigada!

Ao PPGCC e a FCT/Unesp, aos professores do programa de pós graduação, em especial, aos professores Nilton Nobuhiro Imai, Maria de Lourdes Bueno Trindade Galo e Antonio Maria Garcia Tommaselli, pelo conhecimento compartilhado e suporte no desenvolvimento desse trabalho. Aos funcionários do departamento de Cartografia, a Cinthia e a Aline da seção de pós-graduação, muito obrigada!

À Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP pelo Projeto Temático (Processo Nº 2021/06029-7) e pelo Projeto PIPE 2 (Processo Nº 2021/11296-4); também à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES (88887.310313/2018-00) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq (303670/2018-5), pelo financiamento

e concessão de bolsas de pesquisa durante o desenvolvimento do trabalho de mestrado e auxílio financeiro para as campanhas de campo.

*Somewhere, something incredible is
waiting to be known.
(Carl Sagan)*

RESUMO

A clorofila-a (chl-a) é um importante indicador da produção primária e, consequentemente, da qualidade da água, essencial para a existência de ecossistemas aquáticos. O monitoramento da qualidade da água pode ser realizado por meio de imagens provenientes de sensores remotos: satélites e aeronaves remotamente pilotadas (ARPs). ARPs são um método alternativo para monitorar pequenos recursos hídricos, uma vez que permitem a coleta de dados com alta resolução espacial. Entretanto, desafios como reflexão especular e homogeneidade espectral da água podem dificultar o alinhamento fotogramétrico e precisam ser contornados. A trajetória de voo deve ser planejada para minimizar reflexos indesejados da luz solar. O presente estudo foi realizado em tanques de piscicultura, duas represas para alimentação dos tanques e um trecho do rio Mojiguaçu, localizados no Centro Nacional de Pesquisa e Conservação da Biodiversidade Aquática Continental – CEPTA, em Pirassununga/SP. A análise da qualidade da água do sistema de aquicultura foi realizada por meio da tomada de imagens da área com uma câmara *Agrowing* acoplada à ARP *DJI Matrice 300 RTK*. Para compatibilizar imagens capturadas pelo sensor multiespectral e a resposta espectral da superfície da Terra, medidas com espectrorradiômetro, foram aplicados dois métodos de calibração radiométrica, baseados em linha empírica, linear e exponencial. Os métodos foram testados com diversos alvos de calibração, incluindo alvos de água, para corrigir valores negativos de reflectância. O método exponencial revelou-se mais apropriado, com uma acurácia superior em relação ao método linear. Técnicas de regressão de aprendizado de máquina: *Random Forest* (RF) e *Multilayer Perceptron* (MLP), além da Regressão Linear Multivariada (MLR), foram usadas para construir modelos bio-ópticos para a estimação e mapeamento da concentração de chl-a. Dois voos (VOO1 e VOO2) foram realizados para abranger toda a área de estudo. A MLR e o RF resultaram em métricas satisfatórias para ambos os voos, de aproximadamente 12 µg/L para o RMSE, 20% para a NRMSE, -1 para o *bias* e 0,7 para o R^2 . Por sua vez, o modelo baseado em MLP não gerou bons resultados para o VOO2. O presente estudo demonstrou um grande potencial para a utilização de dados de alta resolução espacial para a estimação do conteúdo de chl-a de corpos d'água de pequenas extensões, pouco estudados quando comparados à grandes rios e reservatórios.

Palavras-chave: Sensoriamento Remoto da Cor da Água; Alta Resolução Espacial; Modelagem Bio-Óptica; Dados Radiométricos; Monitoramento da Qualidade da Água.

ABSTRACT

Chlorophyll-a (chl-a) is an important indicator of primary production and, consequently, of water quality, essential for the existence of aquatic ecosystems. Water quality monitoring can be carried out using images from remote sensors: satellites and remotely piloted aircraft (RPAs). RPAs are an alternative method for monitoring small water bodies, as they allow data collection with high spatial resolution. However, challenges such as specular reflection and the spectral homogeneity of water can hinder photogrammetric alignment and need to be addressed. The flight path should be planned to minimize unwanted sunlight reflections. The present study was conducted in aquaculture tanks, two reservoirs supplying the tanks, and a section of the Mojiguaçu River, located at the National Research and Conservation Center for Continental Aquatic Biodiversity – CEPTA, in Pirassununga/SP, Brazil. The water quality analysis of the aquaculture system was performed using images captured by an Agrowing camera mounted on a DJI Matrice 300 RTK RPA. To align the images captured by the multispectral sensor with the spectral response of the Earth's surface, as measured with a spectroradiometer, two radiometric calibration methods were applied: empirical line-based, both linear and exponential. These methods were tested with various calibration targets, including water targets, to correct negative reflectance values. The exponential method proved to be more suitable, with greater accuracy compared to the linear method. Machine learning regression techniques—Random Forest (RF) and Multilayer Perceptron (MLP)—as well as Multivariate Linear Regression (MLR), were used to develop bio-optical models for estimating and mapping chl-a concentration. Two flights (Flight 1 and Flight 2) were conducted to cover the entire study area. MLR and RF produced satisfactory metrics for both flights, with approximately 12 $\mu\text{g/L}$ for RMSE, 20% for NRMSE, -1 for bias, and 0.7 for R^2 . On the other hand, the MLP-based model did not yield good results for Flight 2. This study demonstrated significant potential for using high spatial resolution data to estimate chl-a content in small water bodies, which are less studied compared to large rivers and reservoirs.

Keywords: Remote Sensing of Water Color; High Spatial Resolution; Bio-Optical Modeling; Radiometric Data; Water Quality Monitoring.

LISTA DE FIGURAS

Figura 1 — Interações da luz entre componentes aquáticos e sensores. Fonte: DORNHOFFER; OPPELT (2016).	20
Figura 2 — Espectros de absorção (linha sólida) e de espalhamento (linha pontilhada) da água pura. Fonte: Barbosa et al. (2019).	25
Figura 3 — Reflectância da superfície da água variando com o aumento das concentrações de chl-a, sendo (a) concentrações entre 340 e 2190 $\mu\text{g/L}$ e (b) concentrações entre 156 e 277 $\mu\text{g/L}$. Fonte: Rundquist et al. (1996).	27
Figura 4 — Estrutura do algoritmo RF Regression.	32
Figura 5 — Estrutura básica de uma rede neural MLP.	33
Figura 6 — Fluxograma com os procedimentos metodológicos desenvolvidos nesse trabalho.	35
Figura 7 — Mapa da área de estudo, em que (a) corresponde a região do CEPTA/ICMBio, com destaque para os corpos d'água de interesse para o estudo; (b) a localização do CEPTA no município de Pirassununga e (c) a localização no estado de São Paulo.	37
Figura 8 — Fotos dos tanques de piscicultura, os quais apresentam diferentes características físicas e bio-ópticas.	38
Figura 9 — Fotos dos reservatórios e rio Mojiguaçu, que apresentam diferentes aspectos da cor da água e, portanto, diferentes características físicas e bio-ópticas.	39
Figura 10 — (a) Sonda multiparâmetros (Horiba U-50) com monitor, cabo de 30 m e sonda submersível; (b) monitor mostrando variáveis registradas.	41
Figura 11 — Espectrorradiômetro ASD FieldSpec® HandHeld UV/NIR utilizado para obtenção de medidas de radiométricas in situ.	43
Figura 12 — Câmara Sony Alpha 7R _{XXX} (Agrowing), com seis cabeças e 14 bandas espectrais.	44
Figura 13 — Respostas espectrais dos filtros (luz colimada) da câmara Agrowing (Adaptado de https://Agrowing.com/products/alpha-7riv-sextuple/).	46
Figura 14 — ARP Matrice 300 RTK sobre uma lona pronta para a decolagem.	47
Figura 15 — Placa cinza de campo, cuja radiância foi medida em laboratório, com o auxílio de uma lanterna de luz halógena e um espectrorradiômetro.	49

Figura 16 — Alvos de referência em quatro cores: branco (1AV e 1CO), cinza claro (2AV e 2CO), cinza escuro (3CO) e preto (3AV e 4CO), para a calibração radiométrica das imagens.	52
Figura 17 — Alvos nos corpos d'água (tanque A62 e tanque A30) utilizados para calibração radiométrica das imagens como espectros de menor reflectância.	53
Figura 18 — Respostas espectrais em Rrs, estimadas a partir dos dados de L, coletadas in situ. (a) são as curvas espectrais de todas as amostras dos tanques de piscicultura, (b) curvas espectrais do rio, (c) curvas espectrais dos reservatórios.	64
Figura 19 — Ortomosaicos gerados a partir das imagens coletadas via ARP em ND..	66
Figura 20 — Ajuste linear (VOO1) das bandas 560 nm, 650 nm, 685 nm, 710 nm e 735 nm, juntamente com a equação da reta e o coeficiente de determinação correspondente.	69
Figura 21 — Bias aplicado como uma correção por banda, por meio de uma multiplicação, posteriormente a calibração radiométrica linear, do VOO1.	70
Figura 22 — Ajuste exponencial (VOO1) das bandas 560 nm, 650 nm, 685 nm, 710 nm e 735 nm, juntamente com a equação da reta e o coeficiente de determinação correspondente.	71
Figura 23 — Bias aplicado como uma correção por banda, por meio de uma multiplicação, posteriormente a calibração radiométrica exponencial, do VOO1.	72
Figura 24 — Ajuste linear (VOO2) das bandas 560 nm, 650 nm, 685 nm, 710 nm e 735 nm, juntamente com a equação da reta e o coeficiente de determinação correspondente.	73
Figura 25 — Bias aplicado como uma correção por banda, por meio de uma multiplicação, posteriormente a calibração radiométrica linear, do VOO2.	74
Figura 26 — Ajuste exponencial (VOO2) das bandas 560 nm, 650 nm, 685 nm, 710 nm e 735 nm, juntamente com a equação da reta e o coeficiente de determinação correspondente.	75
Figura 27 — Bias aplicado como uma correção por banda, por meio de uma multiplicação, posteriormente a calibração radiométrica exponencial, do VOO2.	75
Figura 28 — Buffer box de 3x3 pixels, ao redor da coordenada de coleta de chl-a, cujo valor de concentração era conhecido.	77
Figura 29 — Gráficos de dispersão dos valores de chl-a ($\mu\text{g/L}$), considerando os valores medidos em campo e os valores preditos pelos modelos MLR, RF e MLP, gerados a partir dos dados provenientes da calibração radiométrica linear.	79

Figura 30 — Gráficos de dispersão dos valores de chl-a ($\mu\text{g/L}$), considerando os valores medidos em campo e os valores preditos pelos modelos MLR, RF e MLP, gerados a partir dos dados provenientes da calibração radiométrica exponencial.	80
Figura 31 — Os gráficos de dispersão dos modelos MLR, RF e MLP, dos voos 1 e 2, apenas para o método de calibração radiométrica exponencial.	83
Figura 32 — Mapa da distribuição espacial de chl-a, estimada por meio do modelo bio- óptico RF, oriundo das imagens calibradas radiometricamente pelo método exponencial.	85
Figura 33 — Mapa da distribuição espacial de chl-a, estimada por meio do modelo bio- óptico MLP, oriundo das imagens calibradas radiometricamente pelo método exponencial.	86

LISTA DE TABELAS

Tabela 1 - Quantidade de pontos coletados nos diferentes tipos de corpos d'água, em cada campanha de campo realizada.	40
Tabela 2 - Comprimentos de ondas centrais, região espectral e largura de banda (Full Width Half Maximun - FWHM) de cada uma das 14 bandas da câmara Agrowing.	45
Tabela 3 - Características da câmara Sony Alpha 7R _{XXX} e lente multiespectral, da Agrowing.	45
Tabela 4 - Tabela contendo os índices espectrais de estimação de chl-a testados para a construção dos modelos bio-ópticos para a estimação das concentrações de chl-a do sistema de aquacultura, no CEPTA/ICMBio. Na tabela estão contidas a identificação do índice espectral ou algoritmo, a fórmula adaptada para as bandas da câmara Agrowing, a significância, área de aplicação e referência.	56
Tabela 5 - Estatísticas descritivas dos parâmetros limnológicos coletados in situ, por meio da sonda multiparâmetros (Turbidez, OD, STD, Temperatura, pH e Condutividade Elétrica), disco de Secchi (Profundidade do disco de Secchi) e destinados a análises laboratoriais (chl-a).....	61
Tabela 6 - Dados utilizados para o desenvolvimento dos modelos de calibrações radiométricas linear e exponencial do VOO1.....	68
Tabela 7 - Dados utilizados para o desenvolvimento dos modelos de calibrações radiométricas linear e exponencial do VOO2.....	73
Tabela 8 - Resultados da performance da aplicação dos modelos linear e exponencial, depois da aplicação do bias como fator de correção, expressos em RMSE, NRMSE e bias.	76
Tabela 9 - Performance dos modelos MLR, RF e MLP, para as amostras coletadas em julho de 2023, de acordo com ajuste radiométrico linear ou exponencial.	78
Tabela 10 - Desempenho dos modelos MLR, RF e MPL na estimação da concentração de chl-a em diferentes datas e diferentes corpos d'água que compõem o sistema de aquacultura, considerando o voo realizado e o método de calibração radiométrico das imagens.....	81
Tabela 1A - Tabela com os experimentos para a seleção dos atributos de entradas para a construção dos modelos bio-ópticos, em que estão dispostos, o número de amostras utilizadas, qual o modelo aplicado, o valor do k-fold e quatro métricas avaliativas....	108

LISTA DE ABREVIATURAS

μm – Micrometro;

A – Absortância;

a – Coeficiente de Absorção;

AdaBoost - Adaptive Boosting;

ARP – Aeronaves Remotamente Pilotadas;

AV – Avulso;

b – Coeficiente de Espalhamento;

B – Escaterância;

b_b – Retroespalhamento;

b_f – Espalhamento Frontal;

C – Celsius;

c – Coeficiente de Atenuação;

c – Velocidade no Vácuo;

CDOM – Matéria Orgânica Dissolvida Colorida;

CEPTA - Centro Nacional de Pesquisa e Conservação da Biodiversidade Aquática Continental;

CO – Conjunto;

COAs – Componentes Opticamente Ativos

CO₂ – Dióxido de Carbono;

E – Irradiância;

E.V.A - Etil Vinil Acetato;

E_d – Irradiância Descendente;

ENVI - *Environmental for Visualizing Images*;

E_u – Irradiância Ascendente;

FAPESP - Fundação de Amparo à Pesquisa no Estado de São Paulo;

FC – Fator de Correção;

FWHM - *Full Width Half Maximun*;

GNSS - *Global Navigation Satellite System*;

GSD - *Ground Sample Distance*;

H – Constante de Planck;

ICMBio – Instituto Chico Mendes de Biodiversidade;

J – Joules;

Js – Joule segundo;

K_d – Coeficiente de Atenuação Vertical;

km – Quilômetros;

L – Radiância;

L_g – Radiância Uniforme da Placa Cinza de Calibração de Campo;

L_S – Radiância Incidente do Céu;

L_t – Radiância Total;

m – Metros;

m/s – Metros por segundo;

MAE – *Mean Absolut Error*;

mg/m³ – Miligrama por metro cúbico;

ml – Mililitro;

MLP – *Multilayer Perceptron*;

MLR – Regressão Linear Multivariada;

mS/cm - Micro-Siemens por centímetro;

Mtry – Nós da árvore;

mV – Milivolt;

N – Número de Amostras;

NAN – Valores Nulos;

ND – Números Digitais;

NIR – Infravermelho Próximo;

Nm – Nanômetros;

NRMSE - *Normalized Root Mean Square Error*;

Ntree – Número de árvores;

° - Graus;

O₂ – Gás Oxigênio;

OD – Oxigênio Dissolvido;

PAR – Radiação Fotossinteticamente Disponível;

POA – Propriedades Ópticas Aparentes;

POI – Propriedades Ópticas Inerentes;

PPK - *Post Processed Kinematic*;

QGIS – *Quantum GIS*;

R – Coeficiente de Correlação;

r – Rspessura;

R^2 – Coeficiente de Determinação;
 RAE – *Relative Absolut Error*;
 RF – *Random Forest*;
 R_g – Valor do fator de correção proveniente das placas lambertianas medidas em laboratório, multiplicado pela medida de radiância da placa cinza de campo;
 RMSE - *Root Mean Square Error*;
 Rrs – Reflectância de Sensoriamento Remoto;
 RTK - *Real Time Kinematic*;
 S – *South*;
 S_B – Função de Filtro Espectral;
 SP – São Paulo;
 SR – Sensoriamento Remoto;
 sr^{-1} - Inverso do esferorradiano;
 STD – Sedimentos Totais Dissolvidos;
 TSS – Sólidos Totais em Suspensão;
 W – *West*;
 W/m^2 – Watts por metro quadrado;
 Weka - *Waikato Enviroment for Knowledge Analysis*;
 XGBoost - *Extreme Gradient Boosting*;
 β – Espalhamento Volumétrico;
 ε – Fóton;
 θ – Ângulo Zenital;
 θ_n – Ângulo Nadir;
 λ – Comprimento de Onda;
 ρ – Fator de proporcionalidade (0,028) relacionado a velocidade do vento e o ângulo zenital solar, no instante da leitura;
 ν – Frequência;
 ϕ – Ângulo Azimutal;
 Φ – Fluxo Radiante;
 ω - Direção;

SUMÁRIO

1 INTRODUÇÃO.....	18
2 OBJETIVOS.....	22
2.1 Objetivos Específicos	22
3 FUNDAMENTAÇÃO TEÓRICA	22
3.1 Sistema de Aquacultura	22
3.2 Sensoriamento Remoto da Cor da Água.....	23
3.2.1 Resposta espectral da água	23
3.3 Modelagem Bio-Óptica	28
3.4 Modelos Regressivos	30
3.4.1 <i>Multivariate Linear Regression</i> (MLR).....	30
3.4.2 <i>Random Forest</i> Regressivo.....	31
3.4.3 <i>Multilayer Perceptron</i> (MLP).....	32
3.5 Imagens Multiespectrais Obtidas por meio de ARPs	33
4 MATERIAIS E MÉTODOS.....	34
4.1 Área de Estudo.....	36
4.1.1 Características dos corpos d'água.....	37
4.2 Levantamentos em Campo	39
4.2.1 Coleta de água e medição de parâmetros físico-químicos	41
4.2.2 Aquisição de dados com o espectrorradiômetro	42
4.2.3 Aquisição das Imagens	44
4.3 Determinação da reflectância de sensoriamento remoto (<i>Rrs</i>).....	47
4.3.1 Simulação de Bandas	49
4.4 Processamento da Imagens	50
4.4.1 Calibração Radiométrica das Imagens.....	51
4.5 Calibração do Modelo Bio-Óptico	54
4.5.1 Seleção de atributos de entrada.....	55
4.5.2 Validação do modelo bio-óptico	59
5 RESULTADOS E DISCUSSÕES.....	60
5.1 Estatística Descritiva dos Parâmetros Limnológicos adquiridos <i>in situ</i> e em Laboratório	60
5.2 Comportamento Espectral da <i>Rrs</i>	63
5.3 Ortomosaico gerado a partir das imagens coletadas via ARP	66
5.4 Calibração radiométrica das imagens por linha empírica usando modelos linear e exponencial.....	67
5.5 Estimação da concentração de chl-a por meio dos modelos MLR, RF e MLP, baseado nos diferentes métodos de calibração radiométrica	76
5.6 Concentrações de Chl-a Estimadas Espacialmente	84
6 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES PARA TRABALHOS FUTUROS.....	87
REFERÊNCIAS	90

1 INTRODUÇÃO

A biodiversidade aquática é composta por seres que vivem seu ciclo biológico parcial ou totalmente em ecossistemas aquáticos continentais, costeiros ou marinhos. Corpos d'água abundantes nutridos pela energia em forma de radiação solar, dióxido de carbono (CO₂) e minerais são favoráveis ao desenvolvimento de espécies vegetais e micro-organismos, como o fitoplâncton, os quais compõem diferentes ecossistemas aquáticos (KIRK, 2011). O fitoplâncton é o produtor primário mais abundante em águas interiores e oceânicas, e a comunidade fitoplanctônica possui alta significância na produção do gás oxigênio (O₂) global e ciclos biogeoquímicos do planeta (FIELD *et al.*, 1998).

Por sua vez, o enriquecimento excessivo de um corpo d'água com nutrientes, processo chamado de eutrofização, pode levar a uma produção descontrolada de organismos fitoplanctônicos, resultando em floração de algas. A alta taxa de eutrofização reduz a qualidade da água, altera propriedades físico-químicas, prejudica fauna e flora, e gera condições inadequadas para o consumo humano (SMITH *et al.*, 1999; ANSARI *et al.*, 2011). Dessa forma, o monitoramento regular de parâmetros, como a clorofila-a (chl-a), podem ser essenciais para gestão sustentável dos recursos hídricos e detecção precoce de problemas de degradação da água (FALKOWSKI e RAVEN, 2013).

O monitoramento da abundância do fitoplâncton nos corpos d'água, os quais são opticamente complexos, é realizado a partir do pigmento fotossintético chl-a (MATTHEWS, 2017). A chl-a é uma componente opticamente ativa, cujos picos de absorção espectral estão nas regiões do azul e vermelho do espectro eletromagnético. Bricaud *et al.*, (1995) determinaram que a chl-a apresenta absorção entre os comprimentos de onda de 430 até 676 nm (pico da absorção). Gitelson *et al.* (1992) ainda encontraram uma alta absorção na região do vermelho e um mínimo de absorção no infravermelho próximo (NIR).

Dados de sensoriamento remoto (SR) multiespectral e hiperespectral são amplamente empregados em diversos estudos para a estimativa da concentração de chl-a em corpos d'água. A maior parte dos trabalhos se baseiam no uso de algoritmos e/ou razão de bandas espectrais, por meio de uma relação empírica entre valores de radiância ou reflectância com a concentração de chl-a (DALL'OLMO *et al.*, 2005; GITELSON *et al.*, 2008; LE *et al.*, 2009; MISHRA & MISHRA, 2012).

Diferentes algoritmos foram desenvolvidos para estimar a concentração da chl-a, sendo a maioria baseados em duas feições espectrais específicas: a baixa absorção da luz na borda do vermelho (*red edge*), aproximadamente 705 nm, e o pico de absorção na região do vermelho, próximo a 675 nm (DALL'OLMO *et al.*, 2005; GITELSON *et al.*, 2008; LE *et al.*, 2009; MISHRA & MISHRA, 2012). Gitelson *et al.* (2003) otimizaram um modelo de três bandas, utilizando os comprimentos de onda de 684 nm, 700 nm e 720 nm, para estimar a concentração de chl-a em águas turvas na costa da Rússia. Gurlin *et al.* (2011) utilizaram bandas centradas nos comprimentos de onda de 665 nm, 705 nm e 740 nm para estimar chl-a em águas eutrofizadas, por meio sensores MERIS e MODIS.

Algoritmos que utilizam, principalmente, reflectâncias no azul e verde (440 nm – 560 nm) são empregados na estimativa do conteúdo de chl-a em águas oceânicas (GORDON e MOREL, 1983; CARDER *et al.*, 1999; IOCCG, 2000). Comprimentos de onda do vermelho (650 nm) e NIR (a partir de 780 nm) geralmente são utilizados para a recuperação do parâmetro chl-a em água turvas, com excesso de matéria orgânica dissolvida colorida (CDOM) (GITELSON *et al.*, 2007). CDOM é altamente absorvido nos comprimentos de onda azul (430 nm) e verde da luz e é espalhado por fluorescência (GILERSON *et al.*, 2010; LUO *et al.*, 2021), mascarando as feições espectrais da chl-a.

Métodos utilizando multibandas espectrais, equações de regressão e equações diferenciais de primeira ordem também são comparados na estimativa da concentração de chl-a, com base em dados de SR multiespectral e hiperespectral. A análise multibanda se destaca quando comparada ao uso de apenas uma ou duas bandas espectrais, oferecendo uma maior capacidade de detecção e precisão na estimativa de parâmetros, em ambientes aquáticos complexos (ZHU *et al.*, 2014).

Apesar da dificuldade da estimação da concentração de chl-a em águas turvas (opticamente complexas), Ansper e Alikas (2018) mostraram que para concentrações de chl-a até 150 mg/m³, algoritmos de três bandas, utilizando os comprimentos de onda do vermelho e NIR são promissores. Em contrapartida, algoritmos de quatro bandas são favoráveis na eliminação dos efeitos de sólidos totais em suspensão (TSS).

Modelos semi-empíricos de duas e três bandas, usando dados de reflectância e dados de radar, foram avaliados por Zhang *et al.* (2018), por meio da regressão linear multivariada (MLR) e uma rede *multilayer perceptron* (MLP), em que o MLR se mostrou mais estável do que o MLP. Por sua vez, Pahlevan *et al.* (2020) são pioneiros na introdução de modelos de aprendizado de máquina e *Mixture Density Network*. Eles utilizaram um banco de dados com 2943 amostras de chl-a e dados radiométricos

coletados *in situ* para treinamento, os quais foram aplicados a diferentes corpos d'águas, interiores e costeiros, alcançando ótimo desempenho quando comparados a algoritmos ajustados por mínimos quadrados

A aquisição de dados para o monitoramento da chl-a pode ser realizado por meio de técnicas de SR, sobretudo o imageamento por satélites de diferentes resoluções espaciais e temporais, aviões e aeronaves remotamente pilotadas (ARPs). A Figura 1 mostra a interação entre a luz solar e os componentes que qualificam a água, a interação com a atmosfera, bem como os sensores que captam a luz refletida.




Figura 1 — Interações da luz entre componentes aquáticos e sensores. Fonte: DORNHOFFER; OPPELT (2016).

