

**UNIVERSIDADE FEDERAL DE PELOTAS**  
**Centro de Desenvolvimento Tecnológico**  
**Programa de Pós-Graduação em Recursos Hídricos**



**Dissertação**

**Modelagem orbital e monitoramento remoto de clorofila, sólidos suspensos e  
densidade celular de *Ceratium* na Barragem Santa Bárbara, Pelotas, RS**

**Daniele Martin Sampaio**

**Pelotas, 2023**

**Daniele Martin Sampaio**

**Modelagem orbital e monitoramento remoto de clorofila, sólidos suspensos e densidade celular de *Ceratium* na Barragem Santa Bárbara, Pelotas, RS**

Dissertação apresentada ao Programa de Pós-Graduação em Recursos Hídricos, do Centro de Desenvolvimento Tecnológico da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Recursos Hídricos.

Orientador: Hugo Alexandre Soares Guedes

Pelotas, 2023

Universidade Federal de Pelotas / Sistema de Bibliotecas  
Catalogação na Publicação

S192m Sampaio, Daniele Martin

Modelagem orbital e monitoramento remoto de clorofila, sólidos suspensos e densidade celular de *Ceratium* na Barragem Santa Bárbara, Pelotas, RS / Daniele Martin Sampaio ; Hugo Alexandre Soares Guedes, orientador. — Pelotas, 2023.

90 f. : il.

Dissertação (Mestrado) — Programa de Pós-Graduação em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, 2023.

1. Florações. 2. Google Earth Engine. 3. Sensoriamento remoto. 4. Sentinel-2. 5. Espectroscopia de imageamento. I. Guedes, Hugo Alexandre Soares, orient. II. Título.

CDD : 627

Daniele Martin Sampaio

Modelagem orbital e monitoramento remoto de clorofila, sólidos suspensos e densidade celular de *Ceratium* na Barragem Santa Bárbara, Pelotas, RS

Dissertação aprovada, como requisito parcial, para obtenção do grau de Mestre/Doutor em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas.

Data da Defesa: 10 de fevereiro de 2023

Banca Examinadora:

Prof. Dr. Hugo Alexandre Soares Guedes (Orientador)  
Doutor em Engenharia Agrícola pela Universidade Federal de Viçosa

Prof. Dr. André Pereira Rosa  
Doutor em Saneamento, Meio Ambiente e Recursos Hídricos pela Universidade Federal de Minas Gerais

Prof. Dr. Fabrício da Silva Terra  
Doutor em Ciências (Solos e Nutrição de Plantas) pela Universidade de São Paulo

## **Agradecimentos**

À Deus, por sempre me guiar, me dar força e coragem para caminhar com fé, esperança e amor, principalmente nos momentos nos quais pensei em desistir.

Aos meus pais, por todo carinho e confiança durante todo período acadêmico, sempre entendendo meus momentos de ausência; e ao meu irmão, Felipe, pelo grande exemplo que é em minha vida, o qual me fez chegar até aqui hoje.

Ao Hitalo Geiger, que durante os dois anos de mestrado foi namorado, noivo e, por final, marido. Por todo amor, cumplicidade e paciência, por não medir esforços para fazer tudo acontecer, me dando suporte e apoio enquanto eu me dividia entre as tarefas da casa, do casamento, do trabalho e da pesquisa.

Aos meus grandes amigos e amados padrinhos, que foram meu ombro amigo e meu porto seguro, por todas as longas conversas, desabafos, choros e incentivos. Para vocês, a minha eterna amizade.

Ao meu querido orientador Hugo Alexandre Soares Guedes, pelas valiosas orientações que transcenderam o profissional, pelos ensinamentos e por todo apoio durante esse trajeto, o meu mais sincero respeito e admiração.

À minha colega Mirelle Tainá Vieira Lima que, mesmo do outro lado do país, sempre foi um apoio, compartilhando comigo todas angústias e conquistas durante esse período, todo meu carinho e admiração pela mulher que é.