A maioria dos estudos sobre a estimação de parâmetros limnológicos por SR utiliza sensores orbitais de média ou baixa resolução espacial para aplicações em recursos hídricos de grandes extensões (WANG & CHEN, 2024; SANTOS *et al.*, 2024; MPAKAIRI *et al.*, 2024; SINGH *et al.*, 2024; JANG *et al.*, 2024; TAN *et al.*, 2024). No entanto, esses produtos não são adequados para monitorar pequenos corpos d'água, em decorrência da resolução espacial.

Recentemente, imagens multiespectrais obtidas por ARPs têm sido exploradas como uma alternativa promissora para estimativas de chl-a em pequenos corpos d'água, permitindo uma maior precisão na análise, uma vez que capturam cenas com altíssima

resolução espacial, chegando à escala centimétrica (OLIVETTI *et al.*, 2020; CHENG *et al.*, 2020; ALVAREZ *et al.*, 2021; HASHEMI-BENI & GEBREHUWOT, 2021; ISGRÓ *et al.*, 2022; XIAO *et al.*, 2023; CHEN *et al.*, 2024; SONG *et al.*, 2024).

Para mais, o uso de imagens provenientes de ARPs pode reduzir ou excluir a necessidade de laboriosas coletas de dados *in situ*, além de gerar uma fonte complementar de dados (ROTTA *et al.*, 2011; NOVO *et al.*, 1989). A alta resolução espacial centimétrica pode contribuir com valiosas informações sobre qualidade da água, sobretudo de corpos d'água interiores de pequenas dimensões pouco explorados (CILLERO CASTRO *et al.*, 2020), como lagos, açudes, represas, pântanos, riachos, brejos e tanques escavados para a aquacultura. Contudo, a alta resolução espacial também resulta em um maior efeito especular, sendo necessárias, em alguns casos, alternativas para correção de *sunlint*.

As plataformas de ARPs podem fornecer alta resolução espacial e temporal e, também, alta resolução espectral dependendo da câmara a ser transportada. A hipótese deste trabalho é que imagens de alta resolução obtidas de câmaras multiespectrais embarcadas em ARP sejam adequadas para a geração de modelos bio-ópticos de estimação do conteúdo de chl-a, em corpos d'água de pequenas dimensões. Neste estudo, foi utilizada a câmara multiespectral *Sony Alpha 7R_{XXX} Sextuple*, da *Agrowing*, que possui seis cabeças (lentes ópticas) e registra 14 bandas espectrais. Ela foi acoplada à ARP *Matrice 300 RTK (DJI Innovations)* para capturar imagens, que foram usadas para desenvolver modelos bio-ópticos, por meio de algoritmos regressivos estatísticos e de aprendizado de máquina, para a recuperação da concentração de chl-a em pequenos corpos d'água.

Com o objetivo é desenvolver uma metodologia para monitorar corpos d'água de pequeno porte, o estudo foi conduzido em um sistema de aquacultura localizado no Centro Nacional de Pesquisa e Conservação da Biodiversidade Aquática Continental – CEPTA. Embora o CEPTA apresente um ambiente controlado para pesquisas, avaliar a qualidade da água pode servir de base para outros locais onde a aquacultura é praticada.

Esta dissertação estava inserida no contexto do projeto PIPE fase 2, Processo Nº 2021/03110-8, financiado pela Fundação de Amparo à Pesquisa no Estado de São Paulo - FAPESP, em desenvolvimento pela empresa *Inspectral*, que tinha o objetivo gerar um método de monitoramento contínuo, integrado e automatizado de macrófitas, além de outros parâmetros limnológicos, independente de análises de campo, coletas e análises laboratoriais.

2 OBJETIVOS

O objetivo principal deste estudo foi desenvolver modelos de estimação de concentração de chl-a, a partir de imagens multiespectrais de alta resolução espacial para águas interiores que compõem um sistema de tanques de criação de peixes.

2.1 Objetivos Específicos

Os objetivos específicos deste projeto consistem em:

- a. Definir um fluxo de processamento para a tomada e manipulação das imagens multiespectrais de alta resolução espacial da câmara *Agrowing* para aplicação em corpos d'água;
- b. Avaliar a contribuição de atributos espectrais (bandas e índices espectrais) no desempenho de modelos predição de chl-a;
- c. Comparar o desempenho da técnica mínimos quadrados com abordagens baseadas em aprendizado de máquina para o ajuste dos modelos de predição;
- d. Analisar a distribuição espacial do conteúdo de chl-a ao longo de um sistema represas-tanques-rio;
- e. Avaliar a qualidade da água em um sistema de aquacultura por meio da concentração de chl-a, estimada a partir de imageamento remoto.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 Sistema de Aquacultura

O cultivo de organismos, cujo ciclo de vida acontece parcial ou totalmente no meio aquático, é chamado de aquacultura (ou piscicultura, quando o cultivo é exclusivamente de peixes). A aquacultura pode ser desenvolvida dentro do leito de rios ou por meio da construção de tanques escavados. Para a instalação de um sistema de aquacultura com tanques escavados, alguns critérios são levados em consideração, como:

- demanda e qualidade da água, fontes próximas, potáveis e em quantidade adequada para abastecer os viveiros (ONO *et al.*, 2002);

- topografia deve ser plana, com suaves declives, não superiores a dois metros; tipo de solo, preferencialmente, argiloso e de baixa permeabilidade (RIBEIRO, 2001);
- clima da região deve ser compatível com exigências vitais das espécies a serem produzidas (KUBITZA, 1999); e
- a luz, diante de todos os elementos para o desenvolvimento da aquacultura, é um fator primordial, que afeta o crescimento, reprodução e outros comportamentos dos organismos aquáticos (BOYD, 1990).

A existência de uma infraestrutura de rede de energia elétrica e vias de fácil acesso (de pelo menos 4,5 m de largura) também são características essenciais para viabilizar a instalação de viveiros escavados. Os taludes devem possuir fácil acesso para o manejo, alimentação, limpeza e despesca da aquacultura. Os tanques de aquacultura são, geralmente, retangulares, com profundidades variantes de 1,20 m a 1,50 m, devido a declividade de fundo para o auto esvaziamento, do sentido da entrada à saída de água (REZENDE e BERGAMIN, 2013).

O sistema de abastecimento de água de tanques de aquacultura ocorre por meio de tubulações de PVC, adequadas ao volume de água que deve passar pela estrutura (CASSOL e DEBASTIANI, 2020). O sistema de drenagem dos viveiros é indispensável, pois a retenção de água ou água parada favorece o acúmulo de poluição e o desenvolvimento de doenças. A retirada da água pela superfície pode ser realizada quando há excesso de macrófitas emersas, mesmo sendo um trabalho laborioso (SILVA *et al.*, 2020).

O sistema de drenagem também pode ser chamado de sistema de recirculação, em que a troca de água favorece a remoção de excrementos dos animais, resíduos de ração e a manutenção da qualidade da água. A falta da recirculação de água em viveiros afeta diretamente a alimentação e crescimento dos peixes, além de contribuir para o desenvolvimento de deformidades, úlceras e lesões nos organismos, quando a taxa de acumulação de nitratos, nitritos, sólidos em suspensão e matéria orgânica é alta (CASSOL e DEBASTIANI, 2020).

3.2 Sensoriamento Remoto da Cor da Água

3.2.1 Resposta espectral da água

A obtenção de informações sobre as propriedades abaixo da superfície da água por meio do SR é possível devido a luz retroespalhada por moléculas de água e outras partículas que compõem as águas naturais, como a chl-a presente no fitoplâncton, CDOM composto de substâncias húmicas que influenciam na coloração da água, e TSS que são sedimentos minerais, argila e silte, por exemplo (KUSTER, 2009)

3.2.1.1 Água Pura

A água pura não contém concentrações de matéria orgânica ou inorgânica e apresenta um comportamento espectral particular. A luz incidente e descendente na coluna d'água é alterada na sua intensidade e composição espectral por meio da absorção ou do espalhamento seletivos. Nos comprimentos de onda do azul e do verde, a água pura possui baixa absorção, se tornando significativa a partir de 550 nm. Em contrapartida, nos comprimentos do vermelho e NIR a absorção da luz pela água pura é alta. Acima de 750 nm, a radiação incidente é absorvida no primeiro centímetro de profundidade da coluna d'água, se convertendo em calor (BARBOSA *et al.*, 2019).

O espalhamento na região do violeta e azul e a alta absorção nos comprimentos de onda do verde até o vermelho, caracteriza o tom azulado da água pura, visto nos oceanos, onde os corpos d'água são definidos como profundos e não túrbidos. A Figura 2 mostra o comportamento espectral da absorção e do espalhamento da água pura em um intervalo de comprimentos de onda entre 200 e 800 nm, determinadas em laboratório por Smith e Baker (1981).




Figura 2 — Espectros de absorção (linha sólida) e de espalhamento (linha pontilhada) da água pura.
Fonte: Barbosa *et al.* (2019).

3.2.1.2 Componentes Opticamente Ativos (COAs)

Os sistemas aquáticos possuem inúmeros componentes dissolvidos ou em suspensão, de diferentes tamanhos e composições químicas. As substâncias, as quais estão presentes na água e são capazes de interagir com a radiação eletromagnética, por meio dos processos de absorção e espalhamento, são chamadas de componentes opticamente ativos (COAs). Em outras palavras, os COAs têm propriedades ópticas que lhes são inerentes (POIs) (BARBOSA *et al.*, 2019).

As propriedades ópticas da água são divididas em duas classes: POIs e Propriedades Ópticas Aparentes (POAs). Segundo Preisendorfer (1961), em um determinado comprimento de onda, é possível especificar coeficientes de espalhamento e absorção, e a função de espalhamento volumétrico, referidos como POIs. A magnitude destes coeficientes provém de substâncias que compõem o meio aquático, independentes da geometria do campo de luz que pode penetrá-lo.

Em contrapartida, o conceito de POAs incorpora variáveis radiométricas para a descrição do campo de luz em um meio aquático. As propriedades dependem tanto do meio, quanto da geometria direcional do campo de luz, que devem apresentar determinadas regularidade e estabilidade para descreverem um corpo d'água. As POAs comumente utilizadas são o cosseno médio (μ) e os diversos coeficientes de atenuação difusos (MOBLEY, 1994).

Os coeficientes difusos, coeficientes de absorção e espalhamento para fluxos descendentes ou ascendentes são função da distribuição da radiância local e, por consequência, da profundidade. Preisendorfer (1961) classificou os coeficientes de absorção e espalhamento difusos como propriedades ópticas híbridas, por serem derivadas de POIs e propriedades do campo de luz. Kirk (2011) prefere definir como propriedades ópticas quase-inerentes, visto que ambas diferem apenas nas características do fluxo radiante que se imagina incidir sobre a fina camada do meio.

Uma vez que as propriedades ópticas inerentes (POIs) dos COAs foram conhecidas, se torna possível a estimação da concentração dos componentes na coluna d'água. A chl-a, CDOM e TSS são COAs que coexistem em diferentes proporções, interagindo simultaneamente com a radiação solar, interferindo nos processos de absorção e espalhamento, concomitantemente. Assim, as interações entre COAs, suas concentrações e a luz que penetra na superfície da água determinam o comportamento espectral dos corpos hídricos (BARBOSA *et al.*, 2019).

A chl-a é o pigmento fotossintetizante mais importante presente em todas as espécies de fitoplâncton, usado como indicador da qualidade da água, diretamente relacionado ao estado trófico de um ambiente aquático (BARBOSA *et al.*, 2019). O fitoplâncton pode ser encontrado mesmo em ambientes oligotróficos, ou seja, de baixa carga de nutrientes, e pode ser detectado por meio da análise da assinatura espectral da chl-a (MOREL e BRICAUD, 1986).

A Figura 3 mostra como o comportamento espectral da água se altera com o aumento da concentração de chl-a. Na feição (A), conforme o aumento da concentração de chl-a, na região do azul, entre 400 nm e 500 nm, maior é absorção da luz. A alta reflectância no comprimento de onda em torno de 560 nm (B) é decorrente da menor absorção da luz verde pelo fitoplâncton. Em contrapartida, o valor mínimo em 675 nm (D) é devido a alta absorção da luz vermelha pela chl-a (GITELSON, 1992; RUNDQUIST *et al.*; 1996). Em torno de 700 nm (E), região do *red edge* ou vermelho limítrofe, a baixa absorção está relacionada ao espalhamento do fitoplâncton (GITELSON *et al.*, 1993).

Segundo Gitelson (1992), o leve pico de absorção em torno de 620 nm (C) em curvas espectrais de águas naturais é consequência da presença de ficocianina, um pigmento acessório que pode ser encontrado nas cianobactérias. As inflexões em torno de 640 nm (entre C e D) estão associadas ao retroespalhamento devido a substâncias orgânicas dissolvidas e pigmentos acessórios. A absorção pela água pura aumenta na

região do NIR (BRABOSA *et al.*, 2019), enquanto que com o aumento da concentração de chl-a, existe um maior espalhamento luz, diminuindo a absorção (F).




Figura 3 — Reflectância da superfície da água variando com o aumento das concentrações de chl-a, sendo (a) concentrações entre 340 e 2190 µg/L e (b) concentrações entre 156 e 277 µg/L. Fonte: Rundquist *et al.* (1996).

O CDOM, oriundo da decomposição da fauna e flora escoada para os corpos d'água e da atividade biológica de organismos presentes na água, que forma um composto complexo de substâncias húmicas, possui um alto impacto no processo de absorção da

luz pela coluna d'água (KIRK, 2011). A absorção do CDOM possui um comportamento similar ao da água pura, com altos valores na região ultravioleta (UV) do espectro eletromagnético, os quais decrescem exponencialmente conforme os comprimentos de onda aumentam, atingindo valores mínimos próximos ao *red edge* e NIR (BARBOSA *et al.*, 2019). De acordo com Kirk (2011), o CDOM é absorvido em 440 nm, logo o coeficiente de absorção em 440 nm, $a_{CDOM}(440)$, é utilizado como indicador do CDOM em águas naturais.

O TSS é caracterizado por uma composição de fitoplâncton e partículas não algais (NAP), as quais podem ser orgânicas ou inorgânicas, em suspensão. O NAP inorgânico é resultante do intemperismo de rochas, enquanto o NAP orgânico advém de processos antrópicos, da agricultura e indústria, e de células mortas de organismos fitoplanctônicos e de subprodutos da vegetação (BARBOSA *et al.*, 2019). A absorção por meio do NAP é baixa, uma vez que as partículas espalham fortemente a luz, dependendo da composição, tamanho e forma das partículas.

3.3 Modelagem Bio-Óptica

A modelagem bio-óptica é baseada nos componentes opticamente ativos da água e nos parâmetros usados para descrever suas características ópticas, ou seja, POIs e POAs. Gordon *et al.* (1975) e Dekker (1993) derivaram os primeiros modelos bio-ópticos aplicados às águas oceânicas e águas interiores, respectivamente. Os modelos bio-ópticos para a estimativa da concentração de chl-a podem ser definidos a partir das propriedades ópticas do corpo d'água, com base na interação da luz com os componentes biológicos e não biológicos presentes na água (MOREL, 1991) ou por meio da teoria da transferência radiativa (MOBLEY, 1999).

A modelagem bio-óptica da chl-a pode ser realizada por meio de diferentes abordagens, sendo modelos analíticos (JORGE *et al.*, 2021), modelos semi-analíticos (ZHANG *et al.*, 2021), modelagem por meio de classificação (BOTHIA *et al.*, 2020) e modelos empíricos, os quais são relacionados com medidas reais coletadas *in situ* (SU *et al.*, 2021; SHI *et al.*, 2022). Tais abordagens são amplamente utilizadas no SR da qualidade da água, cada uma com suas vantagens e limitações conforme a complexidade óptica do ambiente analisado.

Os modelos analíticos são baseados nos mecanismos de transmissão da radiação pela interface da água, utilizando POIs para a descrição dos processos de absorção e

espalhamento. Os modelos semi-analíticos, além de considerarem as POIs, também incorporam as POAs e as interações com campo de luz subaquático, permitindo uma melhor caracterização dos processos ópticos.

Os modelos de classificação baseiam-se na segmentação dos corpos d'água em diferentes categorias, avaliando suas características ópticas e físico-químicas para definir padrões específicos. Em contrapartida, modelos empíricos estabelecem relações estatísticas entre dados observacionais, correlacionando medições espectrais e concentrações de parâmetros limnológicos, sem a necessidade de relacionar os processos físicos envolvidos.

Vale destacar que as abordagens por meio de algoritmos de aprendizado de máquina também são empíricas, uma vez que a calibração dos hiperparâmetros dos modelos se fundamenta em dados e observações. As vantagens da utilização de modelos empíricos relacionam-se com a facilidade de aplicação e processamento, enquanto a principal desvantagem é que essa modelagem é restritiva a área de estudo (ODERMATT, 2012). Outra desvantagem apontada por Ogashawara (2015) é que modelos empíricos demandam de laboriosas campanhas de campo para coleta de dados para a calibração e validação.

De acordo com Sagan *et al.* (2020), os modelos empíricos para estimar a qualidade da água podem ser desenvolvidos em função de razão de bandas espectrais. Um problema a ser enfrentado é o comportamento homogêneo da água. Nesses casos, a implementação dos modelos baseados em razão de bandas pode gerar erros significativos de estimativas e baixa precisão da estimação da concentração de COAs (MOREAL, 1974).

Estudos recentes (SAGAN *et al.*, 2020; TOPP *et al.*, 2020; DENG *et al.*, 2024) indicam que modelos bio-ópticos baseados em aprendizado de máquina são utilizados para estimar a concentração de chl-a. Zhang *et al.* (2024) utilizaram três algoritmos de aprendizado de máquina, *Random Forest* (RF), *Adaptive Boosting – AdaBoost* e *Extreme Gradient Boosting* (XGBoost), para recuperar a concentração de chl-a do Lago Hulun, no norte da China, juntamente com imagens do satélite Sentinel-2 e medidas de chl-a *in situ*. Diferentemente,

Irie *et al.* (2024) utilizaram imagens obtidas por meio ARPs e dados físicos coletados *in situ*, para estimação da concentração de chl-a em períodos de floração de algas com modelos classificatórios e em períodos de não floração, com modelos regressivos, XGBoost, de aprendizado de máquina, em um reservatório no Japão.

3.4 Modelos Regressivos

3.4.1 *Multivariate Linear Regression* (MLR)

A regressão linear multivariada (*Multivariate Linear Regression* - MLR) é um método de mineração de informações numéricas, de grande quantidade de dados, e predição de características de um conjunto de dados (USHARAMI e KUNGUMARAJ, 2015). Em suma, a análise da MLR é realizada para determinar se uma ou mais variáveis dependentes podem ser previstas por meio de variáveis independentes ou preditoras (Equação 1). A variável Y é dependente da soma de observações, n , da variável X independente, e $\beta_0, \dots, \beta_n$ são os coeficientes de regressão de cada observação.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad (1)$$

Os modelos de MLR para estimar parâmetros de qualidade da água são baseados na relação entre medidas radiométricas obtidas *in situ*, como a reflectância de SR (Rrs). A MLR utiliza combinações entre bandas de sensores remotos e dados coletados *in situ* para realizar as estimativas (OUMA *et al.* 2020). No caso da Equação 1, X representa a Rrs para cada comprimento de onda, $\lambda_1, \dots, \lambda_n$, de interesse, sendo que Y e X são as variáveis dependente e independente do modelo, respectivamente. Segundo Ta *et al.* (2021), a MLR é um dos modelos estatísticos mais populares para a calibração de modelos de estimação da concentração de chl-a, por ser uma análise simples de ser executada, de rápido ajuste e útil quando as variáveis não são complexas.

Para a aplicação da MLR são realizados testes de hipótese dos dados, uma ferramenta estatística que tem por objetivo avaliar a distribuição dos dados e se o modelo não contém multicolinearidade, ou seja, relação linear entre as variáveis dependentes e independentes; e heterocedasticidade, que qualifica se resíduos de uma observação para outra possuem mesma variância (ALITA, 2021). A avaliação do desempenho da regressão é determinada com base na pequena diferença entre o valor obtido e o valor real, ou por meio do cálculo de erros, em que pequenos erros indicam bons desempenhos (LINNET, 1993).

3.4.2 *Random Forest* Regressivo

Algoritmos de aprendizado de máquina são técnicas computacionais utilizadas para gerar conclusões a partir de um conjunto de dados. As técnicas de aprendizado de máquina possuem diversas aplicações em SR, sendo usadas em tarefas de classificação e predição baseadas em imagens. Entre os algoritmos de aprendizado de máquina mais usados destaca-se o RF.

Proposto por Breiman (2001), é um algoritmo que possui amplas aplicações em mineração de dados, a partir de uma abordagem não paramétrica baseada em árvores de decisão, que combinam atributos de vizinhos mais próximos para inferência de dados, por meio do “agrupamento” de árvores de dados correlacionados. O RF é um algoritmo habilitado para a seleção, predição e/ou classificação de dados (ISHWARAN, 2010).

As vantagens da utilização do RF são a eficiência em trabalhar com grandes bancos de dados e o fornecimento da estimativa de importância das variáveis de entrada para a seleção, predição e/ou classificação. Além disso, é um algoritmo robusto e computacionalmente leve, ou seja, não demanda de grande quantidade de memória para sua execução, além de prevenir a covariância das variáveis e evitar o *overfitting* dos dados para o modelo (BREIMAN, 2001).

O RF possui como unidade uma árvore binária, que são aplicadas em metodologias de classificação ou regressão, que se dividem em diferentes nós homogêneos ou quase homogêneos. Destaca-se que cada árvore cultivada traz amostras iniciais dos dados originais, uma vez que faz uso do processo de randomização, ou seja, probabilidades são atribuídas a todos os pontos do espaço amostral, cujo objetivo é descorrelacionar as árvores para que haja baixa variância dentro do conjunto de dados (BREIMAN, 2001).

O RF regressivo (Figura 4) é um método robusto de aprendizado de máquina que constrói múltiplas árvores de decisão com o mesmo número de amostras em cada árvore, que constituem uma floresta aleatória (KUHN e JOHNSON, 2013). O algoritmo é iniciado por meio de uma amostragem aleatória de um conjunto de dados (*bagging*), formando conjuntos de amostras por meio da ferramenta *bootstrap*. Alguns elementos não são incluídos (*out-of-bag* ou OOB), pois serão utilizados como amostra teste. No conjunto amostral de treinamento, um número de atributos é selecionado aleatoriamente como nós de ramificação da árvore de classificação (*Mtry*), para ser construída uma árvore de regressão. O coeficiente de Gini, uma estatística que mede a desigualdade, é

usado para estimar a impureza das variáveis, e as árvores de regressão são geradas para cada amostra de treinamento sem a remoção prévia de ramos irrelevantes ou excessivos, resultando na formação do modelo de regressão. Posteriormente, o valor de OOB é obtido, e a predição para cada pixel é feita a partir da média das previsões de cada árvores (*Ntree*) do modelo.




Figura 4 — Estrutura do algoritmo RF Regression.

3.4.3 Multilayer Perceptron (MLP)

O MLP, proposto por Rumelhart *et al.* (1986), é um modelo de rede neural artificial não linear, o qual pertence a categoria de técnicas de inteligência artificial. Como mostrado na Figura 5, a estrutura básica do MLP possui três camadas principais, sendo a primeira de entrada, onde são introduzidas as variáveis independentes; uma ou mais camadas ocultas; e a camada de saída que contém a variável dependente a ser estimada. Além disso, os parâmetros do modelo são pesos e vieses. O número de nós da camada oculta depende da complexidade da função a ser aproximada (KEINER e YAN, 1998). Quanto maior o número de nós, maior é o tempo de processamento para modelar corretamente a função (DARWISH *et al.*, 2014).

O MLP possui ainda uma função de ativação (comumente sigmoide) nos nós da camada oculta e uma função identidade linear na camada de saída. A Equação 2, calculada de acordo com Ramchoun *et al.* (2016), mostra a saída do modelo MLP, em que Y é o vetor de saída; X é o vetor de entrada; f^1 e f^2 são funções de transferência da camada oculta

e de saída, sigmoide e linear, respectivamente; b^1 e b^2 são vieses da camada oculta e de saída, respectivamente; e W^1 e W^2 são os pesos da camada de entrada e oculta, respectivamente.

Ainda, o treinamento do MLP é realizado por meio do algoritmo de retropropagação de erro (*backpropagation*), que ajusta os pesos da rede de forma iterativa. Esse processo envolve a propagação do erro da saída para as camadas anteriores, utilizando o gradiente da função de custo para atualizar os pesos por meio do método de descida do gradiente, reduzindo assim a diferença entre as saídas previstas e os valores reais.

$$Y = f^2(W^2 f^1(W^1 X + b^1) + b^2) \quad (2)$$




Figura 5 — Estrutura básica de uma rede neural MLP.

3.5 Imagens Multiespectrais Obtidas por meio de ARPs

O monitoramento de pequenos corpos d'água pode ser realizado por meio da combinação de tecnologias emergentes, as quais incluem a utilização de câmaras multiespectrais e ARPs, que contornam limitações de imagens de satélite e pesquisas tradicionais *in situ* (SALANDRA *et al.*, 2021). Elas garantem a aquisição sob demanda de dados de altíssima resolução espacial e permitem a geração de ortomosaicos para a extração, previsão ou recuperação de características físicas, hidrogeomorfológicas ou

limnológicas (CASADO *et al.*, 2015). Da literatura existente (WASEHUN *et al.*, 2024; BAI *et al.*, 2024; YAN *et al.*, 2023), as imagens provenientes de ARPs são vantajosas quando comparadas a imagens de satélite e dados de pesquisa de campo, pois a aquisição de dados é mais rápida, com maior resolução espacial, baixo custo e não são acometidas de interferências atmosféricas (ANSARI *et al.*, 2021).

Apesar da necessidade reduzida de correções dos efeitos atmosféricas em virtude da baixa altura de voo, alguns fatores como a geometria de iluminação (azimute e ângulo de inclinação solar) e sombreamento, relacionados com o dia e horário do voo, restrições tecnológicas e razão sinal-ruído do instrumento podem dificultar o ajuste radiométrico usando alvos de calibração e a radiometria de campo (NICOLÁS *et al.*, 2021). Outro fator a ser considerado é a resposta espectral homogênea da água, que dificulta a detecção de pontos homólogos para a realização do alinhamento de imagens coletadas, as quais possuem altíssima resolução espacial (FRASER *et al.*, 2024).

4 MATERIAIS E MÉTODOS

Nesta seção são apresentadas a área de coleta de dados, materiais, equipamentos e aplicativos utilizados, assim como os procedimentos metodológicos de aquisição e processamento dos dados e como serão analisados os resultados. A Figura 6 mostra as etapas de execução deste estudo esquematizadas em um fluxograma. O fluxograma inicia mostrando a aquisição de dados: amostras de água, medidas limnológicas, leituras radiométricas, e imagens multiespectrais.

As amostras de água foram destinadas à análise laboratorial para determinação das concentrações de chl-a. Os dados limnológicos foram estatisticamente descritos considerando todo o sistema de aquacultura e todas as campanhas de campo realizadas. Em relação à aquisição dos dados radiométricos, as medidas foram realizadas seguindo o protocolo proposto por Mueller (2003) e a *Rrs* foi calculada de acordo com Mobley (1999). As imagens multiespectrais foram posteriormente processadas, aplicando separação das bandas, georreferenciamento, geração de ortomosaico e calibração radiométrica.

Para compatibilizar a *Rrs* obtida *in situ* com as medidas da imagem, foi aplicada uma simulação das bandas da câmara multiespectral *Agrowing*, com base em uma função gaussiana, a partir de um processo de convolução. Em seguida, foi realizado uma seleção de atributos (bandas espectrais e índices espectrais) para entrada na calibração dos

modelos bio-ópticos, utilizando os algoritmos MLR, RF e MLP. Após a calibração dos modelos, eles foram avaliados a partir do processo de validação cruzada. Os modelos com os melhores resultados foram aplicados às imagens para estimar o conteúdo de chl-a e construção de mapas da distribuição espacial horizontal da chl-a.




Figura 6 — Fluxograma com os procedimentos metodológicos desenvolvidos nesse trabalho.

4.1 Área de Estudo

O estudo foi conduzido em um centro especializado do Instituto Chico Mendes de Biodiversidade (ICMBio), o Centro Nacional de Pesquisa e Conservação da Biodiversidade Aquática Continental – CEPTA, localizado no município de Pirassununga, Estado de São Paulo, limitado pelas coordenadas 47°22'22,01" W e 47°22'43,93" W e 21°55'35,69" S e 21°55'31,33" S. Foram analisados os corpos d'água que integram um sistema de aquacultura, composto por duas represas que alimentam 128 tanques escavados para piscicultura; os tanques escavados em operação; e um trecho do rio Mojiguaçu. A Figura 7 apresenta um mapa da área de interesse, onde estão destacados em azul os corpos d'água avaliados neste estudo e em vermelho os pontos de coleta.

A água represada é oriunda do Córrego da Barrinha, pequeno afluente do rio Mojiguaçu. O represamento é necessário para que a água receba oxigenação suficiente para a utilização em tanques de piscicultura. O CEPTA possui 128 tanques escavados, entre eles, 32 possuem base de concreto e dimensões de 1,20 m × 3,50 m. A maior parte dos tanques possui paredes de barro assentadas e maiores dimensões, chegando a 60 m × 130 m. Durante a coleta dos dados, cerca de 35 tanques escavados não estavam sendo utilizados e estavam tomados por grande quantidade de vegetação rasteira e arbustiva. O lançamento dos efluentes dos tanques é feito no rio Mojiguaçu.




Figura 7 — Mapa da área de estudo, em que (a) corresponde a região do CEPTA/ICMBio, com destaque para os corpos d'água de interesse para o estudo; (b) a localização do CEPTA no município de Pirassununga e (c) a localização no estado de São Paulo.

O objetivo de se avaliar o sistema de aquacultura é verificar as alterações na qualidade da água desde a sua captação, utilização nos tanques de piscicultura, que possuem diferentes dimensões, características físicas e manejo, devido às diferentes espécies de peixes, até o descarte no rio Mojiguaçu. Destaca-se que produtos químicos não são adicionados aos viveiros, logo, as modificações da qualidade da água são ocasionadas pelo despejo de ração para alimentação dos peixes, excrementos dos animais e/ou erosão das bordas dos tanques escavados.

4.1.1 Características dos corpos d'água

Os corpos d'água de interesse nesse estudo possuem diferentes características físicas e bio-ópticas, como mostrado nas Figuras 8 e 9. Os tanques I, II, III, IV e VIII (Figura 9) são exemplos de tanques com base de argila assentada e são rodeados por vegetação rasteira, enquanto os tanques V, VI e VII possuem sua base de concreto. Em alguns tanques, macrófitas emersas se acumulam por quase toda superfície da água (tanques III e IV). A espécie de macrófita mais comum encontrada nos tanques é a

Ludwigia Sedoides, comumente conhecida como “planta mosaico” ou “canário de água”. Tal espécie de macrófita é frequente e dominante em ambientes de água lântica ou parada e influenciam o desenvolvimento da ictiofauna (VIANA *et al.*, 2020). Nos pequenos tanques de concreto, notou-se a presença de musgos nas paredes.

Visualmente, a cor da água na maioria dos tanques é esverdeada e pouco turbida (tanques I, II, V e VI), em contrapartida, outros tanques possuem águas amarronzadas. Segundo servidores do CEPTA/ICMBio, tanques que apresentam um aspecto barrento (tanque VIII) abrigam espécies de peixes acometidos por um parasita que causa coceira e, por este motivo, os peixes se esfregam nas paredes dos tanques causando um leve assoreamento. Alguns tanques possuíam uma cobertura de *scum* sobre a água.

Para a coleta de amostras foram selecionados tanques com características físicas distintas e de fácil acesso. Alguns tanques eram rodeados por matagais que impediam o acesso para a coleta de água e medição de variáveis físico-químicas *in situ*. Outro fator considerado na seleção dos tanques foi a quantidade de água, visto que certos tanques não estavam cheios, impossibilitando o acesso à superfície da água.




Figura 8 — Fotos dos tanques de piscicultura, os quais apresentam diferentes características físicas e bio-ópticas.

Ambos os reservatórios são rodeados por faixas de vegetação arbórea densa e na água nota-se a presença de plantas aquáticas. Os reservatórios possuem águas esverdeadas e medianamente turbidas. O local também é habitat de grandes roedores, como capivaras. Em contrapartida, o rio Mojiguaçu, que possui sua nascente no município de Bom Repouso, Serra da Mantiqueira, Estado de Minas Gerais, a cerca de 150 km do município

de Pirassununga/SP, é demasiadamente antropizado e poluído. A água possui uma coloração marrom barrenta, turbida e com alta concentração de sólidos em suspensão. Espuma branca e restos de lixo provenientes do escoamento superficial da área urbana também foram notados na água. A Figura 9 mostra imagens dos reservatórios e do rio Mojiguaçu, respectivamente. Destaca-se que o reservatório I é o de maior porte e o reservatório II de menor porte.



Figura 9 — Fotos dos reservatórios e rio Mojiguaçu, que apresentam diferentes aspectos da cor da água e, portanto, diferentes características físicas e bio-ópticas.

4.2 Levantamentos em Campo

Neste estudo, três campanhas de campo foram realizadas, sendo a primeira em 16 e 17 de fevereiro de 2022, a segunda em 14, 15 e 16 de fevereiro de 2023, e a última em 21 de julho de 2023. Nos dois primeiros levantamentos de campo, foram coletadas apenas amostras de água, dados limnológicos e radiométricos terrestres, e no terceiro, além dessas medidas, foram tomadas as imagens com uma câmara multiespectral *Agrowing A7R_{XXX} Sextuple* acoplada a uma *ARP Matrice 300 RTK*, da fabricante *DJI Innovations*, em conjunto com um sistema de navegação *Post Processed Kinematic* (PPK), que coleta e armazena as coordenadas de voo acuradamente, e um par de receptores *Real Time Kinematic* (RTK), que coleta as coordenadas de forma instantânea, com o auxílio de um outro receptor (*Rover*).

Os levantamentos em campo objetivaram a coleta de amostras de água para a estimação da concentração de chl-a em laboratório; a aquisição de dados limnológicos para a avaliação da qualidade dos corpos d'água estudados; a aquisição de dados radiométricos terrestres; e imagens multiespectrais aéreas, para a construção de modelos empíricos de estimação da concentração de chl-a em todo o sistema de aquacultura. Cabe

mentonar que na primeira campanha de campo, houve a captura das imagens, entretanto, devido a um erro de configuração da câmara, não foi possível utilizá-las.

No primeiro levantamento de campo foram coletados um total de 30 elementos amostrais, no segundo foram amostrados 43 pontos e no último levantamento foram amostrados 10 pontos. As campanhas de campo foram realizadas em diferentes períodos sazonais, visando abranger a variabilidade óptica existente. É esperado que no período chuvoso e de altas temperaturas (fevereiro) haja condições mais favoráveis à produção primária (fitoplâncton) e maior quantidade de sedimentos escoados para os corpos d'água, sendo o contrário para o período seco e frio (julho).

A primeira e a terceira campanhas de campo foram realizadas em dias ensolarados, sem a presença de nuvens, com temperaturas superiores a 28°C. Em contrapartida, o segundo levantamento de campo foi realizado posteriormente a dias chuvosos e havia uma variação de iluminação devido à nebulosidade, com leves garoas, principalmente do meio para o final da tarde. Apesar da variação climática, as temperaturas estavam elevadas, alcançando 31°C.

A Tabela 1 apresenta o número de elementos amostrais coletados em cada campanha de campo e em cada corpo d'água. Embora o total de elementos amostrais obtidos seja 83, alguns foram excluídos, pois apresentavam resposta espectral de vegetação aquática emersa ou espectros de reflectância incoerentes aos da água, como valores de radiância negativos. Destaca-se que para a coleta de amostras no rio e nos reservatórios foi necessário o uso de uma embarcação, devido a extensão e profundidade dos corpos d'água.

Tabela 1 - Quantidade de pontos coletados nos diferentes tipos de corpos d'água, em cada campanha de campo realizada.

Corpos d'água	Campo 16 e 17 de fevereiro de 2022	Campo 14, 15 e 16 de fevereiro de 2023	Campo 21 de julho de 2023
Rio Mojiguaçu	6	7	-
Reservatório I	7	8	-
Reservatório II	-	5	-
Tanques (diversos)	17	23	10
Total de amostras	30	43	10

4.2.1 Coleta de água e medição de parâmetros físico-químicos

Em cada ponto amostral, parâmetros físico-químicos foram registrados a partir de uma sonda multiparâmetros, modelo *Horiba U-50* (*HORIBA Advanced Techno Co., Ltd.*, Kyoto, Japão) (Figura 10). Foram registrados os seguintes parâmetros: temperatura ($^{\circ}\text{C}$); pH; condutividade elétrica (mS/cm); turbidez (NTU); oxigênio dissolvido - OD (mg/L e %); propriedades oxidantes - ORP (mV); e sedimentos totais dissolvidos - STD (g/L). Além disso, a profundidade da coluna d'água (m) e a transparência do disco de *Secchi* (m) também foram medidas, por meio de uma ecossonda para barcos e disco de *Secchi*, respectivamente.

Os dados limnológicos foram medidos apenas para os dois primeiros trabalhos em campo, devido a indisponibilidade do equipamento na terceira campanha. Em poucos pontos amostrais, medidas limnológicas também não foram registradas, no primeiro e segundo levantamentos de campo, por falha no instrumento de medição. Após a medição dos parâmetros físico-químicos e radiométricos, a coleta de água foi realizada em cada ponto. As amostras foram armazenadas em galões de cinco litros envoltos com papel alumínio e fita adesiva marrom, para impedir a entrada de luz e evitar atividade fotossintética pelos organismos fitoplancônicos. Os recipientes foram estocados em caixas de isopor com gelo, para a conservação da água e de seus constituintes, até que fosse realizada a filtragem, feita no mesmo dia.



Figura 10 — (a) Sonda multiparâmetros (*Horiba U-50*) com monitor, cabo de 30 m e sonda submersível; (b) monitor mostrando variáveis registradas.

Para determinação da chl-a em laboratório, foi realizada a filtragem das amostras de água em filtros de fibra de vidro *Whatman GF/F* (GE Healthcare, Chicago), de 47 mm de diâmetro e 0,7 µm de porosidade. O processo foi feito em ambiente escuro, de modo a minimizar os efeitos de fotodegradação. Esses filtros são guardados em envelopes separadamente, armazenados em frasco escuro contendo sílica-gel e mantidos a temperaturas inferiores a 0° C até a análise.

As amostras filtradas foram encaminhadas para a Associação Instituto Internacional de Ecologia e Gerenciamento Ambiental – Laboratório de Análises da Qualidade da Água 1, para determinação da concentração de chl-a em laboratório. A análise foi realizada segundo a metodologia de Nush (1980), em que a chl-a é extraída em solução de etanol 80%, em alta temperatura (75°C), durante cinco minutos, em tubos de ensaio. Em seguida, os tubos são mergulhados em água gelada, temperatura próxima a 0° C, para causar um choque térmico. A extração é mantida por um período de 6 a 24 horas em um refrigerador, sem iluminação. Após a refrigeração, as soluções são passadas para tubos de vidros âmbar, de 20 ml.

As leituras de absorbância são realizadas por espectrofotometria, em cubetas de quartzo de 50 mm, nos comprimentos de onda de 750 nm e 665 nm. Os valores obtidos foram utilizados para calcular a concentração de chl-a. Esses dados foram usados para calibrar um modelo bio-óptico de predição do conteúdo de chl-a.

Vale ressaltar que a coleta de água para a estimação do conteúdo de chl-a em laboratório foi realizada em três campanhas de campo, totalizando 83 amostras. Das 83 amostras, apenas 69 foram utilizadas para o desenvolvimento dos modelos bio-ópticos, uma vez que foram excluídos *outliers* e nem todos os pontos, em que as amostras de água foram coletadas, foram possíveis mensurar a radiância. A medição radiométrica foi comprometida devido ao horário e à inclinação do sol (após às 15 horas).

4.2.2 Aquisição de dados com o espectrorradiômetro

O espectrorradiômetro foi utilizado para a aquisição de medidas radiométricas da superfície dos corpos d'água, usadas como verdade terrestre. O instrumento para coleta dos dados radiométricos *in situ* foi o espectrorradiômetro *FieldSpec® HandHeld UV/NIR*, do fabricante *ASD_{Inc}* (*Analytical Spectral Devices*, Colorado, Estados Unidos), utilizando uma lente de abertura de 1° (um grau). O equipamento registra a radiância no intervalo de 350 nm a 1075 nm, com uma resolução espectral de 1 (nm) nm (Figura 11). O *software*

utilizado para o registro das medidas foi o RS^{3TM} , também do fabricante ASD_{Inc} . Para a conversão dos dados provenientes do espectrorradiômetro para arquivos de texto foi utilizado o aplicativo $ViewSpecPro^{TM}$, da ASD_{Inc} .

Os valores de radiância medidos *in situ* com o uso de espectrorradiômetro portátil foram obtidos cerca de 30 cm acima da superfície da água, cujos dados brutos são base para a estimativa da concentração de chl-a (SATHYENDRANATH, 2000). Para as medições foi seguido o protocolo de Mueller (2003). Após a calibração do equipamento, foram medidas a radiância da placa cinza (placa *Spectralon*® de 5" de diâmetro) (L_g); a radiação incidente do céu (L_{sky}), com o sensor apontado a 45° em relação ao zênite; e a radiância total (L_t), correspondente a radiância que emerge da água (L_w) mais a radiância refletida pela superfície da água (L_r), com o instrumento apontada a 45° em relação ao nadir e ortogonalmente ao plano azimutal solar, onde não houvesse projeção de sombra na superfície da água.

As amostras que dependiam de embarcações para serem coletadas, ou seja, nos reservatórios e rio, tiveram a proa do barco direcionada para o sol e as medidas foram tomadas ortogonalmente. Dez espectros de radiância foram coletados de cada medida em cada ponto. As amostras coletadas foram analisadas individualmente e espectros com radiâncias com magnitude ou formas discrepantes das demais (*outliers*) foram excluídos para o cálculo das reflectâncias espectrais, a fim que os espectros não resultassem em uma resposta espectral equivocada. Posteriormente, foi calculada a média dos espectros de radiância, com o intuito de minimizar variações das medições, causadas por mudanças de iluminação.



Figura 11 — Espectrorradiômetro *ASD FieldSpec® HandHeld UV/NIR* utilizado para obtenção de medidas de radiométricas *in situ*.

4.2.3 Aquisição das Imagens

As imagens foram adquiridas por meio da câmara multiespectral *Sony Alpha 7R_{XXX} Sextuple*, da *Agrowing* (Rishon LeZion, Israel), acoplada à *ARP Matrice 300 RTK* (Figura 14), do fabricante *DJI Innovations*. Cabe ressaltar que dois voos foram realizados (VOO1 e VOO2), para que fosse possível capturar imagens de toda área de estudo. O VOO1 abrangeu o rio Mojiguaçu e parte dos tanques escavados da seção norte da Figura 7, da área de estudo, enquanto que o VOO2 abrangeu o tanque de maior porte, os tanques concretados e ambos reservatórios (parte sul/sudoeste da área de estudo).

A câmara multiespectral da *Agrowing*, possui seis cabeças (lentes ópticas) e registra 14 bandas espectrais, que abrangem as regiões do visível (VIS) e NIR (até 850 nm). A Figura 12 mostra a câmara *Agrowing* e a distribuição das bandas em cada lente. Os comprimentos de ondas centrais das 14 bandas da câmara estão apresentados na Tabela 2. As especificações e características da câmara *Agrowing* estão dispostas na Tabela 3.



Figura 12 — Câmara *Sony Alpha 7R_{XXX} (Agrowing)*, com seis cabeças e 14 bandas espectrais.

Detetores baseados em filtro RGB não filtram a radiação infravermelha. Neste caso, o Q3 capta apenas a radiação no NIR, cujo comprimento de onda central é de 850

nm. Uma vez que a reflexão infravermelha é específica, é necessário que haja um filtro que transmita apenas comprimentos de onda ou canal espectral da luz infravermelha (KISE *et al.*, 2010). Os demais filtros RGB, captam a radiação nas regiões do VIS, não necessariamente nos três canais (Q2 e Q5), sendo essa característica definida pelo desenvolvedor da câmara.

Tabela 2 - Comprimentos de ondas centrais, região espectral e largura de banda (*Full Width Half Maximun* - FWHM) de cada uma das 14 bandas da câmara *Agrowing*.

Bandas	Região espectral	Comprimento de onda central (nm)	FWHM (nm)
1	UV	405	25
2	VIS	430	25
3	VIS	450	25
4	VIS	490	25
5	VIS	525	25
6	VIS	550	25
7	VIS	560	25
8	VIS	570	25
9	VIS	630	25
10	VIS	650	25
11	VIS	685	25
12	<i>Red edge</i>	710	10
13	<i>Red edge</i>	735	10
14	NIR	850	15

Fonte: <https://Agrowing.com/products/alpha-7Rxxx-sextuple/>

Tabela 3 - Características da câmara *Sony Alpha 7Rxxx* e lente multiespectral, da *Agrowing*.

Características	Parâmetros
Tipo	Montagem única – lente de seis cabeças
Campo de visada	Diagonal: 45,9° Horizontal: 35° Vertical: 26,6°
Distorção das lentes	<1%
Distância focal	21,6 mm
Tipo e intervalo de foco	Manual 2,5mm para o infinito
Tamanho da lente	60 mm x 35,2 mm
Peso da lente	180 g
Peso total com a bateria	845 g

Fonte: <https://Agrowing.com/products/alpha-7riv-sextuple/>

A sensibilidade de cada canal da câmara *Agrowing* é função da transmitância dos filtros. Filtros são materiais opacos e/ou transparentes para diferentes comprimentos de onda da luz, os quais mostram as qualidades de transmissão ou absorção de diferentes

canais espectrais (GAT, 2000). O modelo da câmara utilizada neste estudo possui seis cabeças com filtros de transmissão, os quais permitem a aquisição de suas respectivas bandas. A Figura 13 apresenta os espectros de transmitância de cada banda da câmara *Agrowing*.




Figura 13 — Respostas espectrais dos filtros (luz colimada) da câmara *Agrowing* (Adaptado de <https://Agrowing.com/products/alpha-7riv-sextuple/>).

A ARP (Figura 14) possui um design para fotografia aérea profissional, com quatro hélices, peso máximo de decolagem de 9 kg, bateria de 5.935 mAh e tempo estimado de voo de 20 minutos, aproximadamente (*DJI Innovations*). O método de aerolevantamento convencional, com sobreposição de 60% entre as faixas horizontais e 70% frontalmente entre as fotos, foi empregado para a aquisição das imagens. A velocidade do voo foi de 5,9 m/s, sendo as imagens tomadas a cada 2 segundos, a uma altura de voo de 104 m, resultando em um GSD (*Ground Sample Distance*) de aproximadamente 1,8 cm. O GSD equivale ao valor do tamanho do pixel da imagem (0,0037 mm) dividido pela escala ($E = 1/4831$).



Figura 14 — ARP *Matrice 300 RTK* sobre uma lona pronta para a decolagem.

Durante o voo foi utilizado um sistema de navegação *Global Navigation Satellite System* (GNSS) por meio da técnica PPK, embarcado na aeronave, o qual coleta e armazena coordenadas de voo com alta acurácia posicional, sendo uma acurácia planimétrica de 2 cm e uma acurácia altimétrica de 3 cm, após o processamento da imagem. As coordenadas posteriormente foram processadas e corrigidas para georreferenciar as imagens. Ao longo da coleta de coordenadas de toda área de estudo, também foram coletadas por meio do RTK 39 pontos de apoio foto-identificáveis. Os pontos de apoio foram auxiliares para a correção de possíveis distorções no processamento e construção do ortomosaico.

4.3 Determinação da reflectância de sensoriamento remoto (R_{rs})

As medidas de radiância coletadas *in situ* com espectrorradiômetro foram utilizadas para calcular a reflectância de SR (R_{rs}), utilizando Equação 3, proposta por Mobley (1999).

$$R_{rs} = \frac{L_t - \rho L_s}{\frac{\pi}{R_g} L_g} \quad (3)$$

Em que,

L_t – radiância total;

ρ – fator de proporcionalidade (0,028) relacionado a velocidade do vento e o ângulo zenital solar, no instante da leitura;

L_s – radiância incidente do céu;

L_g – radiância uniforme da placa cinza de calibração de campo e;

R_g – valor do fator de correção proveniente das placas lambertianas medidas em laboratório, multiplicado pela medida de radiância da placa cinza de campo.

Antes do cálculo da Rrs , as medidas de radiância da placa cinza de campo foram corrigidas. Para isso, em laboratório foram medidas as radiância (L) da placa de referência *Spectralon*® (superfície lambertiana) de 10” × 10” de dimensão, mantida em laboratório, e da placa cinza de campo (5” de diâmetro). O objetivo da medição da radiância das placas de calibração é gerar um fator de correção (FC) calculado pela divisão entre a radiância da placa cinza de campo e a radiância da *Spectralon*®, ambas medidas em laboratório, dividido por um fator k , correspondente a reflectância espectral da placa de referência, fornecido pelo fabricante da placa (*Labsphere*, Estados Unidos).

O FC de correção é multiplicado pela medida de radiância da placa cinza de campo (L_g), cujo resultado é expresso por R_g , na Equação 3 do cálculo da Rrs (MOBLEY, 1999; LEE *et al.*, 2010). A placa cinza de campo, devido ao seu manuseio, com o passar do tempo ela perde a capacidade de reflexão lambertiana quase ideal, assim, o FC visa alcançar perfeitas condições, comparadas as medições realizadas em laboratório, tanto de geometria, quanto de iluminação (JENSEN, 2014).

O ambiente da tomada das medidas das variáveis que compõem o FC era controlado, com a sala escura e o entorno revestido por placas de etil vinil acetato (E.V.A.) e tecidos da cor preta, para que minimizar efeitos de iluminação externos que interferissem no valor de radiância medido das placas. Para a medição das placas, foi utilizada uma lâmpada halógena para iluminar os alvos (placas) a um ângulo de 45° em relação ao nadir e 90° em azimute em relação a fonte de iluminação, como mostra a Figura 15.



Figura 15 — Placa cinza de campo, cuja radiância foi medida em laboratório, com o auxílio de uma lanterna de luz halógena e um espectrorradiômetro.

4.3.1 Simulação de Bandas

Uma vez que os valores de Rrs foram calculados, a próxima etapa consistiu em compatibilizar as Rrs determinadas pelas medidas do espectrorradiômetro e as reflectâncias das bandas da câmara *Agrowing* por meio de uma simulação de bandas. A simulação de bandas é um procedimento realizado mediante a uma convolução espectral, multiplicando os dados espectrais pela função de filtro espectral (S_B), integrando o resultado para os comprimentos de onda de cada canal e normalizando pela largura de cada banda (BURGRAAFF, 2020), conforme mostrado na Equação 4.

$$\bar{R}_{rs}^B = \frac{\int_{\lambda \in B} L_w(\lambda) S_B(\lambda) d\lambda}{\int_{\lambda \in B} E_d(\lambda) S_B(\lambda) d\lambda} \quad (4)$$

Em que,

$L_w(\lambda)$ – radiância deixando a água espectral;

$E_d(\lambda)$ – irradiância descendente espectral;

$S_B(\lambda)$ – função resposta espectral de cada banda (B);

$S_B(\lambda)$ da câmara *Agrowing* não é disponibilizada pelo fabricante e, por isso, foi aproximada para uma função gaussiana. A Equação 5 mostra a função de distribuição normal.