Às minhas grandes amigas Karen Gularte Peres Mendes e Letícia Vianna do Nascimento, que foram essenciais no desenvolvimento dessa pesquisa, por toda ajuda, por todo companheirismo e por todo carinho, a minha eterna gratidão.

Ao SANEP e aos colegas envolvidos nesta pesquisa, que me proporcionaram executá-la, apesar de algumas dificuldades. Meus sinceros agradecimentos, em especial, ao laboratório de Hidrobiologia da autarquia e àqueles que colocaram a “mão na massa” junto comigo e por mim, por todo envolvimento, colaboração e auxílio nas (desastrosas) saídas de barco – sem vocês, nada teria acontecido.

À Universidade Federal de Pelotas, por oferecer um ensino público, gratuito e de altíssima qualidade, mesmo com os desafios enfrentados nos últimos anos; e ao Programa de Pós-Graduação em Recursos Hídricos pela equipe de professores altamente qualificados, com os quais aprendi lições além de sala de aula durante esse período.

*Eu errei mais de 9.000 arremessos na minha carreira. Perdi quase 300 jogos. Em 26 oportunidades, confiaram em mim para fazer o arremesso da vitória e eu errei. Eu falhei muitas e muitas vezes na minha vida. E é por isso que tenho sucesso.*

**Michael Jordan**

## Resumo

SAMPAIO, Daniele. **Modelagem orbital e monitoramento remoto de clorofila, sólidos suspensos e densidade celular de *Ceratium* na Barragem Santa Bárbara, Pelotas, RS**. 2023. 90f. Dissertação (Mestrado em Recursos Hídricos) - Programa de Pós-Graduação em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas, 2023.

A clorofila-a (Chl-a), os sólidos suspensos totais (SST) e a densidade celular de organismos como os do gênero *Ceratium* são importantes indicadores da qualidade de água de reservatórios. O monitoramento contínuo dessa qualidade é essencial e o sensoriamento remoto surge como uma alternativa para o monitoramento desses indicadores, já que os métodos convencionais existentes (amostragens *in loco*) são limitados pelo tempo e pelo espaço. Assim, o principal objetivo dessa pesquisa foi desenvolver modelos empíricos para as concentrações de Chl-a, SST e *Ceratium*, gerando regressões lineares múltiplas entre dados espectrais de imagens do Sentinel-2, obtidos diretamente da plataforma *Google Earth Engine*, e análises de amostras, coletadas *in situ*, da Barragem Santa Bárbara, em Pelotas/RS. Um conjunto de 10 bandas espectrais, 8 razões de banda e 9 índices espectrais foi usado para gerar correlações com as análises *in loco*. Como resultado, as correlações mais fortes para Chl-a e SST foram obtidas com a Banda 5 e com as razões entre as bandas da região do vermelho e infravermelho próximo, sendo escolhidas como as variáveis independentes utilizadas nas regressões. A modelagem de *Ceratium* foi feita utilizando uma estratégia de modelo duplo, na qual uma regressão foi desenvolvida para a Chl-a usando a densidade celular de *Ceratium* como preditora ( $R^2=0,863$  e  $RMSE=61,1$ ) para ser combinado ao algoritmo previamente gerado. Os modelos bio-ópticos mais bem avaliados para Chl-a ( $R^2=0,64$ ,  $RMSE=122$ ) e para SST ( $R^2=0,61$  e  $RMSE=4,33$ ), e o modelo combinado de *Ceratium* ( $R^2=0,57$ ,  $RMSE=700$ ) foram usados para produzir mapas de distribuição espacial. Esses mapas, derivados do Sentinel-2, apresentaram um bom desempenho para teores altos de Chl-a e a densidade de *Ceratium*.

Palavras-chave: Florações. *Google Earth Engine*. Sensoriamento Remoto. Sentinel-2. Algas. Espectroscopia de Imageamento.

## Abstract

SAMPAIO, Daniele. **Orbital modeling and monitoring of chlorophyll, suspended solids and *Ceratium* cell density in Barragem Santa Bárbara, Pelotas, RS.** 2023. 90f. Dissertation (Master em Recursos Hídricos) - Programa de Pós-Graduação em Recursos Hídricos, Centro de Desenvolvimento Tecnológico, Universidade Federal de Pelotas, Pelotas, 2023.