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (5)$$

Em que,

x – Rrs de um pixel de uma banda espectral;

μ – valor da Rrs no comprimento de onda central;

σ – dispersão dos valores de Rrs , ou seja, FWHM;

As bandas simuladas foram utilizadas na calibração radiométrica das imagens multiespectrais e na calibração e validação do modelo de predição de chl-a. Antes do voo, com o auxílio do espectrorradiômetro, foram medidas em campo as radiâncias de alvos de calibração. Os alvos de calibração das imagens foram placas (0,5 m × 0,5 m) de E.V.A., em quatro cores diferentes: branco, cinza claro, cinza médio e preto. Os valores de radiância dos alvos de calibração também transformados em valores reflectância Rrs e a simulação de bandas também foi aplicada a esses dados.

4.4 Processamento da Imagens

O processamento das imagens foi iniciado utilizando o *software Agrowing Basic* (*Agrowing*, Rishon LeZion, Israel). No *software*, foi feita o alinhamento e separação das imagens capturadas em 14 bandas espectrais, registradas por meio das seis lentes ópticas. O processo de alinhamento das cenas é feito manualmente, utilizando a lente óptica Q1 (Figura 13) como referência. O alinhamento das bandas é necessário, uma vez que elas são tomadas por diferentes ópticas, que estão deslocadas entre si. Depois de alinhadas as imagens, é efetuada a separação automática dos 14 canais espectrais, além de transformar os dados na extensão .RAW para a extensão .TIFF, em números digitais (ND), quantizado em uma resolução radiométrica de 8 bits (ND – 0 a 255). Vale ressaltar, que apesar da resolução radiométrica de 8 bits ser considerada baixa, podendo reduzir a acurácia dos

processamentos, o parâmetro foi escolhido pois não foi possível fazer o processamento fotogramétrico posteriormente com 16 bits.

Com as imagens alinhadas e bandas salvas separadamente, foi realizado o processamento geométrico por meio do *software Agisoft Metashape*, versão 1.7.4, (Agisoft LLC, Rússia). As etapas efetuadas consistem em: importação das imagens em .TIFF e importação das coordenadas coletadas; alinhamento e triangulação fotogramétrica entre as imagens, resultando nos parâmetros de orientação interior e exterior (POI e POE, respectivamente), além da nuvem de pontos (*Cloud Points*), a demarcação dos pontos GNSS utilizando pontos de verificação da qualidade do alinhamento, como referência; densificação dos *Tie Points*; construção de um modelo tridimensional da superfície; desenvolvimento de um modelo digital da superfície (MDS) e; geração do ortomosaico. Vale ressaltar que dois voos foram realizados, devido a dimensão da área de estudo, logo foram gerados dois ortomosaicos.

4.4.1 Calibração Radiométrica das Imagens

A calibração radiométrica das imagens é realizada para converter os NDs em R_{rs} , para que os modelos de predição de chl-a possam ser aplicados às imagens, uma vez que os modelos foram calibrados com os dados terrestres. As reflectâncias tomadas das placas de calibração (quatro cores) foram utilizadas para ajustar um modelo de conversão, utilizando a técnica de linha empírica (SMITH e MILTON, 1999). Apesar da câmara *Agrowing* possuir 14 bandas espectrais, apenas 5 foram utilizadas, visto que os canais centrados em 560 nm, 650 nm, 685 nm, 710 nm e 735 nm, foram adotadas como atributo de entrada para o desenvolvimento dos modelos bio-ópticos, a partir dos índices espectrais. Tais comprimentos de onda são comumente utilizados para o desenvolvimento de modelos bio-ópticos para águas interiores. Duas funções foram testadas para converter NDs em R_{rs} , linear e exponencial, descritas pelas Equações 6 e 7.

$$R_{rs} = a \times (ND) + b \quad (6)$$

$$R_{rs} = a \times e^{b(ND)} \quad (7)$$

As placas utilizadas como alvos de calibração possuíam as cores branco, cinza claro, cinza escuro e preto, como mostra a Figura 16. Além das placas de calibração,

foram adicionadas duas amostras radiométricas de água, uma para cada voo, com menor Rrs para compor o modelo de calibração (Figura 17). Essas amostras foram utilizadas porque os alvos de referência mais escuros (cor preta) têm valores de Rrs maiores do que os alvos de água, resultando em valores negativos de Rrs aos pixels.

Para o primeiro voo realizado, os alvos de calibração utilizados foram: branco (1CO), cinza escuro (3CO), preto (4CO) e o ponto de identificação na água A62, coletado em julho de 2023. O segundo voo teve como alvos de calibração das imagens: cinza escuro (3CO), preto (4CO), tatame avulso (3AV) preto e o ponto de identificação na água A30, coletado em julho de 2023. As placas AV possuíam $0,5 \times 0,5$ m, enquanto as placas CO possuíam $0,5 \times 0,25$ m cada (o conjunto $0,5 \times 1$ m).



Figura 16 — Alvos de referência em quatro cores: branco (1AV e 1CO), cinza claro (2AV e 2CO), cinza escuro (3CO) e preto (3AV e 4CO), para a calibração radiométrica das imagens.




Figura 17 — Alvos nos corpos d'água (tanque A62 e tanque A30) utilizados para calibração radiométrica das imagens como espectros de menor reflectância.

A calibração radiométrica foi realizada manualmente por meio do *software Excel*, do pacote *Microsoft Office*, e para a aplicação do modelo de ajuste radiométrico e construção dos mapas finais, mostrando a distribuição espacial da chl-a, foi utilizado o *software Quantum GIS (QGIS)*. Cabe mencionar que o *software Environmental for Visualizing Images (ENVI)* possui ferramentas para aplicação automática da linha empírica para a calibração das imagens e foi testado. Entretanto, não foram capazes abrir as imagens, uma vez que possuíam um tamanho não suportado pelo *software*.

A calibração radiométrica foi validada por meio das métricas: coeficiente de determinação (R^2), *Root Mean Square Error (RMSE)*, *Normalized Root Mean Square Error (NRMSE)* e *bias* (Equações 8, 9, 10 e 11). Para a validação foram utilizadas um total de 26 amostras para o VOO1 e 45 amostras para o VOO2. Destaca-se que com o objetivo de melhorar os resultados avaliados, uma vez que a magnitude das curvas era

muito diferente daquelas tomadas em campo, a métrica *bias*, calculada por banda, foi multiplicada como uma correção para assim ser possível alcançar modelos significativamente acurados.

$$R^2 = 1 - \frac{\sum (x_i - \hat{x}_i)^2}{\sum (x_i - \bar{x})^2} \quad (8)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (9)$$

$$NRMSE = \frac{RMSE}{x_{max} - x_{min}} \quad (10)$$

$$bias = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i) \quad (11)$$

Em que, x é a variável do modelo; $\bar{x}$ é a média do valor de x ; $\hat{x}$ é o valor predito a partir da variável x ; x_{max} e x_{min} são os valores máximos e mínimos de x ; i são os i -ésimos valores de x ; e n é o número total de amostras.

4.5 Calibração do Modelo Bio-Óptico

Três algoritmos foram testados para ajustar os modelos de predição da concentração de chl-a: MLR, RF e MLP. Um total de 69 amostras foram utilizadas para o ajuste dos modelos. A MLR é um modelo estatístico empregado para prever uma variável dependente com base em duas ou mais variáveis independentes, baseado em uma relação linear entre os atributos de entrada e a variável resposta, minimizando o erro da predição por meio do método dos mínimos quadrados. Em contrapartida, o RF é um algoritmo de aprendizado de máquina baseado em um conjunto de árvores de decisão, enquanto o MLP é uma rede neural rasa, também caracterizada como aprendizado de máquina.

Os modelos bio-ópticos foram calibrados no *software Waikato Environment for Knowledge Analysis (Weka)*, livre de domínio da licença GLP (Licença Pública Geral GNU é uma licença de *software* livre proeminente criada pela *Free Software Foundation*

sob a liderança de Richard Stallman), criado por pesquisadores da Universidade de Waikato, Nova Zelândia. O *Weka* está implementado na linguagem Java, tornando sua utilização possível em diversos sistemas operacionais, devido a sua portabilidade. O *software* é capaz de pré-processar dados, aplicar diversos algoritmos de aprendizado de máquina de maneira rápida e possui ferramentas de visualização de dados para solucionar problemas de mineração e para comparação de dados de saída (<https://www.cs.waikato.ac.nz/ml/people.html>).

Os atributos de entrada para modelos regressivos correspondem às variáveis explicativas utilizadas para prever a variável de interesse. No contexto deste trabalho, foram testados como atributos de entrada as bandas espectrais capturadas pelo sensor *Agrowing* e alguns índices espectrais de chl-a fitoplanctônica, que fornecem informações sobre a resposta espectral da superfície da água e sua relação com a concentração de chl-a. Para a calibração dos modelos, foram utilizados índices espectrais disponíveis na literatura e, pelo menos, quatro bandas espectrais da câmera *Agrowing*. As diferentes combinações de atributos de entrada testados estão apresentadas na Tabela A1 do Apêndice.

A validação cruzada *k-fold* foi empregada para avaliar o desempenho dos modelos preditivos. O método consiste em dividir o conjunto de dados em '*k*' subconjuntos (*folds*), de tamanhos iguais, os quais são treinados *k-1* e usado o *k* restante para teste, em cada iteração. O objetivo é reduzir o risco de super ajustamento (*overfitting*) e aprimorar a capacidade de generalização do modelo. A *k-fold Cross Validation* é uma técnica de reamostragem e múltiplas iterações para a avaliação de modelos (GERÓN, 2022). Cabe mencionar que diferentes valores de *k-fold* foram testados, dentre eles, o valor igual a 10 e também igual ao número máximo de amostras para os modelos determinados (67 ou 69).

4.5.1 Seleção de atributos de entrada

Os atributos de entrada testados para a calibração dos modelos bio-ópticos foram apenas atributos espectrais: valores de *Rrs* das bandas simuladas da câmara *Agrowing*, e índices espectrais para estimação de chl-a na água, disponíveis na literatura.

4.5.1.1 Índices Espectrais

No total foram testados como atributos de entrada 15 índices espectrais, propostos por diferentes autores (Tabela 4), considerando as bandas disponíveis na câmara *Agrowing*. Os índices espectrais para estimação de chl-a tabelados serviram de base para diferentes estudos que estimaram a concentração do constituinte chl-a ao longo do tempo, fazendo uso de canais com comprimentos de onda na região do visível e NIR.

Tabela 4 - Tabela contendo os índices espectrais de estimação de chl-a testados para a construção dos modelos bio-ópticos para a estimação das concentrações de chl-a do sistema de aquacultura, no CEPTA/ICMBio. Na tabela estão contidas a identificação do índice espectral ou algoritmo, a fórmula adaptada para as bandas da câmara *Agrowing*, a significância, área de aplicação e referência.

Índice	I1
Fórmula Adaptada	$\frac{R_{rs710}}{R_{rs650}}$
Significância	Base para chegar a algoritmos mais robustos de estimação de chl-a que não exigiriam ajuste regional significativo
Área de Aplicação	Lagos estaduais de Fremont, Nebraska, Estados Unidos
Referência	Gilerson <i>et al.</i> (2010)
Índice	I2
Fórmula Adaptada	$\frac{R_{rs735}}{R_{rs650}}$
Significância	Base para chegar a algoritmos mais robustos de estimação de chl-a que não exigiriam ajuste regional significativo.
Área de Aplicação	Lagos estaduais de Fremont, Nebraska, Estados Unidos
Referência	Gilerson <i>et al.</i> (2010)
Índice	I3
Fórmula Adaptada	$\frac{R_{rs735}}{R_{rs650}} - \frac{R_{rs735}}{R_{rs710}}$
Significância	Base para chegar a algoritmos mais robustos de estimação de chl-a que não exigiriam ajuste regional significativo.
Área de Aplicação	Lagos estaduais de Fremont, Nebraska, Estados Unidos
Referência	Gilerson <i>et al.</i> (2010)
Índice	I4
Fórmula Adaptada	$315,5 \times \left[\left(\frac{R_{rs735}}{R_{rs650}} - \frac{R_{rs735}}{R_{rs710}} \right)^2 + 215,95 \right] \times \left[\left(\frac{R_{rs735}}{R_{rs650}} - \frac{R_{rs735}}{R_{rs710}} \right) + 22,66 \right]$

Significância	Investigar o desempenho de modelos de NIR para a estimativa remota de concentrações de chl-a em águas produtivas turvas
Área de Aplicação	Lagos Estaduais para recreação em Fremont, Nebraska, Estados Unidos
Referência	Gurlin <i>et al.</i> (2011)
Índice	I5
Fórmula Adaptada	$25,28 \times \left[\left(\frac{R_{rs}710}{R_{rs}650} \right)^2 + 14,85 \right] \times \left[\left(\frac{R_{rs}710}{R_{rs}650} \right) - 15,18 \right]$
Significância	Investigar o desempenho de modelos de NIR para a estimativa remota de concentrações de chl-a em águas produtivas turvas
Área de Aplicação	Lagos Estaduais para recreação em Fremont, Nebraska, Estados Unidos
Referência	Gurlin <i>et al.</i> (2011)
Índice	I6
Fórmula Adaptada	$190,34 \times \left[\left(\frac{R_{rs}735}{R_{rs}650} \right) - 32,45 \right]$
Significância	Investigar o desempenho de modelos de NIR para a estimativa remota de concentrações de chl-a em águas produtivas turvas
Área de Aplicação	Lagos Estaduais para recreação em Fremont, Nebraska, Estados Unidos
Referência	Gurlin <i>et al.</i> (2011)
Índice	I7
Fórmula Adaptada	$\frac{R_{rs}710 - R_{rs}650}{R_{rs}710 + R_{rs}650}$
Significância	Um novo modelo para estimativa remota da concentração de chl-a em águas produtivas turvas
Área de Aplicação	Baía de Chesapeake, Baía de Delaware, Baía de Mobile e região do delta do Rio Mississippi no norte do Golfo do México
Referência	Mishra e Mishra (2012)
Índice	I8
Fórmula Adaptada	$42,197 + \left[236,5 \times \left(\frac{R_{rs}710 - R_{rs}650}{R_{rs}710 + R_{rs}650} \right) \right] + \left[314,97 \times \left(\frac{R_{rs}710 - R_{rs}650}{R_{rs}710 + R_{rs}650} \right)^2 \right]$
Significância	Um novo modelo para estimativa remota da concentração de chl-a em águas produtivas turvas
Área de Aplicação	Baía de Chesapeake, Baía de Delaware, Baía de Mobile e região do delta do Rio Mississippi no norte do Golfo do México
Referência	Mishra e Mishra (2012)
Índice	I9
Fórmula Adaptada	$\frac{R_{rs}735}{R_{rs}650} - \frac{R_{rs}735}{R_{rs}710}$

Significância	Um índice de três bandas aprimorado para a estimação da concentração de chl-a, em lagos de água turvas de caso-II
Área de Aplicação	Lago Kasumigaura, Japão, e Lago Dianchi, China
Referência	Yang <i>et al.</i> (2010)
Índice	I10
Fórmula Adaptada	$\frac{R_{rs650} - R_{rs850}}{R_{rs650} + R_{rs850}}$
Significância	Desenvolvimento de um modelo empírico para estimar as concentrações de chl-a, gerando uma série temporal de longo prazo e determinando áreas de floração de algas, para dados do satélite MODIS-Aqua
Área de Aplicação	Lago taihu, China
Referência	Shi <i>et al.</i> (2017)
Índice	I11
Fórmula Adaptada	$7,45 \times \left[\frac{R_{rs525}}{\left(\frac{R_{rs450}}{R_{rs560}} \right)} \right]^{0,6}$
Significância	Índice para quantificar chl-a em águas do caso 2 (de produção turva estuarina e costeira) usando dados MERIS
Área de Aplicação	Baía de Keweenaw (Lago Superior) e Baía Verde (Lago Michigan), dois dos Grandes Lagos Laurentianos, Estados Unidos
Referência	Gons <i>et al.</i> (2008)
Índice	I12
Fórmula Adaptada	$\frac{R_{rs735} - R_{rs650}}{R_{rs735} + R_{rs650}}$
Significância	Identificar padrões espaciais na distribuição de chl-a, que estão associados ao processo de filtração causado pela cascata do reservatório do rio Tietê, São Paulo, Brasil
Área de Aplicação	Médio curso do rio Tietê, São Paulo, Brasil: Barra Bonita, Bariri e Ibitinga
Referência	Watanabe <i>et al.</i> , 2019
Índice	I13
Fórmula Adaptada	$\frac{R_{rs650} - R_{rs560}}{650 - 560}$
Significância	Quantificação da distribuição espaço-temporal da pluma (sólidos suspensos) e da floração (chl-a) em um lago usando dados de SR
Área de Aplicação	Lago Pontchartrain, Louisiana, Estados Unidos
Referência	Mishra e Mishra, 2010
Índice	I14

Fórmula Adaptada	$\frac{R_{rs685}}{R_{rs550}}$
Significância	Descoberta da variabilidade do rendimento quântico de fluorescência e do coeficiente de absorção específico da chl-a, que podem reduzir consideravelmente a precisão das previsões remotas do parâmetro
Área de Aplicação	Águas turvas e produtivas
Referência	Dall'Olmo e Gitelson, 2005
Índice	I15
Fórmula Adaptada	$\frac{R_{rs735}}{R_{rs685}} - \frac{R_{rs735}}{R_{rs710}}$
Significância	Descoberta da variabilidade do rendimento quântico de fluorescência e do coeficiente de absorção específico da chl-a, que podem reduzir consideravelmente a precisão das previsões remotas do parâmetro
Área de Aplicação	Águas turvas e produtivas
Referência	Dall'Olmo e Gitelson, 2005

4.5.2 Validação do modelo bio-óptico

A validação dos modelos bio-ópticos testados foi feita por meio das métricas: coeficiente de correlação R (Equação 12), MAE (Equação 13), RMSE e RAE (Equações 14). As métricas de validação dos modelos bio-ópticos são as métricas calculadas pelo *software Weka*. Para mais, os modelos foram avaliados por meio do método de *k-fold Cross Validation*, frequentemente adotada em abordagens baseadas em aprendizado de máquina, quando se tem poucas observações (JUNG, 2018).

$$R = \frac{\sum(x - \bar{x})(y - \bar{y})}{\sqrt{\sum(x - \bar{x})^2 \sum(y - \bar{y})^2}} \quad (12)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - \hat{x}_i| \quad (13)$$

$$RAE = \frac{\sum_{i=1}^n |x_i - \hat{x}_i|}{\sum_{i=1}^n |x_i - \bar{x}_i|} \quad (14)$$

Em que, x e y são variáveis do modelo; $\bar{x}$ e $\bar{y}$ são as médias dos valores de x e y , respectivamente; $\hat{x}$ é o valor predito a partir da variável x ; i são os i -ésimos valores de x ; e n é o número total de amostras.

5 RESULTADOS E DISCUSSÕES

Os resultados obtidos a partir do processamento e análise dos dados estão organizados nas seguintes etapas: análise descritiva de parâmetros limnológicos; comportamento espectral da *Rrs in situ*; ortomosaicos das imagens multiespectrais; avaliação da calibração radiométrica usando modelos linear e exponencial baseado em linha empírica; e avaliação do desempenho dos modelos bio-ópticos para a estimação da concentração de chl-a.

5.1 Estatística Descritiva dos Parâmetros Limnológicos adquiridos *in situ* e em Laboratório

A análise descritiva de parâmetros limnológicos adquiridos *in situ* foi uma etapa importante para a caracterização inicial do sistema de aquacultura analisado, gerando o entendimento da distribuição e variabilidade dos dados. Além disso, a análise descritiva auxilia na avaliação das variáveis, se estão dentro dos limites aceitáveis para diferentes usos, como a aquacultura.

A Tabela 5 apresenta as estatísticas descritivas dos dados limnológicos coletados *in situ* com a sonda multiparâmetros, disco de *Secchi* e determinados a partir de análises laboratoriais. Nessa tabela, os parâmetros estão caracterizados por números de amostras (N), média, mediana, valor mínimo e valor máximo registrados, e desvio-padrão. Os parâmetros foram divididos de acordo com o local de coleta das amostras (tanques, rio, represas e total). Vale mencionar novamente que em alguns pontos a sonda multiparâmetros não funcionou, não sendo possível coletar os dados.

Na literatura, é possível encontrar estudos que utilizam sondas multiparâmetros para obter dados de qualidade da água, uma vez que o equipamento garante uma padronização metodológica e a medição em tempo real (MENDONÇA, 2016). Andrietti *et al.* (2016) identificaram a qualidade da água superficial do Rio Caiabi, no Estado do Mato Grosso, por meio do cálculo do índice de qualidade da água (IQA), utilizando parâmetros medidos por uma sonda multiparâmetros *Horiba U-50*.

Tabela 5 - Estatísticas descritivas dos parâmetros limnológicos coletados *in situ*, por meio da sonda multiparâmetros (Turbidez, OD, STD, Temperatura, pH e Condutividade Elétrica), disco de *Secchi* (Profundidade do disco de *Secchi*) e destinados a análises laboratoriais (chl-a).

Parâmetros	N	Média	Med.	Mín.	Máx.	Desv.-Pad.
Chl-a (µg/L) - represas	20	24,27	18,63	6,35	59,80	15,47
Chl-a (µg/L) - tanques	51	36,69	35,17	1,60	73,96	18,28
Chl-a (µg/L) - rio	13	1,47	1,12	0,00	6,21	1,64
Chl-a (µg/L)	83	28,28	24,17	0,00	73,96	20,41
Turbidez (NTU) - represas	14	7,41	7,35	3,70	12,30	2,12
Turbidez (NTU) - tanques	41	24,75	17,90	0,90	97,10	21,05
Turbidez (NTU) - rio	13	65,25	79,20	35,50	89,80	20,58
Turbidez (NTU)	68	28,93	17,40	0,90	97,10	26,55
Prof. de <i>Secchi</i> (m) - represas	20	0,63	0,60	0,50	0,80	0,08
Prof. de <i>Secchi</i> (m) - tanques	41	0,50	0,55	0,15	0,80	0,15
Prof. de <i>Secchi</i> (m) - rio	13	0,38	0,24	0,15	0,60	0,21
Prof. de <i>Secchi</i> (m)	44	0,46	0,49	0,15	0,80	0,20
OD (mg/L) - represas	14	8,80	8,57	6,35	10,97	1,37
OD (mg/L) - tanques	41	7,24	6,94	3,30	11,79	1,44
OD (mg/L) - rio	13	8,22	7,67	6,68	17,28	2,77
OD (mg/L)	68	7,75	7,39	3,30	17,28	1,85
STD (g/L) - represas	14	0,02	0,01	0,01	0,03	2,12
STD (g/L) - tanques	41	0,01	0,01	0,01	0,03	0,00
STD (g/L) - rio	13	0,04	0,04	0,02	0,05	0,01
STD (g/L)	68	0,02	0,01	0,01	0,05	0,01
Temperatura (°C) - represas	14	27,84	27,58	25,81	29,99	1,25
Temperatura (°C) - tanques	41	29,41	29,11	27,20	33,11	1,36
Temperatura (°C) - rio	13	25,73	25,10	25,06	26,82	0,77
Temperatura (°C)	68	28,38	28,60	25,06	33,11	1,89
pH - represas	14	6,13	5,74	4,77	7,31	0,84
pH - tanques	41	7,49	7,27	6,29	8,93	0,75
pH - rio	13	7,41	7,39	7,14	7,84	0,20
pH	68	7,20	7,21	4,77	8,93	0,88
Cond. elétrica (mS/cm) - represas	14	0,03	0,02	0,01	0,04	0,01
Cond. elétrica (mS/cm) - tanques	41	0,02	0,02	0,01	0,04	0,01
Cond. elétrica (mS/cm) - rio	13	0,04	0,05	0,02	0,07	0,02
Cond. elétrica (mS/cm)	63	0,03	0,02	0,01	0,07	0,01

A análise dos parâmetros de qualidade da água ao longo do sistema represas-tanques-rio revela padrões coerentes com os processos biológicos e físicos ocorrendo em cada ambiente. De acordo com a Resolução CONAMA nº 357/2005, que estabelece padrões de qualidade de águas Classe 2, o limite específico de até 40 µg/L é considerado adequado em um sistema de aquacultura, a fim de evitar a eutrofização excessiva. A concentração de chl-a é mais elevada nos tanques (36,69 µg/L), intermediária nas represas (24,27 µg/L) e muito baixa no rio (1,47 µg/L), estando dentro dos limites estabelecidos.

Nos tanques, com a diminuição da vazão e devido à maior carga de nutrientes e matéria orgânica, o crescimento de fitoplâncton é favorecido, o que é esperado para ambientes aquícolas. Em contrapartida, no rio Mojiguaçu, a diminuição da chl-a era esperada, uma vez que é um rio antropizado, com alta carga de sedimentos e alta vazão, o que dificulta o desenvolvimento de organismos fitoplanctônicos. Quando a produção de fitoplâncton é baixa, fatores como a temperatura da água e a quantidade de OD são reduzidos e a profundidade do disco de *Secchi* tende a ser menor (WETZEL, 2001).

Idealmente, recomenda-se a turbidez abaixo de 50 NTU para a penetração suficiente da luz em corpos d'água (Resolução CONAMA 357/2005). A turbidez segue um padrão crescente ao longo do sistema, sendo menor nas represas (7,41 NTU), aumentando nos tanques (24,75 NTU) e atingindo o maior valor no rio (65,25 NTU), ultrapassando o limite recomendado na legislação. O comportamento da turbidez é confirmado pela profundidade de *Secchi*, que diminui de 0,63 m nas represas para 0,50 m nos tanques e 0,38 m no rio. A baixa transparência da água é comum em ambientes de alta turbidez, registrados especialmente no rio e em alguns tanques de piscicultura.

O oxigênio dissolvido (OD) apresenta valores elevados nas represas (8,80 mg/L), diminui nos tanques (7,24 mg/L) e volta a subir no rio (8,22 mg/L). A Resolução CONAMA 357/2005 estabelece que águas de Classe 2 devem apresentar valores mínimos de 5 mg/L, o que é atendido em todos os pontos analisados. A redução de OD nos tanques pode ser explicada pelo consumo de oxigênio devido à decomposição da matéria orgânica e à respiração dos organismos aquáticos. Segundo Boyd (1990), a média de OD, em torno de 7,24 mg/L, é comum em ambientes bem oxigenados e necessária para o desenvolvimento de diferentes espécies de peixe. O aumento no rio pode indicar processos de reaeração natural devido ao movimento da água.

As concentrações de sólidos totais dissolvidos (STD) foram baixas, sendo o maior valor registrado de 0,045 g/L. Esse valor segue as condições típicas de ambientes de água doce (BOYD, 1990). A temperatura da água é maior nos tanques (29,41°C), intermediária nas represas (27,84°C) e mais baixa no rio (25,73°C). A Resolução CONAMA 357/2005 não estipula um limite específico para a temperatura em águas de Classe 2, mas estabelece que variações significativas não devem comprometer a biota aquática, o que parece estar sendo respeitado na área estudada. Esse padrão é esperado, uma vez que os tanques têm menor profundidade e maior exposição ao sol, enquanto o rio, devido ao fluxo contínuo da água e à possível influência de águas subterrâneas, mantém temperaturas mais amenas.

O pH varia ao longo do sistema, sendo mais ácido nas represas (6,13), mais próximo da neutralidade nos tanques (7,49) e levemente alcalino no rio (7,41). De acordo com a Resolução CONAMA 357/2005, o pH das águas deve permanecer entre 6,0 e 9,0, o que é atendido em todos os pontos analisados, exceto em alguns valores mínimos nas represas. Essa variação pode estar associada à decomposição da matéria orgânica nas represas, ao consumo de CO₂ pela fotossíntese nos tanques e à presença de bicarbonatos dissolvidos no rio. A maior parte dos corpos d'água possuem condições favoráveis para a formação de ecossistemas aquáticos (BOYD, 1990).

A condutividade elétrica segue uma tendência de aumento ao longo do sistema, sendo baixa nas represas (0,03 mS/cm) e tanques (0,02 mS/cm), mas mais elevada no rio (0,04 mS/cm), sugerindo maior presença de íons dissolvidos devido à lixiviação do solo e ao escoamento superficial. Uma característica de águas doces é a baixa concentração de sais e minerais dissolvidos, logo, baixa capacidade de conduzir eletricidade, como mostram os valores registrados de condutividade elétrica (média 0,03 ms/cm).

De maneira geral, dados analisados demonstram uma progressão coerente dos parâmetros de qualidade da água ao longo do sistema represas-tanques-rio. A água proveniente dos tanques de criação não alterou as condições ambientais do rio adjacente no cenário estudado. A concentração de chl-a e OD diminui no rio, indicando menor atividade fotossintética e maior reaeração, atendendo aos padrões estabelecidos. A turbidez e os STD aumentam, refletindo o carregamento de partículas em suspensão, com valores elevados no rio que ultrapassam o limite para águas de Classe 2.

A temperatura é maior nos tanques, devido à maior exposição solar, enquanto o pH se ajusta para valores mais neutros ao longo do percurso, mantendo-se dentro dos limites da Resolução CONAMA 357/2005 na maioria dos pontos. Por fim, a condutividade elétrica cresce no rio, indicando maior concentração de sais dissolvidos, mas ainda dentro dos padrões esperados para águas doces. As tendências eram esperadas e refletem as interações naturais entre os diferentes compartimentos do sistema aquático.

5.2 Comportamento Espectral da *Rrs*

As curvas espectrais das bandas simuladas da câmara *Agrowing* em *Rrs* estão mostrados na Figura 18, em que (a) são as curvas espectrais de todas as amostras dos tanques de piscicultura, (b) curvas espectrais do rio e (c) curvas espectrais dos reservatórios. Nota-se a diferença do comportamento espectral para os diferentes corpos d'água,

considerando suas diferentes características ópticas. Nos gráficos, o eixo Y indica a Rrs , expressa em sr^{-1} , e o eixo X representa as bandas espectrais da câmara *Agrowing* distribuídas entre os comprimentos de onda de 430 nm a 850 nm.




Figura 18 — Respostas espectrais em Rrs , estimadas a partir dos dados de L , coletadas *in situ*. (a) são as curvas espectrais de todas as amostras dos tanques de piscicultura, (b) curvas espectrais do rio, (c) curvas espectrais dos reservatórios.

De acordo com as respostas espectrais observadas, as curvas mostram alta absorção nas bandas da região azul (430 nm a 490 nm) do espectro, característica típica em corpos d'água interiores, visto que a luz é altamente absorvida pelos COAs presentes nos corpos d'água estudados, ou seja, chl-a, material particulado em suspensão e CDOM. O fitoplâncton absorve luz na faixa do azul do espectro eletromagnético ao realizar o processo de fotossíntese (MOBLEY, 1994), logo, a alta absorção pode indicar presença de comunidade fitoplanctônica, exceto para as curvas (b), pois segundo as medidas dos parâmetros limnológicos coletados *in situ*, o rio possui pouca ($< 3 \mu\text{g/L}$) ou nenhuma concentração de chl-a.

O pico de reflectância na região da luz verde (entre 530 nm e 580 nm) enfatizado nos gráficos (a) e (c), estão associados a presença do pigmento chl-a, variando de intensidade, indicando diferentes concentrações de fitoplâncton ou sedimentos, os quais influenciam a reflectância nesta região (BUKATA *et al.*, 2018). Ainda, o pico de absorção em torno de 670 nm, seguido de um pico de reflectância por volta de 710 nm é característico da presença de chl-a na água (DEKKER e PETERS, 1993).

Sobre as curvas espectrais mensuradas no rio (b), a reflectância em comprimentos de onda menores ($< 450 \text{ nm}$) é reduzida, devido a absorção pelo CDOM e partículas em suspensão, as quais dispersam a luz na região do azul. A curva espectral apresenta um aumento inicial, seguido por uma estabilização no intervalo do espectro visível entre 550 nm e 720 nm. Esse comportamento é atribuído à interação da radiação eletromagnética com partículas em suspensão, que promovem a reflexão e dispersão da luz, resultando em uma maior resposta espectral nessa faixa (KIRK, 2011).

De maneira geral, os corpos d'água apresentam variações nos teores de chl-a, CDOM, material particulado em suspensão e outros COAs em menores proporções (BARBOSA *et al.*, 2019). Consequentemente, as curvas espectrais resultam da interação simultânea desses constituintes, cujas concentrações influenciam a resposta espectral do meio aquático, ressaltadas por picos de absorção.

A queda acentuada da reflectância após 720 nm é caracterizada pela alta absorção da luz pela água na faixa do NIR. A presença de sedimentos e partículas em suspensão podem aumentar o espalhamento na faixa entre 720 nm e 850 nm. Em águas muito turvas, a reflectância pode ser um pouco mais alta, devido ao retroespalhamento da luz pelas partículas, entretanto, à medida que o comprimento de onda aumenta, a alta absorção pela água é dominante (a partir de 740 nm) (MOBLEY, 1994).

5.3 Ortomosaico gerado a partir das imagens coletadas via ARP

Os ortomosaicos mostrados na Figura 19 apresentam a área de estudo. Foram recortados e mantidos apenas os corpos d'água presentes no local e que compunham o sistema de cultivo de peixes. Ambos os ortomosaicos da Figura 19 estão em uma composição colorida cor verdadeira, formada pelas bandas 650 nm/ 550 nm/ 450 nm (RGB). Enfatiza-se que foram produzidos dois mosaicos, correspondentes ao número de voos (VOO1 e VOO2), necessários para que toda a área do sistema de aquacultura fosse abrangida.




Figura 19 — Ortomosaicos gerados a partir das imagens coletadas via ARP em ND.

O recorte dos corpos d'água foi realizado manualmente em uma escala de 1/500, portanto, com alto nível de detalhe. As áreas escuras identificadas nas bordas dos corpos d'água, principalmente, nos rios e reservatórios, correspondem a vegetação aquática, árvores de grande porte, cujas copas sobrepõem a água e, também, a respectiva sombra das copas das árvores.

No ortomosaico do VOO2, nota-se a presença de lacunas (buracos) no interior dos reservatórios. Elas ocorrem pela dificuldade em gerar o mosaico em corpos d'água, causada pela não identificação de pontos homólogos em áreas homogêneas. Esse é um problema documentado na fotogrametria, especialmente em locais onde faltam características distintas, as quais possam ser identificadas quando as imagens são

sobrepostas (DEWITT e WOLF, 2000). Neste caso, devido a altíssima resolução espacial das imagens, a homogeneidade da área e a falta de pontos homólogos, o *software* não foi capaz de gerar o mosaico em algumas regiões dos reservatórios.

Um problema similar foi reportado por Fraser *et al.* (2024), que utilizaram do sistema UAS-SfM (*Unpiloted Aerial Systems and Structure from Motion*) para a modelagem de ambientes de água doce, fornecendo a capacidade de análise de características dos corpos d'água em altíssimas resoluções. Entretanto, na construção dos mosaicos para a avaliação do mapeamento de cianobactérias, encontraram desafios quanto aos impactos quantitativos e qualitativos resultantes da seleção do *software* fotogramétrico, da altura de voo e das técnicas de processamento de imagens. Independente da técnica de modelagem utilizada, os ortomosaicos gerados mostravam porções de incompletude, comprometendo o fluxo de trabalho.

Para contornar o problema das lacunas nos ortomosaicos, estudos recentes estão sendo desenvolvidos na literatura. Román *et al.* (2022) criaram um código em linguagem *Python*, melhorado por Román *et al.* (2024), de modo que não apenas a coordenada do ponto central de cada captura é considerada, mas também a geometria de cada um dos cantos é calculada para seu posicionamento correto no ortomosaico final. Este novo código usa o posicionamento da aeronave durante o voo (latitude, longitude, altitude e orientação do voo) e as características do sensor montado nela (distância focal, tamanho da captura, tamanho do sensor, dimensões do plano focal).

5.4 Calibração radiométrica das imagens por linha empírica usando modelos linear e exponencial

A calibração radiométrica das imagens foi realizada utilizando os dados de campo do dia 21 de julho de 2023, quando também foram coletadas as radiância das placas de referência e realizados os voos para a tomada das imagens da área de estudo. Os resultados da aplicação das calibrações radiométricas realizadas banda a banda estão apresentados apenas para as bandas centradas em 560 nm, 650 nm, 685 nm, 710 nm e 735 nm, uma vez que elas foram adotadas como atributo de entrada para o desenvolvimento dos modelos bio-ópticos, a partir dos índices espectrais.

Na Tabela 6, são mostrados os valores de ND e *Rrs* dos alvos de referência utilizados no VOO1, ou seja, as placas de E.V.A nas cores branca, cinza escura e preta, além de uma amostra de água. Os valores em ND dos alvos de referência para calibração

foram extraídos das imagens tomadas na área de estudo. Por sua vez, os valores de *Rrs* dos alvos de calibração medidos em campo utilizando o espectrorradiômetro. Assim, a Tabela 6 apresenta os dados usados para o desenvolvimento dos modelos de calibração radiométrica linear e exponencial do VOO1.

Tabela 6 - Dados utilizados para o desenvolvimento dos modelos de calibrações radiométricas linear e exponencial do VOO1.

Bandas Alvos	560 nm		650 nm		685 nm		710 nm		735 nm	
	ND	<i>Rrs</i>	ND	<i>Rrs</i>	ND	<i>Rrs</i>	ND	<i>Rrs</i>	ND	<i>Rrs</i>
Branco	255	0,2167	255	0,2239	255	0,2242	255	0,2288	255	0,2300
Cinza E.*	150	0,0678	254	0,0722	220	0,0738	237	0,0750	197	0,0762
Preto	68	0,0131	125	0,0138	107	0,0141	120	0,0143	102	0,0145
T. A62**	72	0,0068	107	0,0053	85	0,0045	109	0,0046	58	0,0016

*Cinza Escuro **Tanque Enumerado A62

A Figura 20 mostra os cinco gráficos com o ajuste linear das bandas centradas em 560 nm, 650 nm, 685 nm, 710 nm e 735 nm, usando os dados da Tabela 6. Cada gráfico exibe a relação entre os valores em ND (eixo X) e os valores em *Rrs* (eixo Y). Os valores de R^2 indicam o grau de ajuste da reta. Para o modelo linear, a banda espectral em 560 nm (verde) mostrou o melhor ajuste ($R^2 = 0,9729$), enquanto a banda 650 nm (vermelho) o pior ajuste ($R^2 = 0,6299$).

O baixo ajuste identificado para a banda espectral em 650 nm é decorrente do alto valor de ND, de 254, para o alvo cinza escuro, muito próximo ao valor do alvo branco, de 255, gerando uma fraca relação linear. A alta resposta espectral do alvo cinza escuro sugere que os alvos de referência de E.V.A. utilizados podem não ser adequados para a realização de calibrações radiométricas de imagens aéreas tomadas de corpos d'água. Alvos de outros materiais e que sejam lambertianos poderiam mostrar melhores resultados.




Figura 20 — Ajuste linear (VOO1) das bandas 560 nm, 650 nm, 685 nm, 710 nm e 735 nm, juntamente com a equação da reta e o coeficiente de determinação correspondente.

Após a aplicação do modelo na imagem, notou-se uma magnitude diferente entre a Rrs *in situ* e da imagem. Para compensar essa diferença foi ajustado um fator de correção baseado no *bias*. Uma vez que a calibração radiométrica linear, no contexto do VOO1, não foi altamente satisfatória, a Figura 21 mostra um gráfico de linha que representa o valor do *bias* calculado e aplicado por banda (multiplicado), com o objetivo de melhorar as métricas avaliativas, e, portanto, ajustar magnitude do modelo aplicado, para a posterior geração do modelo bio-óptico. Observa-se uma variação nos valores de *bias* entre as bandas espectrais centradas em 560 nm e 710 nm, enquanto a banda em 735 nm apresenta um valor negativo. Ressalva-se que fatores de escalas iguais para todas as bandas foram testados, a fim apenas de ajustar a magnitude, porém bons resultados não foram gerados.




Figura 21 — *Bias* aplicado como uma correção por banda, por meio de uma multiplicação, posteriormente a calibração radiométrica linear, do VOO1.

Em contrapartida, o ajuste exponencial do VOO1 (Figura 22) obteve resultados de R^2 superiores a 0,90 (banda 650 nm). Diferente do modelo exponencial, o modelo linear pode apresentar um padrão de resíduos não homogêneos, evidenciando uma inadequação do ajuste, principalmente quando a relação entre as variáveis não segue uma tendência linear direta. Assim, o modelo exponencial pode resultar em um ajuste mais adequado aos dados que apresentam um crescimento lento, seguido de um aumento rápido e estabilização, positivo para água, devido ao baixo sinal de resposta (MOTULSKY e RANSNAS, 1987). Vale ressaltar, que apesar do melhor ajuste encontrado por meio do modelo exponencial, outros alvos de referência para a calibração das imagens poderiam mostrar um desempenho superior.




Figura 22 — Ajuste exponencial (VOO1) das bandas 560 nm, 650 nm, 685 nm, 710 nm e 735 nm, juntamente com a equação da reta e o coeficiente de determinação correspondente.

Apesar do melhor desempenho alcançado para o ajuste do modelo, o *bias* também foi aplicado ao modelo exponencial (Figura 23). O *bias* para a banda espectral centrada em 735 nm não foi negativo para ajuste exponencial, assim como para o ajuste linear (Figura 21). Entretanto, o valor é baixo, visto que nos comprimentos de onda do *red edge* chega menos energia do que nos comprimentos de onda do visível, gerando um *bias* proporcional a quantidade de energia mensurada.




Figura 23 — Bias aplicado como uma correção por banda, por meio de uma multiplicação, posteriormente a calibração radiométrica exponencial, do VOO1.

Um problema observado, neste estudo, ao ajuste radiométrico linear é a geração de valores de Rrs negativos para alvos de água que são mais escuros do que alvos de referência (placas) utilizados para a calibração radiométrica. Neste cenário, os valores resultantes são fisicamente inválidos, uma vez que a Rrs não deve ser negativa. Esses valores negativos exigiam o uso de técnicas de correção adicionais, como optado pela aplicação do método de ajuste exponencial e a aplicação do *bias* como fator de correção.

Do Carmo *et al.* (2019) utilizou de métodos de linha empírica, linear e exponencial, aplicados a imagens hiperespectrais de águas interiores combinados com alvos de referência e medições de água *in situ*. Como resultados obtiveram uma melhor correspondência com o ajuste exponencial, atingindo um R^2 de 0,87 e resultados adequados para derivar dados de reflectância dos NDs brutos das imagens.

A Tabela 7 apresenta os dados utilizados para o desenvolvimento dos modelos das calibrações radiométricas linear e exponencial para o VOO2. Diferente do primeiro VOO1, o VOO2 mostrou um melhor ajuste radiométrico linear (Figura 24), com R^2 superior a 0,92 (banda em 735 nm). O melhoramento no ajuste radiométrico pode estar associado ao uso de diferentes alvos de calibração. Neste experimento, o alvo cinza escuro foi utilizado como alvo mais claro (maior brilho) e dois alvos na cor preta, com diferentes respostas espectrais, como alvos intermediários. Esta combinação de alvos não foi utilizada para a calibração radiométrica do VOO1, visto que um dos alvos na cor preta não foi identificado no ortomosaico, ou seja, não foi alocado corretamente na área de estudo para que aparecesse em ambos os voos.

Tabela 7 - Dados utilizados para o desenvolvimento dos modelos de calibrações radiométricas linear e exponencial do VOO2.

Bandas	560 nm		650 nm		685 nm		710 nm		735 nm	
	ND	Rrs	ND	Rrs	ND	Rrs	ND	Rrs	ND	Rrs
Alvos										
Cinza E*	148	0,068	250	0,072	221	0,074	245	0,075	193	0,076
Preto	76	0,013	135	0,014	115	0,014	137	0,014	106	0,015
T. Preto**	60	0,008	111	0,009	91	0,010	111	0,010	89	0,010
T. A30***	41	0,005	76	0,004	612	0,004	78	0,003	44	0,001

*Cinza Escuro **Tatame Preto ***Tanque Enumerado A30




Figura 24 — Ajuste linear (VOO2) das bandas 560 nm, 650 nm, 685 nm, 710 nm e 735 nm, juntamente com a equação da reta e o coeficiente de determinação correspondente.

O *bias* aplicado por banda para os resultados do ajuste linear do VOO2 (Figura 25), mostra valor positivo em 560 nm, diminuindo em 650 nm, aumentando novamente em 710 nm e, finalmente, apresenta um valor negativo em 735 nm. Esse padrão é ligeiramente diferente do observado na Figura 21, sugerindo uma variação no *bias* aplicado entre os dois voos.




Figura 25 — Bias aplicado como uma correção por banda, por meio de uma multiplicação, posteriormente a calibração radiométrica linear, do VOO2.

O ajuste radiométrico exponencial para o VOO2 (Figura 26), assim como para o VOO1, mostrou valores de R^2 superiores a 0,90. Comparando os valores de *bias* estimados para o ajuste exponencial dos VOO1 (Figura 23) e VOO2 (Figura 27), ambos os gráficos mostram um declínio geral na *Rrs* à medida que o comprimento de onda aumenta, embora apresentem padrões diferentes nos valores de pico e vale. Uma diferença é o valor do *bias* para a banda centrada em 560 nm, que para o VOO1 é metade do valor da *Rrs* para o VOO2, sendo $0,012 \text{ sr}^{-1}$ e $0,024 \text{ sr}^{-1}$, respectivamente.




Figura 26 — Ajuste exponencial (VOO2) das bandas 560 nm, 650 nm, 685 nm, 710 nm e 735 nm, juntamente com a equação da reta e o coeficiente de determinação correspondente.




Figura 27 — Biais aplicado como uma correção por banda, por meio de uma multiplicação, posteriormente a calibração radiométrica exponencial, do VOO2.

O resultado dos modelos, linear e exponencial, após a aplicação do *bias* estão mostrados na Tabela 8, para os voos 1 e 2, aplicados às bandas espectrais de 560 nm, 650 nm, 685 nm, 710 nm e 735 nm. O desempenho dos modelos foi similar para ambos os ajustes, linear e exponencial, visto que todas as métricas avaliadas apresentam valores

próximos entre as bandas espectrais. Os resultados mostram um *bias* negativo consistente, indicando que ambos os modelos (linear e exponencial) tendem a subestimar as medidas reais em diferentes bandas espectrais. O modelo exponencial pode ser vantajoso em situações em que os dados apresentam crescimento lento, depois um aumento rápido seguido de uma estabilização (curva assintótica), um comportamento comum em respostas espectrais de corpos d'água com alta concentração de material em suspensão (KUHN e JOHNSON, 2013; DEKKER e PETTERS, 1993).

Tabela 8 - Resultados da performance da aplicação dos modelos linear e exponencial, depois da aplicação do bias como fator de correção, expressos em RMSE, NRMSE e bias.

Bandas	Modelos	Linear			Exponencial		
		RMSE (sr ⁻¹)	NRMSE (%)	bias (sr ⁻¹)	RMSE (sr ⁻¹)	NRMSE (%)	bias (sr ⁻¹)
VOO1	560 (nm)	0.0099	64.30	-0.0087	0.0099	64.30	-0.0087
	650 (nm)	0.0083	49.89	-0.0071	0.0091	55.19	-0.0078
	685 (nm)	0.0079	50.00	-0.0067	0.0083	52.67	-0.0070
	710 (nm)	0.0066	53.98	-0.0057	0.0075	61.19	-0.0065
	735 (nm)	0.0036	58.04	-0.0030	0.0036	57.44	-0.0030
VOO2	560 (nm)	0.0071	48.77	-0.0064	0.0070	47.83	-0.0062
	650 (nm)	0.0065	47.95	-0.0057	0.0065	48.02	-0.0057
	685 (nm)	0.0058	44.69	-0.0050	0.0058	45.39	-0.0051
	710 (nm)	0.0055	44.25	-0.0047	0.0057	45.94	-0.0050
	735 (nm)	0.0035	31.28	-0.0027	0.0035	31.24	-0.0027

5.5 Estimação da concentração de chl-a por meio dos modelos MLR, RF e MLP, baseado nos diferentes métodos de calibração radiométrica

As avaliações obtidas dos modelos bio-ópticos, para a recuperação da concentração de chl-a, foram extraídas e convertidas para um vetor de pontos, permitindo a análise pontual da chl-a nas áreas amostradas. Em seguida, para cada vetor de ponto correspondente as áreas de interesse, foi criado um *buffer box* de 3×3 pixels ao redor da coordenada de coleta (Figura 28). Dentro deste *buffer box*, foi selecionado o valor de chl-a que apresentava a menor diferença em relação ao valor medido em campo, visando obter uma estimativa mais precisa.




Figura 28 — Buffer box de 3x3 pixels, ao redor da coordenada de coleta de chl-a, cujo valor de concentração era conhecido.

Os modelos MLR, RF e MLP foram ajustados por meio do *software Weka*. Os atributos de entrada que melhor ajustaram os modelos estão na Tabela 1A do apêndice. O experimento 101 foi o melhor para o ajuste do MLR. Foram utilizados como atributos de entrada: índices I5, I8, I10, I14 e I16; e bandas: 10, 11, 12 e 13. Na validação cruzada por *k-fold* foi usado *k* igual a 10, obtendo um $R = 0,75$, $MAE = 8,69 \mu\text{g/L}$, $RMSE = 13,04 \mu\text{g/L}$ e $RAE = 54,34\%$. Com métricas similares, o experimento 124 foi o melhor para o ajuste do RF. Foram utilizados os atributos de entrada: índices I8, I14 e I16. A validação por *k-fold* usando *k* igual a 65, obteve-se $R = 0,77$, $MAE = 8,66 \mu\text{g/L}$, $RMSE = 12,45 \mu\text{g/L}$ e $RAE = 53,03\%$. O experimento 114 foi o melhor para o ajuste do MLP. Foram utilizados os atributos de entrada: índices I5, I8, I10, I14 e I16; o *k-fold* foi igual a 67, $R = 0,77$, $MAE = 9,66 \mu\text{g/L}$, $RMSE = 12,82 \mu\text{g/L}$ e $RAE = 58,93\%$.

Na data da captura das imagens foram coletadas 10 amostras de água e dados radiométricos. Logo, os primeiros testes realizados, para a avaliação dos modelos bio-ópticos foram realizados apenas para as 10 amostras. Na Tabela 9 está disposta a performance dos modelos bio-ópticos, baseados no método de calibração radiométrica e no número de amostras que o modelo foi capaz de estimar. O modelo de MLR não foi capaz de estimar o conteúdo de chl-a para alguns pontos amostrais (pixels), pois foram estimados apenas seis pontos de um total de 10, baseado em ajuste linear, e nove pontos de um total de 10, baseado no ajuste exponencial.

As razões podem ser devido à complexidade do ambiente aquático; influências de variáveis não lineares, em decorrência de fenômenos de absorção e espalhamento na água, especialmente em águas muito turvas, causando variações não-lineares, as quais a MLR

não consegue capturar. A variabilidade nas amostras pode ser outro empecilho que não permite que a MLR estime chl-a para todos os pontos, uma vez que o ajuste linear pode não ser capaz de generalizar para todas as condições (DIERSSSEN, 2010).

Tabela 9 - Performance dos modelos MLR, RF e MLP, para as amostras coletadas em julho de 2023, de acordo com ajuste radiométrico linear ou exponencial.

Método	Número de Amostras	Modelos	RMSE (µg/L)	NRMSE (%)	bias (µg/L)
Linear	6	MLR	9,61	63,23	4,41
Linear	10	RF	13,48	29,58	4,81
Linear	10	MLP	30,82	67,67	-2,83
Exponencial	9	MLR	4,05	23,93	1,64
Exponencial	10	RF	6,82	40,27	4,28
Exponencial	10	MLP	9,72	57,41	7,14

De maneira geral, os modelos aplicados às imagens ajustadas linearmente apresentam RMSE e NRMSE mais altos, o que indica uma precisão menor em relação aos modelos aplicados às imagens ajustadas exponencialmente. O valor de NRMSE para o RF foi uma exceção, visto que foi maior para a imagem derivada do modelo exponencial, do que a imagem derivada do modelo linear. Em relação a calibração radiométrica das imagens, o ajuste exponencial pode descrever melhor o comportamento dos dados, quando se aplica os modelos bio-ópticos, em comparação com o ajuste linear simples.

Para ambos os métodos de calibração radiométricas (linear e exponencial), os quais as imagens foram ajustadas, o modelo bio-óptico MLR apresentou resultados relativamente bons, mas o desempenho melhora significativamente com as imagens ajustadas pelo método exponencial (RMSE de 4,05 µg/L e NRMSE de 23,93%). Isso indica que o modelo MLR pode capturar bem a variação dos dados, especialmente com uma abordagem exponencial.

O modelo RF teve um desempenho satisfatório. Para as imagens derivadas do ajuste linear, o NRMSE é igual a 29,58%, sugerindo um bom ajuste relativo, embora o RMSE ainda seja considerado alto (13,48 µg/L). O RF aplicado às imagens derivadas do método exponencial, o NRMSE aumentou para 40,27% e o RMSE diminuiu para 6,82 µg/L. A relação inversa entre as métricas RMSE e NRMSE pode ocorrer devido a escala de normalização, em outras palavras, se os dados possuem valores concentrados, ou seja, baixa variabilidade, o denominador do NRMSE diminui, tornando o NRMSE maior para o mesmo RMSE.

Diferentemente, o MLP apresentou os piores resultados, com RMSE e NRMSE altos, especialmente para o modelo aplicado as imagens exponencialmente ajustadas (RMSE de 30,82 $\mu\text{g/L}$ e NRMSE de 67,67%). Portanto, o MLP pode não ser uma escolha adequada para esse conjunto de dados, uma vez que ajustes ou treinamentos adicionais com os dados sejam necessários.

Os gráficos de dispersão referentes aos dados da Tabela 9 estão mostrados nas Figuras 29 e 30. Os gráficos mostram a relação entre as concentrações de chl-a previstas (eixo Y) e as medidas em campo (eixo X), para os três modelos diferentes MLR, RF e MLP, os quais usaram as imagens calibradas pelo método linear (Figura 28) e exponencial (Figura 29). Cada gráfico inclui a linha de regressão e o R^2 , que indica o grau de ajuste entre os valores preditos e reais.




Figura 29 — Gráficos de dispersão dos valores de chl-a ($\mu\text{g/L}$), considerando os valores medidos em campo e os valores preditos pelos modelos MLR, RF e MLP, gerados a partir dos dados provenientes da calibração radiométrica linear.

Na Figura 29, o modelo MLR apresentou o melhor ajuste entre os três, com um R^2 de 0,6955, o que indica que aproximadamente 69,55% da variação dos valores de chl-a observados pode ser explicada pelos valores preditos. A linha de regressão tem uma inclinação positiva, sugerindo que o MLR conseguiu captar a relação entre as concentrações preditas e reais de forma razoável, ainda que haja alguma dispersão dos pontos.

O modelo RF mostrou um ajuste fraco, com um R^2 de apenas 0,0412, indicando que ele explica apenas cerca de 4,12% da variação dos valores reais. A inclinação da linha é semelhante à do MLR, mas a dispersão dos pontos em torno da linha de regressão é bem maior, o que revelou a ineficácia do modelo em estimar corretamente a chl-a. De antemão, o MLP apresentou o pior desempenho entre os três. O R^2 é de 0,0402, indicando que ele explicou apenas cerca de 4,02% da variação dos valores reais. Além disso, a linha de regressão possui uma inclinação negativa, contrário ao esperado, pois concentrações maiores de chl-a preditas deveriam corresponder a valores maiores de chl-a reais. Assim, o MLP pode estar modelando de forma errônea a relação entre as variáveis ou sofrendo de problemas de ajuste.

Os modelos bio-ópticos aplicados às imagens ajustadas pelo método exponencial (Figura 30) mostraram uma melhor dispersão dos dados. Considerando que todas as amostras deveriam ser analisadas, o RF mostrou um melhor desempenho ($R^2 = 0,3056$) comparado ao MLP ($R^2 = 0,1907$). O melhor ajuste foi o do MLR, com R^2 de 0,5748, apesar do modelo não ser capaz de estimar valores de chl-a para todos os pixels.




Figura 30 — Gráficos de dispersão dos valores de chl-a (µg/L), considerando os valores medidos em campo e os valores preditos pelos modelos MLR, RF e MLP, gerados a partir dos dados provenientes da calibração radiométrica exponencial.

Os modelos bio-ópticos aplicados às imagens foram avaliados quanto ao seu desempenho na predição de chl-a para todo o sistema de aquacultura. Além disso, foram

considerados pontos do rio e dos reservatórios na análise. Os dados das diferentes campanhas de campo foram validados, mesmo que as medidas *in situ* tenham sido adquiridas em diferentes datas e períodos sazonais (fevereiro de 2022 e fevereiro de 2023). Pelo sistema de aquacultura ser um ambiente controlado, não existem grandes variações da qualidade da água ao longo dos anos.

A Tabela 10 mostra os resultados das métricas RMSE, NRMSE e *bias*, para os modelos MLR, RF e MLP, considerando os ajustes linear ou exponencial para calibração radiométrica das imagens e separadas as amostras coletadas nas regiões dos voos 1 e 2. Para ambos os voos o total de amostras analisadas foram 71 (26 VOO1 e 45 VOO2).

Em suma, os modelos bio-ópticos aplicados às imagens ajustadas exponencialmente obtiveram menores valores de RMSE e NRMSE em comparação com os modelos aplicados às imagens ajustadas linearmente. No entanto, o modelo MLP no VOO2 apresentou um desempenho muito inferior para as imagens ajustadas pelo método exponencial. Os resultados foram RMSE alto de 45,91 $\mu\text{g/L}$ e um NRMSE de 74,01%. O modelo ajustado por MLR mostraram uma maior precisão na estimativa de chl-a, com erros baixos e sendo capaz de estimar todos os pontos amostrais. Neste mesmo contexto, o RF também estimou resultados satisfatórios.

Tabela 10 - Desempenho dos modelos MLR, RF e MPL na estimativa da concentração de chl-a em diferentes datas e diferentes corpos d'água que compõem o sistema de aquacultura, considerando o voo realizado e o método de calibração radiométrico das imagens.

Método	Número de Amostras	Modelos	RMSE ($\mu\text{g/L}$)	NRMSE (%)	<i>bias</i> ($\mu\text{g/L}$)
VOO1 - L	25	MLR	18,31	24,78	-3,27
VOO1 - L	26	RF	19,00	25,71	-2,74
VOO1 - L	26	MLP	38,04	51,49	-21,06
VOO1 - E	21	MLR	11,44	15,47	-1,65
VOO1 - E	26	RF	12,26	16,60	-1,89
VOO1 - E	26	MLP	12,40	16,78	0,43
VOO2 - L	26	MLR	18,27	29,45	-1,70
VOO2 - L	45	RF	18,44	29,74	-3,58
VOO2 - L	45	MLP	31,28	50,43	-9,74
VOO2 - E	33	MLR	12,27	20,26	-0,77
VOO2 - E	45	RF	15,26	24,60	0,75
VOO2 - E	45	MLP	45,91	74,01	17,28

L – linear E - exponencial

Na Figura 31, estão representados os gráficos de dispersão dos modelos MLR, RF e MLP, dos voos 1 e 2, aplicados apenas às imagens ajustadas exponencialmente, base

das melhores performances e os melhores resultados desde o início do desenvolvimento deste trabalho. A boa performance do modelo exponencial de calibração radiométrica pode ser em decorrência do comportamento da penetração da luz na coluna d'água e seu comportamento em relação às diferentes composições e concentrações de componentes opticamente ativos, que não possuem comportamento linear. Além disso, a água possui um comportamento exponencial em função do aumento da profundidade. Esse fenômeno é descrito pela Lei de Beer-Lambert, que afirma que a intensidade da luz diminui exponencialmente conforme aumenta a profundidade devido à absorção e dispersão pela água e por partículas em suspensão (KIRK, 2011).

A chl-a encontrada em organismos fotossintetizantes, como o fitoplâncton, responde diretamente à penetração da luz. A concentração de chl-a, geralmente, diminui com a profundidade, mas depende da intensidade de luz incidente na superfície, acompanhando a diminuição da luz disponível para a fotossíntese. Modelos que preveem a concentração de chl-a em função da profundidade muitas vezes utilizam essa relação exponencial de penetração da luz para estimar a produtividade primária em diferentes camadas da coluna d'água (EL-ALEM *et al.*, 2014; HUSSEIN e MOHAMMED, 2020; ZHANG *et al.*, 2024). Para mais, modelos de aprendizado de máquina regressivos (JIN *et al.*, 2024; GARCÍA-NIETO *et al.*, 2024) e modelos lineares (HUANG e ZANG, 2024) são comumente usados para prever concentrações de chl-a, em diferentes corpos d'água.




Figura 31 — Os gráficos de dispersão dos modelos MLR, RF e MLP, dos voos 1 e 2, apenas para o método de calibração radiométrica exponencial.

O número de amostras total para a interpretação dos dados do VOO1 foi 26, enquanto que para o VOO2 foram 45. Cabe ressaltar novamente que o MLR não foi capaz de estimar o conteúdo de chl-a para todos os pontos, para o VOO1 foram apenas 21 pontos e para o VOO2 33 pontos. Apesar do déficit de amostras resultantes, o MLR gerou os melhores R^2 para ambos os voos, sendo $R^2 = 0,7677$ para o VOO1 e $R^2 = 0,3835$ para o VOO2. De modo semelhante, o RF também mostrou bons resultados de R^2 para ambos os voos ($R^2 = 0,7626$ e $R^2 = 0,2267$, respectivamente). Dentre as métricas analisadas, o MLP para o VOO2 não foi eficiente. A correlação entre os dados foi negativa e fraca, uma vez que a reta mostrou uma inclinação descendente e os pontos estavam distantes da reta, sugerindo alta variabilidade e pouca precisão ($R^2 = 0,0096$).

Um dos fatores que contribuíram para que as métricas do VOO2 não atingissem resultados satisfatórios foi provavelmente a falha no alinhamento fotogramétrico. A área de cobertura do VOO2 incluía dois reservatórios que não foram mapeados integralmente,

resultando em buracos no ortomosaico gerado. Consequentemente, os pixels ao redor dessas lacunas apresentaram valores incorretos, uma vez que o *software* tentou ajustar encontrar pontos homólogos da melhor forma possível, mas não obteve sucesso devido à ausência de pontos homólogos suficientes nessas regiões. É observado na Figura 19, um brilho diferente nos pixels ao redor das lacunas, o que pode ter diminuído a precisão das informações geradas na região.

5.6 Concentrações de Chl-a Estimadas Espacialmente

Uma limitação técnica relevante ao expandir o mapeamento de chl-a para toda a área de estudo foi o grande volume de pontos gerados (milhões de pontos). Em razão disso, apenas foram gerados dois mapas da distribuição espacial de chl-a na área, os quais correspondem a aplicação dos modelos RF (Figura 32) e MLP (Figura 33), em dados oriundos da calibração radiométrica de ajuste exponencial.




Figura 32 — Mapa da distribuição espacial de chl-a, estimada por meio do modelo bio-óptico RF, oriundo das imagens calibradas radiometricamente pelo método exponencial.

A Figura 32 mostra um mapa da distribuição espacial da chl-a para todos os corpos d'água analisados da área de estudo. A legenda apresenta uma escala de cor verde que varia de tons mais claros (indicando menor concentração de chl-a, 1,439 µg/L) a tons mais escuros (indicando maior concentração, 67,68 µg/L). O maior valor de chl-a estimado é menor do que a maior concentração de chl-a em campo, logo o modelo subestimou os dados, o que é condizente com o valor do *bias* negativo resultado para o VOO1. Visualmente a distribuição não é uniforme, mas é condizente. No rio Mojiguaçu a concentração de chl-a é baixa, devido à alta velocidade de corrente do corpo d'água, enquanto que nos tanques e represas as concentrações de chl-a são variada. As variações espaciais também podem ser influenciadas pela circulação da água, resíduos de alimentação, ou excrementos dos peixes.

Distribuição espacial de clorofila-a (chl-a) em um sistema de aquacultura, no CEPTA/ICMBio




Figura 33 — Mapa da distribuição espacial de chl-a, estimada por meio do modelo bio-óptico MLP, oriundo das imagens calibradas radiometricamente pelo método exponencial.

A Figura 33 mostra o resultado da aplicação do modelo bio-óptico MLP à imagem, que mostra um mapa da distribuição espacial da chl-a para todos os corpos d'água analisados da área de estudo. A legenda do mapa apresenta um gradiente de verde indicando a concentração de chl-a de 0 µg/L até 167 µg/L, ultrapassando os valores do intervalo real de concentrações observadas em campo (73,96 µg/L). Portanto, concentrações acima de 73,96 µg/L indicadas no mapa podem ser superestimções pelo modelo MLP, que precisa ser analisado e ajustado para melhor representação dos dados reais. Além disso, parte dos valores acima do intervalo de chl-a real se encontram na região das lacunas dos reservatórios.

Dentro do intervalo real (0 a 73,96 $\mu\text{g/L}$), as áreas mais escuras do gradiente verde (Figura 33) continuam representando concentrações mais altas de chl-a, enquanto áreas mais claras indicam concentrações mais baixas. Os pontos com valores negativos (em vermelho) nas bordas indicam a presença de *outliers*, especialmente em transições de área aquática para terrestre, macrófitas que não foram detectadas por outros modelos, e grades sobre alguns tanques de piscicultura.

O fato do modelo MLP ter identificado concentrações fora da faixa real observada em campo (superiores a 73,96 $\mu\text{g/L}$) sugere a necessidade de ajustes no treinamento e validação do modelo. Uma possível solução seria restringir as estimativas a um limite máximo baseado nos valores observados em campo ou aplicar filtros para remover valores não plausíveis. A presença de valores negativos também destaca a necessidade de calibrar o modelo para evitar estimativas inválidas, especialmente em áreas de borda.

6 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES PARA TRABALHOS FUTUROS

O estudo mostrou a viabilidade do uso de imagens multiespectrais de altíssima resolução espacial, oriundas da câmara multiespectral *Agrowing*, integrada a uma ARP, para a estimativa da concentração de chl-a em águas interiores. O estudo foi conduzido em um sistema de tanques de aquacultura, composto por um trecho do rio Mojiguaçu; tanques de piscicultura; e dois reservatórios de alimentação dos tanques.

A captura das imagens por meio da câmara *Agrowing* foi realizada a partir do uso de uma ARP, auxiliada pela tecnologia da coleta automática de coordenadas. Foram realizados dois voos para cobrir toda a área de estudo. Tomadas as imagens brutas, foi realizado o processamento para a exportação das cenas em .TIFF, 8 bits e alinhamento das bandas espectrais. Depois o processo fotogramétrico para a construção dos ortomosaicos. Houve dificuldades no alinhamento fotogramétrico durante o processo de geração do ortomosaico, devido à presença de grandes corpos d'água (reservatórios), e a falta de pontos homólogos. Isso impactou diretamente a acurácia do mapeamento, uma vez que lacunas não foram preenchidas nas imagens, evidenciando a necessidade de aprimoramentos na etapa de processamento geométrico das imagens.

Para a compatibilização dos dados coletados *in situ* e as imagens multiespectrais, visando o desenvolvimento de modelos bio-ópticos de predição do conteúdo chl-a, foram testados dois ajustes para a calibração radiométrica por meio da linha empírica: linear e

exponencial. O modelo exponencial resultou em um desempenho superior ao ajuste linear, considerando os diversos experimentos realizados. Esse resultado alinha-se às observações de estudos anteriores, que destacam a limitação dos ajustes lineares em fenômenos ambientais com padrões de crescimento não lineares.

Para o desenvolvimento de modelo bio-ópticos, as bandas espectrais da câmara *Agrowing* e índices espectrais disponíveis na literatura, mas adaptados para as bandas da câmara, foram utilizados. Foram testados índices provenientes de outros trabalhos, os quais estimavam a chl-a em ambientes túrbidos e eutrofizados, geralmente utilizando bandas do vermelho e *red edge*. Como esperado, a utilização de bandas espectrais em comprimentos de onda maiores apresentou desempenho satisfatório na predição de chl-a. Bandas em menores comprimentos de onda (como a de 405 nm) não foram utilizadas devido à baixa sensibilidade da câmera e ao aumento de erros relacionados ao espalhamento da luz, o que comprometeria a precisão do modelo.

A partir do desenvolvimento de modelos de predição, foi possível identificar que o uso de abordagens baseadas em árvores de decisão apresentara um desempenho superior em comparação com técnicas de redes neurais rasas (MLP). Destacou-se o algoritmo RF, capaz de estimar para todos os pixels o conteúdo de chl-a, com uma boa precisão para ambos os voos (VOO1 – RMSE = 12,26 µg/L, NRMSE = 16,60%, bias = -1,89, $R^2 = 0,7626$; VOO2 - RMSE = 15,26 µg/L, NRMSE = 24,60%, bias = 0,75, $R^2 = 0,2267$). O RF foi capaz de ajustar relações não lineares complexas, uma vez que havia muita variabilidade óptica entre os diferentes corpos d'água presentes que compunham o siste, além da integração entre os atributos espectrais e as concentrações de chl-a. O MLR também mostrou resultados significativos no ajuste e, para alguns casos, com maior acurácia do que o RF (VOO1 – RMSE = 11,44 µg/L, NRMSE = 15,47%, bias = -1,65, $R^2 = 0,7677$; VOO2 - RMSE = 12,27 µg/L, NRMSE = 20,26%, bias = -0,77, $R^2 = 0,2825$). No entanto, ao aplicar na imagem, os valores eram negativos ou não preditos.

Com base nos resultados obtidos, conclui-se que a água proveniente dos tanques de criação não alterou as condições ambientais do rio adjacente no cenário estudado. Isso ocorre porque os materiais incorporados à água, como restos de ração e excrementos dos peixes, são predominantemente de origem orgânica e se diluem rapidamente em um corpo d'água de maior volume e vazão. Contudo, é importante ressaltar que essa dinâmica pode variar conforme as características do rio receptor. Em rios de menor dimensão ou com qualidade de água já comprometida, o aporte de efluentes de tanques de criação poderia contribuir para um aumento na carga orgânica e potencial risco de eutrofização,

especialmente em períodos de baixa vazão. Portanto, o monitoramento contínuo é essencial para detectar alterações ao longo do tempo e garantir que não haja impactos cumulativos significativos na qualidade da água, especialmente em sistemas mais vulneráveis.

Em relação a trabalhos futuros, é recomendado investigar métodos de correção geométrica a fim de evitar lacunas nos ortomosaicos. É necessário definir um melhor fluxo para o processamento fotogramétrico. Para o método de calibração radiométrica, recomenda-se a investigação o uso de diferentes alvos de referência, feitos de diferentes materiais, bem como o uso de alvos do próprio terreno, como corpos d'água isolados. Espera-se que placas de calibração mais escuras e com comportamento mais difuso sejam capazes de gerar os modelos mais confiáveis, minimizando a estimativa de Rrs negativas.

Vale também investigar a razão sinal-ruído (*signal-noise ratio* - SNR) das bandas da câmara *Agrowing*, pois valores baixos de SNR não são adequados para estimativa de COAs, uma vez que a água possui uma baixa resposta espectral. Resoluções espaciais, principalmente menores, poderiam ser avaliadas. Devido à área de estudo ser próxima à Academia da Força Aérea de Pirassununga, não foi possível tomar imagens em altura de voo maior. Outras configurações da câmara, como aumento do tempo de exposição, poderiam melhorar a SNR baixo sinal da água. A resolução radiométrica também foi um fator limitador neste trabalho que usou 8 bits. Em aplicações de SR da cor da água, o uso de imagens em 16 bits poderia melhorar as estimativas de chl-a. Por fim, recomenda-se também testar outros algoritmos e diferentes abordagens de modelagem bio-óptica.

REFERÊNCIAS

ALITA, D.; PUTRA, A. D.; DARWIS, D. Analysis of Classic assumption test and multiple linear regression coefficient test for employee structural office recommendation. *Indonesian Journal of Computing and Cybernetics Systems*, v. 15, pp. 295 – 306, 2021. DOI: 10.22146/ijccs.65586

ALVAREZ, E. V.; CORPETTI, T.; HOUET, T.. UAV & satellite synergies for optical remote sensing applications: A literature review. *Science of remote sensing*, v. 3, p. 100019, 2021. DOI: 10.1016/j.srs.2021.100019.

ANDRIETTI, G.; FREIRE, R.; AMARAL, A. G. D.; ALMEIDA, F. T. D.; BONGIOVANI, M. C.; SCHNEIDER, R. M. Índices de qualidade da água e de estado trófico do rio Caiabi, MT. *Revista Ambiente & Água*, v. 11, p. 162-175, 2016.

ANSARI, Abid A.; GILL, Sarvajeet S.; KHAN, Fareed A. Eutrophication: threat to aquatic ecosystems. *Eutrophication: causes, consequences and control*, p. 143-170, 2011. DOI: 10.1007/978-90-481-9625-8_7

ANSARI, E.; AHTAR, M. N.; ABDULLAH, M. N.; OTHMAN, W. A. F. W.; BAKAR, E. A.; HAWARY, A. F.; ALHADY, S. S. N. Processamento de imagens de UAV para reconhecimento de características fluviais do rio Kerian, Malásia. *Sustentabilidade*, v. 13, p. 9568, 2021. DOI: 10.3390/su13179568.

ANSPER, A.; ALIKAS, K. Retrieval of chlorophyll a from Sentinel-2 MSI data for the European Union water framework directive reporting purposes. *Remote Sensing*, v. 11, n. 1, p. 64, 2018. DOI: 10.3390/rs11010064.

BAI, X.; WANG, J.; CHEN, R.; KANG, Y.; DING, Y.; LV, Z.; DING, D.; FENG, H.. Research progress of inland river water quality monitoring technology based on unmanned aerial vehicle hyperspectral imaging technology. *Environmental Research*, v. 257, p. 119254, 2024. ISSN 0013-9351. DOI: 10.1016/j.envres.2024.119254.

BARBOSA, C. C. F.; NOVO, E. M. L. M.; MARTINS, V. S. *Introdução ao sensoriamento remoto de sistemas aquáticos*. São José dos Campos: LabIsa INPE, 1ª ed., 161 p., 2019.

BOTHA, E. J.; ANSTEE, J. M.; SAGAR, S.; LEHMANN, E.; MEDEIROS, T. A. G. Classification of Australian waterbodies across a wide range of optical water types. *Remote Sensing*, v. 12, n. 18, p. 3018, 2020.

BOWKER, D. E.; DAVIS, R. E.; MYRICK, D. L.; STACY, K.; JONES, W. T. Spectral Reflectances of Natural Targets for Use in Remote Sensing Studies. NASA Reference Publication 1139, 1985.

BOYD, C. E. *Water Quality in Ponds for Aquaculture*. Alabama Agricultural Experiment Station/Auburn University, Alabama, 1990.

BRASIL. Conselho Nacional do Meio Ambiente (CONAMA). Resolução nº 357, de 17 de março de 2005. Dispõe sobre a classificação dos corpos de água e diretrizes ambientais para o seu enquadramento, bem como estabelece as condições e padrões de lançamento de efluentes. *Diário Oficial da União*, Brasília, DF, 18 mar. 2005.

BREIMAN, L. Bagging predictors. *Machine Learning*, v. 26, n. 2, p. 123–140, 1996.

BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5-32, 2001. DOI: 10.1023/A:1010933404324.

BRICAUD, A.; BABIN, M.; MOREL, A.; CLAUSTRE, H. Variability in the chlorophyll-specific absorption coefficients of natural phytoplankton: Analysis and parameterization. *Journal of Geophysical Research: Oceans*, v. 100, n. C7, p. 13321-13332, 1995.

BUKATA, R. P.; JEROME, J. H.; KONDRATYEV, A. S.; POZDNYAKOV D. V. *Optical properties and remote sensing of inland and coastal waters*. CRC press, 2018.

BURGGRAAFF, Olivier. Biases from incorrect reflectance convolution. *Optics express*, v. 28, n. 9, p. 13801-13816, 2020. DOI: 10.1364/OE.391470

CASADO, M. R.; GONZALEZ, R. B.; KRIECHBAUMER, T.; VEAL, A. Automated Identification of River Hydromorphological Features Using UAV High Resolution Aerial Imagery. *Sensors*, v. 15, p. 27969–27989, 2015.

CASSOL, M. L. DEBASTIANI, S. M. Proposta de implantação de um viveiro municipal em Cascavel/PR. *Revista Competitividade e Sustentabilidade*. v. 7, n. 1, p. 24-38, 2020.

CHEN, G.; WANG, Y.; GU, X.; CHEN, T.; LIU, X.; LV, W.; ZHANG, B.; TANG, R.; HE, Y.; LI, G. Estimating water quality parameters of freshwater aquaculture ponds using UAV-based multispectral images. *Agricultural Water Management*, v. 304, 2024. ISSN 0378-3774. DOI: 10.1016/j.agwat.2024.109088.

CHENG, K. H.; CHAN, S. N.; LEE, J. H. W. Remote sensing of coastal algal blooms using unmanned aerial vehicles (UAVs). *Marine Pollution Bulletin*, v. 152, 2020. DOI: 10.1016/j.marpolbul.2020.110889.

CILLERO CASTRO, C.; DOMÍNGUEZ GÓMEZ, J. A.; DELGADO MARTÍN, J.; HINOJO SÁNCHEZ, B. A.; CEREIJO ARANGO, J. L.; CHEDA TUYA, F. A.; DÍAZ-VARELA, R. An UAV and satellite multispectral data approach to monitor water quality in small reservoirs. *Remote Sensing*, v. 12, n. 9, p. 1514, 2020.

CILLERO CASTRO, C.; DOMÍNGUEZ GÓMEZ, J. A.; DELGADO MARTÍN, J.; HINOJO SÁNCHEZ, B. A.; CEREIJO ARANGO, J. L.; CHEDA TUYA, F. A.; DIAZ-VARELA, R. An UAV and satellite multispectral data approach to monitor water quality in small reservoirs. *Remote Sensing*, v. 12, n. 9, p. 1514, 2020.

CUTLER, D. R.; EDWARDS JR., T. C.; BEARD, K. H.; *et al.* Random forests for classification in ecology. *Ecology*, v. 88, p. 2783-2792, 2007. DOI: 10.1890/07-0539.1.

DALL'OLMO, G.; GITELSON, A. A. Effect of bio-optical parameter variability on the remote estimation of chlorophyll-a concentration in turbid productive waters:

experimental results. *Applied Optics*, v. 44, p. 412-422, 2005. DOI: 10.1364/AO.44.000412.

DARWISH, K. M.; IBRAHIM, O. M.; AWAD, F. Artificial neural network and spatial distribution of soil attributes for farming management in Western Desert, Egypt. *Arabian Journal of Geosciences*, v. 15, n. 15, p. 1324, 2022. DOI: 10.1007/s12517-022-10565-w

DEKKER, A. G. *Detection of optical water quality parameters for eutrophic waters by high resolution remote sensing*. 1993. 206 f. Tese (Doutorado em Sensoriamento Remoto). Vrije Universiteit, Amsterdam.

DEKKER, A. G.; PETERS, S. W. M. The use of the Thematic Mapper for the analysis of eutrophic lakes: A case study in the Netherlands. *International Journal of Remote Sensing*, v. 14, n. 5, p. 799-821, 1993. DOI: 10.1080/01431169308904379.

DENG, Y.; ZHANG, Y.; PAN, D.; YANG, S. X.; GHARABAGHI, B. Review of recent advances in remote sensing and machine learning methods for lake water quality management. *Remote Sensing*, v. 16, p. 4196, 2024. DOI: 10.3390/rs16224196.

DEWITT, B. A.; WOLF, P. R. *Elements of Photogrammetry (with Applications in GIS)*. McGraw-Hill Higher Education, 2000.

DIERSSSEN, H. M. Perspectives on empirical approaches for ocean color remote sensing of chlorophyll in a changing climate. *Proceedings of the National Academy of Sciences*, v. 107, n. 40, p. 17073-17078, 2010.

DO CARMO, A. F. C.; BERNARDO, N. M. R.; IMAI, N. N.; SHIMABUKURO, M. H. Improving the empirical line method applied to hyperspectral inland water images by combining reference targets and *in situ* water measurements. *Remote Sensing Letters*, v. 11, n. 2, p. 186–194, 2019. DOI: 10.1080/2150704X.2019.1692383.

DÖRNNHÖFER, K.; OPPELT, N. Remote sensing for lake research and monitoring - Recent advances. *Ecological Indicators*, v. 64, p. 105–122, 2016. DOI: 10.1016/j.ecolind.2015.12.009.

EL-ALEM, A.; CHOKMANI, K.; LAURION, I.; SE, EL-A. An adaptive model to monitor chlorophyll-a in inland waters in southern Quebec using downscaled MODIS imagery. *Remote Sensing*, v. 6, n. 7, p. 6446-6471, 2014.

FALKOWSKI, P. G.; RAVEN, J. A. *Aquatic photosynthesis*. Princeton University Press, 2013.

FIELD, C. B.; BEHRENFELD, M. J.; RANDERSON, J. T.; FALKOWSKI, P. G. Primary production of the ocean: the oceanic carbon cycle. *Science*, v. 281, n. 5374, p. 237–240, 1998.

FRASER, B. T.; BUNYON, C. L.; CONGALTON, R. G. Conducting Structure-from-Motion (SfM) Modeling of Freshwater Environments using Unpiloted Aerial Systems (UAS): Challenges and Lessons Learned. *Faculty Publications*, n. 2061, 2024.

GAO, Y.; JIA, J.; LU, Y.; *et al.* Determining dominating control mechanisms of inland water carbon cycling processes. *Earth-Science Reviews*, v. 213, 103497, 2021. DOI: 10.1016/j.earscirev.2020.103497.

GARCÍA-NIETO, P. J.; GARCÍA-GONZALO, E.; FERNÁNDEZ, J. R. A.; MUÑIZ, C. D. Forecast of chlorophyll-a concentration as an indicator of phytoplankton biomass in El Val reservoir by utilizing various machine learning techniques: A case study in Ebro river basin, Spain. *Journal of Hydrology*, v. 639, p. 131639, 2024.

GAT, N. Imaging spectroscopy using tunable filters: a review. *Wavelet Applications VII*, v. 4056, p. 50-64, 2000. DOI: 10.1117/12.381686

GÉRON, A. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media, Inc., 2022.

GILERSON, A. A.; GITELSON, A. A.; ZHOU, J.; *et al.* Algorithms for remote estimation of chlorophyll-a. *Optics Express*, v. 18, p. 24109-24125, 2010.

GITELSON, A. A.; DALL'OLMO, G.; MOSES, W.; RUNDQUIST, D. C.; BARROW, T.; FISHER, T. R.; GURLIN, D.; HOLZ, J. A simple semi-analytical model for remote estimation of chlorophyll-a in turbid waters. *Remote Sensing of Environment*, v. 12, p. 3582–3593, 2008.

GITELSON, A. A.; GRITZ, U.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, v. 160, p. 271–282, 2003.

GITELSON, A. A.; GURLIN, D.; MOSES, W.; YACOBI, Y. Remote estimation of chlorophyll-a concentration. In: *Q. Weng (Ed.), Advances in environmental remote sensing*. CRC Press, pp. 449-478, 2011.

GITELSON, A. A.; KUTSER, T.; HEMMINGA, M. A. Remote sensing of chlorophyll in turbid productive waters: Challenges and new approaches. *Aquatic Biology*, v. 1, p. 15-21, 2007. DOI: 10.3354/ab00002.

GITELSON, A. The peak near 700 nm on radiance spectra of algae and water. *International Journal of Remote Sensing*, v. 13, n. 17, p. 3367-3373, 1992.

GITELSON, A.; GARBUZOV, G.; SZILAGYI, F.; MITTENZWEY, K. H.; KARNIELI, A.; KAISER, A. Quantitative remote sensing methods for real-time monitoring of inland waters quality. *International Journal of Remote Sensing*, v. 14, n. 17, p. 1269–1295, 1993.

GORDON, H. R.; CLARK, D. K.; BROWN, J. W.; BROWN, O. B.; EVANS, R. H.; BROCK, J. C. Phytoplankton pigment concentrations. *Applied Optics*, v. 22, p. 20-36, 1983. DOI: 10.1364/AO.22.000020

GORDON, H. R.; MOREL, A. Y. Remote assessment of ocean color for interpretation of satellite visible imagery: A review. *Lecture Notes on Coastal and Estuarine Studies*. Springer, 1983.

GURLIN, D.; GITELSON, A. A.; MOSES, W. J. Remote estimation of Chl-a concentration. *Remote Sensing of Environment*, v. 115, p. 3479–3490, 2011.

HASHEMI-BENI, L.; GEBREHIWOT, A. A. Flood extent mapping: an integrated method using deep learning and region growing using UAV optical data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 14, 2021. DOI: 1109/JSTARS.2021.3051873.

HINTON, G. E. *Connectionist learning procedures*. In: *Machine learning*. Morgan Kaufmann, p. 555-610, 1990.

HUANG, H.; ZHANG, J. Prediction of chlorophyll a and risk assessment of water blooms in Poyang Lake based on a machine learning method. *Environmental Pollution*, v. 347, p. 123501, 2024.

HUSSEIN, Nidal M.; ASSAF, Mohammed N. Multispectral Remote Sensing Utilization for Monitoring Chlorophyll-a Levels in Inland Water Bodies in Jordan. *The Scientific World Journal*, v. 2020, n. 1, p. 5060969, 2020.

IOCCG. Remote sensing of ocean colour in coastal, and other optically-complex, waters. In: SATHYENDRANATH, S. (ed.). *Reports of the International Ocean-Colour Coordinating Group*, n. 3. Dartmouth: IOCCG, 2000.

IRIE, M.; MANABE, Y.; YAMASHITA, M. Método de estimativa da distribuição da concentração de clorofila com base em imagens aéreas de UAV considerando a distribuição de água turva em um reservatório. *Drones*, v. 8, p. 224, 2024. DOI: 10.3390/drones8060224

ISGRÓ, M. A.; BASALLOTE, M. D.; CABALLERO, I.; BARBERO, L. Comparison of UAS and Sentinel-2 multispectral imagery for water quality monitoring: a case study for acid mine drainage affected areas (SW Spain). *Remote Sensing*, v. 14, n. 16, p. 4053, 2022. DOI: 3390/RS14164053/S1.

ISHWARAN, H.; KOGALUR, U. B.; GORODESKI, E. Z.; MINN, A. J.; LAUER, M. S. High-dimensional variable selection for survival data. *Journal of the American Statistical Association*, v. 105, n. 489, p. 205-217, 2010.

JANG, W.; KIM, J.; KIM, J. H.; SHIN, J.-K.; CHON, K.; KANG, E. T.; PARK, Y.; KIM, S. Evaluation of Sentinel-2 based chlorophyll-a estimation in a small-scale reservoir: assessing accuracy and availability. *Remote Sensing*, v. 16, n. 2, p. 315, 2024. DOI: 10.3390/rs16020315.

JENSEN, J. R. *Remote Sensing of Environment: An Earth Resource Perspective*. Upper Saddle River: Prentice Hall, 544 p., 2000.

JENSEN, J. R. *Sensoriamento Remoto do ambiente: uma perspectiva em recursos terrestres*. 2ª ed. São José dos Campos: Parênteses, 2009.

JIN, S. H.; JARGAL, N.; KHAING, T. T.; CHO, M. J.; CHOI, H.; ARIUNBOLD, B.; AN, K. G. Long-term prediction of algal chlorophyll based on empirical models and the machine learning approach in relation to trophic variation in Juam Reservoir, Korea. *Heliyon*, v. 10, n. 11, 2024.

JOHANSEN, K.; DUNNE, A. F.; TU, Y. H.; ALMASHHARAWI, S.; JONES, B. H.; MCCABE, M. F. Dye tracing and concentration mapping in coastal waters using unmanned aerial vehicles. *Scientific Reports*, v. 12, n. 1, p. 1141, 2022.

JORGE, D. S.; LOISEL, H.; JAMET, C.; DESSAILLY, D.; DEMARIA, J.; BRICAUD, A.; ANDON, O. F. A three-step semi analytical algorithm (3SAA) for estimating inherent optical properties over oceanic, coastal, and inland waters from remote sensing reflectance. *Remote Sensing of Environment*, v. 263, p. 112537, 2021. DOI: 10.1016/j.rse.2021.112537

JUNG, Y. Multiple predicting K-fold cross-validation. *Journal of Nonparametric Statistics*, v. 30, n. 1, p. 197-215, 2018. DOI: 10.1080/10485252.2017.1404598.

KEINER, L. E.; YAN, X. H. A neural network model for estimating sea surface chlorophyll and sediments from thematic mapper imagery. *Remote sensing of environment*, v. 66, n. 2, p. 153-165, 1998.

KIM, H. H.; KO, B. C.; NAM, J. Y. Predicting chlorophyll-a using Landsat 8 OLI sensor data and the non-linear RANSAC method – a case study of Nakdong River, South Korea. *International Journal of Remote Sensing*, v. 34, n. 14, p. 3255–3271, 2016. DOI: 10.1080/01431161.2016.1196839

KINGMA, D. P.; BA, J. *Adam: A method for stochastic optimization*. arXiv preprint, arXiv:1412.6980, 2014.

KIRK, J. T. O. *Light & Photosynthesis in Aquatic Ecosystems*. 3^a ed. Cambridge: Cambridge University Press, 2011.

KISE, M.; PARK, B.; HEITSCHIMIDT, G. W.; LAWRENCE, K. C. WINDHAM, W. R. Multispectral imaging system with interchangeable filter design. *Computers and Electronics in Agriculture*, v. 72, n. 2, p. 61-68, 2010. DOI: 10.1016/j.compag.2010.02.005

KUBITZA, Fernando *et al.* *Qualidade da água na produção de peixes*. F. Kubitza, 1999.

KUHN, M.; JOHNSON, K. *Applied Predictive Modeling*. New York: Springer, 2013.

KUSTER, T.; HIIRE, M.; METSAMAA, L.; VAHTMÄE, E.; PAAVEL, B.; APS, R. Field measurements of spectral backscattering coefficient of the Baltic Sea and boreal lakes. *Boreal Environment Research*, v. 14, p. 305–312, Helsinki, 2009.

LE, C.; LI, Y.; ZHA, Y.; *et al.* A four-band semi-analytical model. *Remote Sensing of Environment*, v. 113, n. 6, p. 1175-1182, 2009. DOI: 10.1016/j.rse.2009.02.005.

LEE, Z.; AHN, Y. H.; MOBLEY, C.; ARNONE, R. Removal of surface-reflected light for the measurement of remote-sensing reflectance from an above-surface platform. *Optics Express*, v. 18, n. 25, p. 26313-26324, 2010. DOI: 10.1364/OE.18.026313.

LINNET, K. Evaluation of regression procedures for methods comparison studies. *Clinical Chemistry*, v. 39, n. 3, p. 424-432, 1993.

MAFANYA, M.; TSELE, P.; BOTAI, J. O.; MANYAMA, P.; CHIRIMA, G. J.; MONATE, T. Radiometric calibration framework for ultra-high-resolution UAV-derived orthomosaics for large-scale mapping of invasive alien plants in semi-arid woodlands: *Harrisia pomanensis* as a case study. *International Journal of Remote Sensing*, v. 39, p. 1–22, 2018.

MARTENS, N.; NAES, T. *Multivariate calibration*. New York: John Wiley & Sons, 1989.

MATTHEWS, M.W. Bio-optical modeling of phytoplankton chlorophyll-a. In: *Bio-optical modeling and remote sensing of inland waters*. Elsevier, p. 157-188, 2017.

MENDONÇA, A. M. *Confiabilidade dos parâmetros monitorados em águas por sonda multiparâmetros*. Dissertação (Mestrado) — Universidade Federal de Santa Maria, Santa Maria, 2016. Disponível em: <https://repositorio.ufsm.br/handle/1/7656>. Acesso em: 21 nov. 2024.

MILTON, E. J. Principles of Field Spectroscopy. *International Journal of Remote Sensing*, v. 8, n. 12, p. 1807-1827, 1987. DOI: 10.1080/01431168708954818.

MISHRA, D. R.; MISHRA, S. Plume and bloom: effect of the Mississippi River diversion on the water quality of Lake Pontchartrain. *Geocarto International*, v. 25, n. 7, p. 555–568, 2010. DOI: 10.1080/10106041003763394.

MISHRA, S.; MISHRA, D. R. Normalized difference chlorophyll index: A novel model for remote estimation of chlorophyll-a concentration in turbid productive waters. *Remote Sensing of Environment*, v. 117, p. 394-406, 2012. DOI: 10.1016/j.rse.2011.10.016.

MOBLEY, C. D. Estimation of the remote-sensing reflectance from above-surface measurements. *Applied Optics*, v. 38, p. 7442-7455, 1999. DOI: 10.1364/AO.38.007442.

MOBLEY, C. D. The optical properties of water. In: *Handbook of Optics*. M. Bass (Ed.). New York: McGraw-Hill Book, 1994.

MOREAL, A. Optical properties of pure water and pure seawater. *Optical aspects of oceanography*, 1974.

MOREL, A.; BRICAUD, A. Inherent optical properties of algal cells including picoplankton: theoretical and experimental results. In: *Canadian Bulletin of Fisheries and Aquatic Sciences. 214: Photosynthetic picoplankton*, Ed: T & Li, W.K.W., p. 521-559, 1986.

MOTULSKY, Harvey J.; RANSNAS, Lennart A. Fitting curves to data using nonlinear regression: a practical and nonmathematical review. *The FASEB journal*, v. 1, n. 5, p. 365-374, 1987.

MPAKAIRI, K. S.; MUTHIVHI, F. F.; DONDOFEMA, F.; MUNYAI, L. F.; DALU, T. Chlorophyll-a unveiled: unlocking reservoir insights through remote sensing in a subtropical reservoir. *Environmental Monitoring and Assessment*, v. 196, p. 401, 2024. DOI: 10.1007/s10661-024-12554-w.

MUELLER, J. L. In-water radiometric profile measurements and data analysis protocols. In: *Ocean Optics Protocols for Satellite Ocean Color Sensor Validation*. Mueller, J. L.; Fargion, G. S.; McClain, C. R. (Eds.). Greenbelt, MD: NASA Goddard Space Flight Space Center, p. 7-20, 2003.

NICOLÁS, M. V.; LÓPEZ, S. G.; BARBERO, L.; ORTIZ, V. R.; BELLÓN, Á. S. Applications of Unmanned Aerial Systems (UASs) in Hydrology: A Review. *Remote Sensing*, v. 13, p. 1359, 2021. DOI: 10.3390/rs13071359.

NOVO, E. M. L. M.; HAMSOM, J. D.; CURRAN, P. J. The effect of sediment type on the relationship between reflectance and suspended sediment concentration. *International Journal of Remote Sensing*, v. 10, n. 7, p. 1283-1289, 1989. DOI: 10.1080/01431168908903967.

ODERMATT, D.; GITELSON, A. A.; BRANDO, V. E.; SCHEAPMAN, M. Review of constituent retrieval in optically deep and complex waters from satellite imagery. *Remote Sensing of Environment*, v. 118, pp. 116-126, 2012.

OGASHAWARA, I. Terminology and classification of bio-optical algorithms. *Remote Sensing Letters*, v. 6, n. 8, p. 613-617, 2015. DOI: 10.1080/2150704X.2015.1066523

OLIVETTI, D.; ROIG, H.; MARTINEZ, J. M.; BORGES, H.; FERREIRA, A.; CASARI, R. Low-cost unmanned aerial multispectral imagery for siltation monitoring in reservoirs. *Remote Sensing*, v. 12, n. 11, p. 1855, 2020. DOI: 3390/RS12111855.

ONO, E. A.; CAMPOS, J.; KUBITZA, F. Construção de viveiros e de estruturas hidráulicas para o cultivo de peixes. *Revista Panorama da Aquicultura*, v.12, n.74, p.15-29, 2002.

OSHIRO, T. M. *Uma abordagem para a construção de uma única árvore a partir de uma Random Forest para classificação de bases de expressão gênica*. 2013. Tese de Doutorado. Universidade de São Paulo.

OUMA, Y. O.; NOOR, K.; HERBERT, K. Modelling Reservoir Chlorophyll-a, TSS, and Turbidity Using Sentinel-2A MSI and Landsat-8 OLI Satellite Sensors with Empirical Multivariate Regression. *Journal of Sensors*. Special Issue: Advanced Sensor Technologies in Geospatial Sciences and Engineering, 2020. DOI: 10.1155/2020/8858408

PAHLEVAN, N.; SMITH, B.; SCHALLES, J.; BINDING, C.; CAO, Z.; MA, R.; ALIKAS, K.; KANGRO, K.; GURLIN, D.; HÀ, N.; MATSUSHITA, B.; MOSES, W.; GREB, S.; LEHMANN, M. K.; ONDRUSEK, M.; OPPELT, N.; STUMPF, R. Seamless retrievals of chlorophyll-a from Sentinel-2 (MSI) and Sentinel-3 (OLCI) in inland and coastal waters: a machine learning approach. *Remote Sensing of Environment*, v. 240, 111604, 2020. DOI: 10.1016/j.rse.2019.111604.

PREISENDORFER, R. W. Application of radiative transfer theory to light measurements in the sea. *Union of Geodesy and Geophysics Institute Monograph*, v. 10, p. 11–30, 1961.

RAMCHOUN, H.; YOUSSEF, G.; MOHAMED, E.; IDRISSE, J.; AMINE, M. Multilayer perceptron: Architecture optimization and training. *International Journal of Interactive Multimedia and Artificial Intelligence (IJIMAI)*, v. 4, n.1 2016. DOI: <http://doi.org/10.9781/ijimai.2016.415>

REYNOLDS, C. S.; IRISH, A. E. Modelling phytoplankton dynamics in lakes and reservoirs: the problem of in-situ growth rates. *Hydrobiologia*, v. 349, p. 5-17, 1997.

REZENDE, F. P.; BERGAMIN, G. T. *Implantação de piscicultura em viveiro escavados e tanques-rede*. 2013.

RIBEIRO, R. P. Construção de tanques. In: *Fundamentos da moderna aquicultura*. Canoas: ULBRA, p. 45-52, 2001

ROMÁN, A.; HEREDIA, S.; WINDLE, A. E.; TOVAR-SÁNCHEZ, A.; NAVARRO, G. Aprimorando técnicas de georreferenciamento e mosaico sobre superfícies aquáticas com imagens de veículos aéreos não tripulados (VANT) de alta resolução. *Remote Sensing*, v. 16, n. 2, p. 290, 2024.

ROMÁN, A.; TOVAR-SÁNCHEZ, A.; GAUCI, A.; DEIDUN, A.; CABALLERO, I.; COLICA, E.; NAVARRO, G. Water-quality monitoring with a UAV-mounted multispectral camera in coastal waters. *Remote Sensing*, v. 15, n. 1, p. 237, 2022.

ROTTA, L. H. S.; IMAI, N. I.; BOSCHI, L. S.; BATISTA, L. F. A. Detecção de macrófitas submersas por meio de imagem QuickBird - Estudo de caso: Usina Hidrelétrica de Porto Colômbia MG/SP. In: *Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR*, Curitiba, PR, Brasil, 30 abril a 05 de maio, INPE, p. 4460, 2011.

RUDORFF, C. M. *Estudo da composição das águas da planície amazônica por meio de dados de reflectância do sensor Hyperion/EO-1 e de espectrorradiômetro de campo*

visando à compreensão da variação temporal dos seus constituintes opticamente ativos. 2006. 140 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning representations by back-propagating errors. *Nature*, v. 323, n. 6088, p. 533–536, 1986.

RUNDQUIST, D. C.; HAN, L. H.; SCHALLES, J. F.; PEAKE, J. S. Remote measurement of algal chlorophyll in surface waters: the case for the first derivative of reflectance near 690 nm. *Photogrammetric Engineering and Remote Sensing*, v. 62, n. 2, p. 195-200, 1996.

SAGAN, V.; PETERSON, K. Y.; MAIMAITIJANG, M.; SIDIKE, P.; SLOAN, J.; GREELING, B. A.; MAALOUF, S.; ADAMS, C. Monitoring inland water quality using remote sensing: Potential and limitations of spectral indices, bio-optical simulations, machine learning, and cloud computing. *Earth-Science Reviews*, v. 205, p. 103187, 2020. DOI: 10.1016/j.earscirev.2020.103187

SALANDRA, M. L.; MINIELLO, G.; NICOTRI, S.; ITALIANO, A.; DONVITO, G.; MAGGI, G.; DELLINO, P.; CAPOLONGO, D. Generating UAV high-resolution topographic data within a FOSS photogrammetric workflow using high-performance computing clusters. *International Journal of Applied Earth Observation and Geoinformation*, v. 105, p. 102600, 2021. DOI: 10.1016/j.jag.2021.102600.

SANTOS, R. L. *O uso de praguicidas nas atividades aquícolas: destino e efeitos após aplicações em tanques experimentais e avaliação nas pisciculturas e pesqueiros da bacia do rio Mogi-Guaçu*. 2007. Tese de Doutorado. Universidade de São Paulo.

SANTOS, V.; GUIMARÃES, B.; NETO, I.; SOUZA FILHO, F.; ROCHA, P.; THÉ, J.; GHARABAGHI, B. Chlorophyll-a estimation in 149 tropical semi-arid reservoirs using remote sensing data and six machine learning methods. *Remote Sensing*, v. 16, n. 11, p. 1870, 2024. DOI: 10.3390/rs16111870.

SATHYENDRANATH, S. Remote Sensing of Ocean Colour in Coastal, and other Optically-Complex, Waters. *International Ocean-Colour Coordinating Group*, v. 3, p. 17-18, 2000.

SHI, K.; ZHANG, Y.; ZHOU, Y.; LIU, X.; ZHU, G.; QIN, B.; GAO, G. Long-term MODIS observations of cyanobacterial dynamics in Lake Taihu: Responses to nutrient enrichment and meteorological factors. *Scientific Reports*, v. 7, p. 40326, 2017. DOI: 10.1038/srep40326.

SINGH, R.; SARITHA, V.; PANDE, C. B. Monitoring of wetland turbidity using multi-temporal Landsat-8 and Landsat-9 satellite imagery in the Bisalpur wetland, Rajasthan, India. *Environmental Research*, v. 241, 2024. ISSN 0013-9351. DOI: 10.1016/j.envres.2023.117638.

SILVA, B. C.; DELLA-GIUSTINA, E. G.; MASSAGO, H.; MARCHIORI, N. C.; GARCIA, S. Monocultivo de tilápia em viveiros escavados em Santa Catarina. *Sistemas de Produção*. n. 52, p.126, 2020.

SMITH, G. M.; MILTON, E. J. The use of the empirical line method to calibrate remotely sensed data to reflectance. *International Journal of remote sensing*, v. 20, n. 13, p. 2653-2662, 1999. DOI: 10.1080/014311699211994

SMITH, V. H.; SORANNO, P. A.; ELLIOTT, C.; GEORGE, L.; DOWNING, J. A.; PARSONS, R.; YODER, J. A. Eutrophication: impacts of excess nutrient inputs on freshwater, marine, and terrestrial ecosystems. *Environmental Science & Technology*, v. 23, n. 5, p. 423-433, 1999.

SONG, F.; ZHANG, W.; YUAN, T.; JI, Z.; CAO, Z.; XU, B.; LU, L.; ZOU, S. UAV quantitative remote sensing of riparian zone vegetation for river and lake health assessment: a review. *Remote Sensing*, v. 16, n. 19, p. 3560, 2024. DOI: 10.3390/rs16193560.

STAVN, R. H.; WEIDEMANN, A. D. Shape factors, two-flow models, and the problem of irradiance inversion in estimating optical parameters. *Limnological Oceanography*, v. 34, n. 8, p. 1426-1441, 1989.

SU, H.; LU, X.; CHEN, Z.; ZHANG, H.; LU, W.; WU, W. Estimating coastal chlorophyll-a concentration from time-series OLCI data based on machine learning. *Remote Sensing*, v. 13, n. 4, p. 576, 2021. DOI: 10.3390/rs13040576

TA, N.; CHANG, Q.; ZHANG, Y. Estimation of Apple Tree Leaf Chlorophyll Content Based on Machine Learning Methods. *Remote Sensing*, v. 13, n. 9, 3902, 2021. DOI: 10.3390/rs13193902

TAN, K.; SUN, M.; SUN, D.; LIU, X.; LIU, X.; WANG, B.; DOU, W.; ZHANG, H.; LUN, F. Mapping of nearshore bathymetry using Gaofen-6 images for the Yellow River Delta-Laizhou Bay, China. *Ecological Informatics*, v. 80, 2024. ISSN 1574-9541. DOI: 10.1016/j.ecoinf.2024.102497.

TOPP, S. N.; PAVELSKY, T. M.; JENSEN, D.; SIMARD, M.; ROSS, M. R. V. Research trends in the use of remote sensing for inland water quality science: moving towards multidisciplinary applications. *Water*, v. 12, p. 169, 2020. DOI: 10.3390/w12010169.

USHARAMI, S.; KUNGUMARAJ, K. A Survey on Data Mining with Big data Applications, Techniques, Tools, Challenges and Visualization. *International Journal of Advanced Research in Computer and Communication Engineering*, v. 4, pp. 102, 2015.

VIANA, C. R. S.; BARBOSA, A. P. D.; OLIVEIRA, E. S.; MUNIZ, C. C.; FILHO, M. S. Peixes associados à formação de *Ludwigia sedoides* (Humb. & Bonpl.) H.Hara e *Salvinia auriculata* Aubl. rio Paraguai, Pantanal Norte. *Revista de Ciências Agro-Ambientais*, v. 18, n. 1, p. 50-54, 2021. DOI: 10.5327/rcaa.v18i1.4550.

WANG, C.; MYINT, S. A simplified empirical line method of radiometric calibration for small unmanned aircraft systems-based remote sensing. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 8, p. 1876-1885, 2015.

WANG, J.; CHEN, X. A new approach to quantify chlorophyll-a over inland water targets based on multi-source remote sensing data. *Science of The Total Environment*, v. 906, 2024. DOI: 10.1016/j.scitotenv.2023.167631.

WASEHUN, E. T.; HASHEMI B. L.; DI VITTORIO, C. A. UAV and satellite remote sensing for inland water quality assessments: a literature review. *Environmental Monitoring and Assessment*, v. 196, n. 3, p. 277, 2024.

WATANABE, F.; ALCÂNTARA, E.; BERNARDO, N.; ANDRADE, C.; GOMES, A. C.; CARMO, A.; RODRIGUES, T.; ROTTA, L. H. Mapping the chlorophyll-a horizontal gradient in a cascading reservoirs system using MSI Sentinel-2A images. *Advances in Space Research*, v. 64, n. 3, p. 581-590, 2019. DOI: 10.1016/j.asr.2019.04.035.

WEN, Z.; ZHANG, C. E.; SHAO, G.; WU, S.; ATKINSON, P. M. Ensembles of multiple spectral water indices for improving surface water classification. *International Journal of Applied Earth Observation and Geoinformation*, v. 96, p. 102278, 2021. DOI: 10.1016/j.jag.2020.102278.

WETZEL, Robert G. *Limnology: Lake and River Ecosystems*. 3. ed. San Diego: Academic Press, 2001.

YAN, Y.; WANG, Y.; YU, C.; ZHANG, Z. Multispectral Remote Sensing for Estimating Water Quality Parameters: A Comparative Study of Inversion Methods Using Unmanned Aerial Vehicles (UAVs). *Sustainability*, v. 15, n. 13, p. 10298, 2023. DOI: 10.3390/su151310298.

XIAO, Y.; CHEN, J.; XU, Y.; GUO, S.; NIE, X.; GUO, Y.; LI, X.; HAO, F.; FU, Y. H. Monitoring of chlorophyll-a and suspended sediment concentrations in optically complex inland rivers using multisource remote sensing measurements. *Ecological Indicators*, v. 155, 2023. ISSN 1470-160X. DOI: 10.1016/j.ecolind.2023.111041.

YANG, W.; MATSUSHITA, B.; CHEN, J.; FUKUSHIMA, T.; MA, R. An Enhanced Three-Band Index for Estimating Chlorophyll-a in Turbid Case-II Waters: Case Studies of Lake Kasumigaura, Japan, and Lake Dianchi, China. *IEEE Geoscience and Remote Sensing Letters*, v. 7, n. 4, p. 655-659, 2010. DOI: 10.1109/LGRS.2010.2044364.

ZHANG, C.; ZOU, Z.; WANG, Z.; WANG, J. Ensemble deep learning modeling for Chlorophyll-a concentration prediction based on two-layer decomposition and attention mechanisms. *Acta Geophysica*, v. 72, n. 5, p. 3447-3471, 2024.

ZHANG, H.; YAO, B.; WANG, S.; WANG, G. Remote sensing estimation of the concentration and sources of coloured dissolved organic matter based on MODIS: A case study of Erhai lake. *Ecological Indicators*, v. 131, p. 108180, 2021. DOI: 10.1016/j.ecolind.2021.108180

ZHANG, S.; YINGLAN, A.; WANG, L.; WANG, Y.; ZHANG, X.; ZHU, Y.; MA, G. Monitoramento de baixa concentração de Chl-a no lago Hulun com base na fusão de dados de satélite de sensoriamento remoto e observação terrestre. *Remote Sensing*, v. 16, p. 1811, 2024. DOI: 10.3390/rs16101811.

ZHANG, Y.; HALLIKAINEN, M.; ZHANG, H.; DUAN, H.; LI, Y.; SAN LIANG, X. Chlorophyll-a estimation in turbid waters using combined SAR Data with hyperspectral reflectance Data: A case study in Lake Taihu, China. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 11, n. 4, p. 1325-1336, 2018. DOI: 10.1109/JSTARS.2017.2789247.

ZHU, W.; YU, W.; TIAN, Y. Q.; BECKER, B. L.; CARRICK, H. Issues and potential improvement of multiband models for remotely estimating chlorophyll-a in complex inland waters. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 8, n. 2, p. 562-575, 2014. DOI: 10.1109/JSTARS.2014.2360872

ZIBORDI, G.; MÉLIN, F.; VOSS, K. J.; JOHNSON, B. C.; FRANZ, B. A.; KWIATKOWSKA, E.; HUOT, J.; WANG, M.; ANTOINE, D. System vicarious calibration for ocean color climate change applications: Requirements for *in situ* data. *Remote Sensing of Environment*, v. 159, p. 361-369, 2015.

APÊNDICE

Tabela 1A - Tabela com os experimentos para a seleção dos atributos de entradas para a construção dos modelos bio-ópticos, em que estão dispostos, o número de amostras utilizadas, qual o modelo aplicado, o valor do *k-fold* e quatro métricas avaliativas.

Experimentos			Entrada			Métricas		
n°	Descrição	Amostras	Método	k-fold	R	MAE (µg/L)	RMSE (µg/L)	RAE (%)
1	Bandas	69	RF	10	0.21	15.44	19.50	96.52
2	Bandas	69	RF	69	0.26	15.41	19.05	96.29
3	Bandas	69	MLR	10	0.29	15.64	18.69	97.81
4	Bandas	69	MLR	69	0.23	15.96	19.02	99.75
5	Bandas	69	MLP	10	0.47	15.18	20.31	94.90
6	Bandas	69	MLP	69	0.64	13.11	16.14	81.95
7	Índices e algoritmos	69	RF	10	0.68	9.95	14.31	62.26
8	Índices e algoritmos	69	RF	69	0.70	9.59	14.01	59.93
9	Índices e algoritmos	69	MLR	10	0.57	11.13	17.49	69.64
10	Índices e algoritmos	69	MLR	69	0.54	12.43	18.04	77.71
11	Índices e algoritmos	69	MLP	10	0.39	19.01	25.82	118.83
12	Índices e algoritmos	69	MLP	69	0.35	20.31	30.08	126.92
13	Bandas e índices e algoritmos	69	RF	10	0.72	9.38	13.51	58.69
14	Bandas e índices e algoritmos	69	RF	69	0.70	9.69	13.92	60.55
15	Bandas e índices e algoritmos	69	MLR	10	0.49	13.03	19.52	81.48
16	Bandas e índices e algoritmos	69	MLR	69	0.34	14.40	26.64	90.00
17	Bandas e índices e algoritmos	69	MLP	10	0.49	16.27	21.88	101.74
18	Bandas e índices e algoritmos	69	MLP	69	erro	erro	erro	erro
19	I1	69	RF	10	0.15	17.33	22.00	108.37
20	I1	69	MLR	10	-0.34	15.99	19.66	100.00
21	I1	69	MLP	10	0.10	18.91	22.65	118.22
22	I2	69	RF	10	0.46	13.43	19.04	83.96
23	I2	69	MLR	10	0.16	15.94	23.12	99.67
24	I2	69	MLP	10	0.45	15.21	18.83	95.09
25	I3	69	RF	10	-0.14	18.95	25.92	118.51
26	I3	69	MLR	10	0.05	15.92	19.58	99.52
27	I3	69	MLP	10	0.12	18.77	22.46	117.38
28	I4	69	RF	10	0.50	12.69	18.25	79.35
29	I4	69	MLR	69	0.12	16.78	26.37	104.88

30	I4	69	MLP	69	0.50	14.61	18.26	91.34
31	I5	69	RF	69	0.53	12.85	17.90	80.29
32	I5	69	MLR	10	0.06	19.34	41.03	120.92
33	I5	69	MLP	10	0.36	16.26	20.11	101.66
34	I6	69	RF	10	0.46	13.42	19.04	83.95
35	I6	69	MLR	10	0.09	17.45	29.49	109.10
36	I6	69	MLP	10	0.39	16.01	19.53	100.12
37	I7	69	RF	10	-0.14	18.95	25.92	118.51
38	I7	69	MLR	10	0.05	15.92	19.58	99.52
39	I7	69	MLP	10	0.12	18.77	22.46	117.38
40	I8	69	RF	10	0.46	13.42	19.04	83.93
41	I8	69	MLR	10	0.33	14.60	18.98	91.28
42	I8	69	MLP	10	0.50	14.32	18.31	89.55
43	I9	69	RF	10	0.46	13.42	19.04	83.93
44	I9	69	MLR	10	0.15	16.06	23.36	100.41
45	I9	69	MLP	10	0.44	15.27	18.90	95.48
46	I10	69	RF	10	0.50	12.69	18.25	79.35
47	I10	69	MLR	10	0.14	16.40	25.89	102.53
48	I10	69	MLP	10	0.46	15.11	19.29	94.47
49	I11	69	RF	10	-0.01	17.85	23.68	111.64
50	I11	69	MLR	10	-0.34	15.99	19.66	100.00
51	I11	69	MLP	10	0.09	18.90	22.87	118.19
52	I12	69	RF	10	-0.05	19.92	23.66	124.56
53	I12	69	MLR	10	-0.34	15.99	19.66	100.00
54	I12	69	MLP	10	0.04	19.31	23.61	119.54
55	I13	69	RF	10	-0.14	18.94	25.92	118.43
56	I13	69	MLR	10	0.06	15.81	19.57	94.00
57	I13	69	MLP	10	0.14	18.40	22.16	115.04
58	I14	69	RF	10	0.41	14.36	19.17	89.83
59	I14	69	MLR	10	0.53	13.45	16.47	84.08
60	I14	69	MLP	10	0.47	15.29	18.71	95.64
61	I15	69	RF	10	0.44	13.66	18.54	85.44
62	I15	69	MLR	10	0.49	13.73	16.86	85.88
63	I15	69	MLP	10	0.44	15.72	19.32	98.30
64	I16	69	RF	10	0.65	10.72	15.22	67.02
65	I16	69	MLR	10	0.50	12.14	17.45	75.91
66	I16	69	MLP	10	0.60	12.90	17.17	80.68
67	Bandas (exc. 1 e 14)	69	RF	10	0.22	15.35	19.44	95.98
68	Bandas (exc. 1 e 14)	69	RF	69	0.24	15.48	19.30	96.73
69	Bandas (exc. 1 e 14)	69	MLR	10	0.32	15.33	18.42	95.85
70	Bandas (exc. 1 e 14)	69	MLR	69	0.26	15.50	18.97	97.00
71	Bandas (exc. 1 e 14)	69	MLP	10	0.54	15.07	19.57	94.24

72	Bandas (exc. 1 e 14)	69	MLP	69	0.63	13.46	16.79	84.14
73	I4 I5 I8 I10 I14 I16	69	RF	69	0.70	9.82	13.95	61.36
74	I4 I5 I8 I10 I14 I16	69	MLR	10	0.70	10.82	13.89	67.69
75	I4 I5 I8 I10 I14 I16	69	MLP	10	0.70	10.82	14.59	67.64
76	Bandas (exc. 1, 2 e 14)	69	RF	69	0.26	15.23	19.089	95.22
77	Bandas (exc. 1, 2 e 14)	69	MLR	10	0.23	15.98	19.11	99.91
78	Bandas (exc. 1, 2 e 14)	69	MLP	69	0.64	13.26	16.81	82.91
79	I4 I5 I8 I10 I14 I16 e bandas (exc. 1, 2 e 14)	69	RF	69	0.69	9.93	14.14	62.07
80	I4 I5 I8 I10 I14 I16 e bandas (exc. 1, 2 e 14)	69	MLR	10	0.66	11.11	14.56	69.45
81	I4 I5 I8 I10 I14 I16 e bandas (exc. 1, 2 e 14)	69	MLP	69	0.60	12.59	17.93	78.71
82	I5 I8 I10 I14 I16	69	RF	69	0.73	9.31	13.39	58.16
83	I5 I8 I10 I14 I16	69	MLR	10	0.75	8.91	13.05	55.74
84	I5 I8 I10 I14 I16	69	MLP	10	0.72	10.78	14.25	67.39
85	I5 I8 I16	69	RF	69	0.68	10.14	14.5	63.37
86	I5 I8 I16	69	MLR	69	0.32	13.2	39.39	82.54
87	I5 I8 I16	69	MLP	69	0.66	11.71	15.6	76.00
88	I5 I8 I10 I16	69	RF	69	0.68	10.35	14.63	64.70
89	I5 I8 I10 I16	69	MLR	69	0.49	11.04	23.07	69.00
90	I5 I8 I10 I16	69	MLP	10	0.57	13.16	18.79	82.28
91	I5 I8 I10 I16	69	RF	69	0.72	9.42	15.5	58.88
92	I5 I8 I10 I16	69	MLR	69	0.69	9.39	14.95	58.70
93	I5 I8 I10 I16	69	MLP	10	0.72	10.52	13.95	65.81
94	I8 I14 I16	69	RF	69	0.74	9.19	13.15	54.47
95	I8 I14 I16	69	MLR	10	0.61	11.2	15.82	70.04
96	I8 I14 I16	69	MLP	10	0.71	10.73	14.59	67.12
97	I8 I16	69	RF	69	0.71	9.95	13.82	62.21
98	I8 I16	69	MLR	10	0.52	12.21	17.37	75.76
99	I8 I16	69	MLP	69	0.63	12.09	15.89	75.59
100	I5 I8 I10 I14 I16 e bandas: 10, 11, 12 e 13	69	RF	69	0.70	9.85	14.04	61.59
101	I5 I8 I10 I14 I16 e bandas: 10, 11, 12 e 13	69	MLR	10	0.75	8.69	13.04	54.34
102	I5 I8 I10 I14 I16 e bandas: 10, 11, 12 e 13	69	MLP	10	0.65	11.7	16.47	73.15

103	I5 I8 I14 I16 e bandas: 10, 11, 12 e 13	69	RF	69	0.70	9.74	13.97	60.91
104	I5 I8 I14 I16 e bandas: 10, 11, 12 e 13	69	MLR	10	0.71	9.21	14.33	57.58
105	I5 I8 I14 I16 e bandas: 10, 11, 12 e 13	69	MLP	69	0.69	11.33	15.46	70.84
106	I8 I14 I16 e bandas: 10, 11, 12 e 13	69	RF	69	0.72	9.24	13.54	57.79
107	I8 I14 I16 e bandas: 10, 11, 12 e 13	69	MLR	10	0.62	10.43	15.92	65.22
108	I8 I14 I16 e bandas: 10, 11, 12 e 13	69	MLP	10	0.68	11.56	15.18	72.29
109	I13 I14 I15 I16	69	RF	10	0.67	9.75	14.53	60.96
110	I13 I14 I15 I16	69	MLR	69	0.12	16.21	28.89	101.34
111	I13 I14 I15 I16	69	MLP	69	0.57	13.25	16.85	82.85
112	I5 I8 I10 I14 I16	67	RF	10	0.73	9.47	13.65	57.43
113	I5 I8 I10 I14 I16	67	MLR	67	0.68	9.73	15.44	59.33
114	I5 I8 I10 I14 I16	67	MLP	67	0.77	9.66	12.82	58.93
115	I5 I8 I14 I16	67	RF	67	0.73	9.54	13.54	58.20
116	I5 I8 I14 I16	67	MLR	67	0.68	9.73	15.44	59.33
117	I5 I8 I14 I16	67	MLP	10	0.71	10.64	14.35	64.50
118	I8 I14 I16	67	RF	10	0.69	10.52	14.65	63.78
119	I8 I14 I16	67	MLR	67	0.40	12.2	30.45	74.43
120	I8 I14 I16	67	MLP	67	0.73	10.83	13.71	66.05
121	I5 I8 I10 I14 I16 e bandas: 10, 11, 12 e 13	67	RF	67	0.71	9.78	14.06	59.68
122	I5 I8 I10 I14 I16 e bandas: 10, 11, 12 e 13	67	MLR	67	0.57	11.51	18.57	70.20
123	I5 I8 I10 I14 I16 e bandas: 10, 11, 12 e 13	67	MLP	10	0.64	12.81	17.26	77.63
124	I5 I8 I10 I14 I16	65	RF	65	0.74	9.28	13.37	56.86
125	I5 I8 I10 I14 I16	65	MLR	65	0.54	10.57	21.07	65.29
126	I5 I8 I10 I14 I16	65	MLP	65	0.73	10.16	13.83	62.24
127	I8 I14 I16	65	RF	10	0.77	8.66	12.45	53.03
128	I8 I14 I16	65	MLR	10	0.58	11.51	16.64	70.49
129	I8 I14 I16	65	MLP	10	0.72	10.53	13.74	64.50
130	I8 I14 I16 e bandas: 10, 11, 12 e 13	69	RF	10	0.73	9.52	13.53	58.30
131	I8 I14 I16 e bandas: 10, 11, 12 e 13	69	MLR	65	0.62	10.92	16.15	67.47

132	I8 I14 I16 e bandas: 10, 11, 12 e 13	69	MLP	10	0.64	12.22	16.52	74.86
-----	--	----	-----	----	------	-------	-------	-------

*exc: exceto.

DADOS CURRICULARES

IDENTIFICAÇÃO	
Data de Nascimento	15 de julho de 1998
Nacionalidade	Brasileira
Nome em citações bibliográficas	Lucchetta, Beatriz Cirino Lucchetta, B.
Currículo Lattes	6396591316923368
ORCID	0000-0002-7987-0927
Outro identificador	https://www.webofscience.com/wos/author/record/KIE-9664-2024
FORMAÇÃO ACADÊMICA	
2016-2021	Graduação (Engenharia Ambiental) Faculdade de Ciências e Tecnologia – FCT, Universidade Estadual Paulista – Unesp
2021-2024	Mestrado Acadêmico (Programa de Pós-Graduação em Ciências Cartográficas - PPGCC) Faculdade de Ciências e Tecnologia – FCT, Universidade Estadual Paulista – Unesp
2023 - Atual	Doutorado Acadêmico (Programa de Pós-Graduação em Ciências Cartográficas - PPGCC) Faculdade de Ciências e Tecnologia – FCT, Universidade Estadual Paulista – Unesp
PRODUÇÃO BIBLIOGRÁFICA	
LUCCHETTA, BEATRIZ CIRINO; WATANABE, FERNANDA SAYURI YOSHINO; OLIVEIRA, FERNANDA SILVA. Evaluation of OLI Landsat-8 images based on spectral indices in detecting areas affected by mining tailings mud: a case study of the Brumadinho dam rupture, Brazil. Boletim De Ciências Geodésicas (IMPRESSO), v. 30, p. 1982-2170, 2024. LUCCHETTA, BEATRIZ CIRINO; WATANABE, FERNANDA SAYURI YOSHINO; BERNARDO, NARIANE MARSELHE RIBEIRO; FIALHO, RAFAEL DE CAMPOS; IMAI, NILTON NOBUHIRO; TOMMASELLI, ANTONIO MARIA GARCIA; RONCOLATO, GUSTAVO SOARES. An Empirical Line approach for Agrowing Camera Aerial Images of inland waters based on exponential fit and in situ water measurements. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, v. X-3-2024, p. 215-222, 2024. LUCCHETTA, BEATRIZ CIRINO; WATANABE, FERNANDA SAYURI YOSHINO; DO CARMO, NARIANE MARSELHE RIBEIRO BERNARDO. A spatiotemporal classification approach to evaluate the impacts of land use and land cover changes before and after the Três Irmãos reservoir formation in the Tietê River, Brazil. Modeling Earth Systems and Environment, v. 9, p. 0000, 2023. LUCCHETTA, B. C.; WATANABE, F. S. Y. Avaliação de índices espectrais na detecção de áreas atingidas por lama de rejeitos de mineração: estudo de caso da Barragem da Mina do Córrego do Feijão, Brumadinho/MG. In: XII Colóquio Brasileiro de Ciências Geodésicas e V Simpósio Brasileiro de Geomática, 2022, Curitiba/PR. Informações Geoespaciais Sistema Terra Para O Monitoramento Do Visando O Desenvolvimento Sustentável, 2022.	

LUCCHETTA, B. C.; WATANABE, F. S. Y. Classificação da cobertura da terra na bacia do reservatório da hidrelétrica de Três Irmãos, Rio Tietê, SP. In: XXXI Congresso de Iniciação Científica da UNESP, 2019, Presidente Prudente. Anais do XXXI Congresso de Iniciação Científica da UNESP , 2019.
PARTICIPAÇÃO EM BANCAS E ORIENTAÇÕES
Banca de trabalhos de conclusão
SÁ, I. M.; RAMOS, A. P. M.; FURUYA, D. E. G; LUCCHETTA, B. C. Participação em banca de Isabelly Martins Sá. Mapeamento Arbóreo Urbano a partir de Imagens de Sensoriamento Remoto usando Aprendizagem de Máquina . 2024. Trabalho de Conclusão de Curso (Engenharia Ambiental) - Faculdade de Ciências e Tecnologia – FCT, Universidade Estadual Paulista – Unesp, Presidente Prudente, 2024.
Orientações
ORTIZ, R. B. Estimação da Turbidez em Águas Interiores por meio de Imagens Sentinel-2 . 2023. Orientadora: Dra. Fernanda Sayuri Yoshino Watanabe. Co-orientadoras: Dra Nariane Marselhe Ribeiro Bernardo do Carmo e Msc Beatriz Cirino Lucchetta. Trabalho de Conclusão de Curso (Graduação em Engenharia Ambiental) - Faculdade de Ciências e Tecnologia – FCT, Universidade Estadual Paulista – Unesp
PARTICIPAÇÃO EM EVENTOS CIENTÍFICOS
1ª fase do XXXVI Congresso de Iniciação Científica da Unesp - FCT/Presidente Prudente. Qualidade de AVALIADOR da(s) área(s) Ciências Exatas e da Terra e Engenharias. 2024. (Congresso).
ISPRS Technical Commission III Mid-term Symposium on Remote Sensing. An Empirical Line approach for Agrowing Camera Aerial Images of inland waters based on exponential fit and in situ water measurements. 2024. (Simpósio).
1ª fase do XXXV Congresso de Iniciação Científica da Unesp - FCT/Presidente Prudente. Qualidade de AVALIADOR da(s) área(s) Ciências Exatas e da Terra. 2023. (Congresso).
XX Simpósio Brasileiro de Sensoriamento Remoto. Análise preliminar das bandas da câmera Agrowing na modelagem do conteúdo de clorofila-a em um sistema de aquicultura. 2023. (Simpósio).
XII Colóquio Brasileiro de Ciências Geodésicas e V Simpósio Brasileiro de Geomática. Avaliação de índices espectrais na detecção de áreas atingidas por lama de rejeitos de mineração: estudo de caso da Barragem da Mina do Córrego do Feijão, Brumadinho/MG. 2022. (Simpósio).
III SAEC - Geotecnologias: Informando e Conectando o Mundo. 2021. (Simpósio).
XV Simpósio de Engenharia Ambiental da Unesp de Presidente Prudente. 2020. (Simpósio).
XXXI Congresso de Iniciação Científica da Unesp. Classificação da cobertura da terra na bacia do reservatório da hidrelétrica de Três Irmãos, Rio Tietê, SP. 2019. (Congresso).