Chlorophyll-a (Chl-a), total suspended solids (SST) and cell density of organisms such as *Ceratium* are important indicators of reservoir water quality. Their continued monitoring is essential and remote sensing emerges as an alternative for monitoring of these indicators since existing conventional methods (e.g., in situ monitoring) are limited in time and space. The main aim of this research was to develop empirical models for the concentrations of Chl-a, SST and *Ceratium*, by multiple linear regressions between spectral data of Sentinel-2 images, obtained directly from the Google Earth Engine platform, and analysis of samples collected in situ from the Barragem Santa Bárbara, Pelotas/RS. A combination of 10 spectral bands, 8 band ratios and 9 spectral indices was used to generate correlations within situ analyses. As a result, the strongest correlations for Chl-a and SST were obtained with Band 5 and with the ratios between the red and near infrared bands, being chosen as the independent variables used in the regressions. *Ceratium* modeling was performed using a dual-model strategy. A regression was developed for Chl-a using the cell density of *Ceratium* as a predictor ( $R^2=0.863$  and  $RMSE=61.1$ ) to be coupled with the previously generated algorithm. The bio-optical models best evaluated for Chl-a ( $R^2=0.64$ ,  $RMSE=122$ ) and For SST ( $R^2=0.61$  and  $RMSE=4.33$ ), and the combined *Ceratium* model ( $R^2=0.57$ ,  $RMSE=700$ ) were used to produce spatial distribution maps. The spatial distribution maps derived from Sentinel-2 performed well where Chl-a and *Ceratium* were relatively high.

Keywords: Bloom. *Google Earth Engine*. Remote Sensing. Sentinel-2. Algae. Imaging Spectroscopy.

## Lista de Figuras

Figura 1	Esquema simplificado do processo de eutrofização impulsionada pela ação sinérgica de fatores diretos e indiretos. ....	19
Figura 2	O espectro eletromagnético, com destaque da porção correspondente à luz visível.....	23
Figura 3	Os três principais domínios de informação do sensoriamento remoto: as resoluções de espectro, de tempo e de espaço. ....	24
Figura 4	Espectros de reflectância da água modelados para concentrações de clorofila-a de 0,1 mg m <sup>-3</sup> , 3 mg m <sup>-3</sup> , 30 mg m <sup>-3</sup> e 300 mg m <sup>-3</sup> , mostrando o pico em 685 nm para concentrações de Chl-a mais baixas e o pico na faixa de comprimento de onda 700-710 nm para concentrações de Chl-a a acima de 100 mg m <sup>-3</sup> .....	27
Figura 5	Espectros de reflectância da água modelados para concentrações de sólidos suspensos totais de 25 mg L <sup>-1</sup> , 76 mg L <sup>-1</sup> , 141 mg L <sup>-1</sup> , 237 mg L <sup>-1</sup> e 351 mg L <sup>-1</sup> . ....	29
Figura 6	Resolução espacial do MSI versus comprimento de onda: 13 bandas espectrais do Sentinel-2, do visível (VIS) e infravermelho próximo (NIR) até infravermelho de ondas curtas (SWIR) com diferentes resoluções espaciais, variando de 10m a 60m. ....	31
Figura 7	Ambiente de trabalho GEE ( <i>code editor</i> ) e código para obtenção de imagens Sentinel-2. (A) Mecanismo de pesquisa; (B) painel das funções pré-estabelecidas da API; (C) painel de programação para o usuário gerar seus <i>scripts</i> ; (D) console no qual são exibidos apenas os resultados; (E) painel de exibição no qual são mostrados os mapas gerados; (F) ferramentas de desenho para selecionar uma região de interesse através de um ponto, uma linha ou um polígono; (G) camadas ativas e inativas na visualização. ....	35
Figura 8	Esquema metodológico seguindo duas linhas concomitantemente – a obtenção de dados de campo e de sensoriamento remoto.....	37
Figura 9	Localização da Barragem Santa Bárbara – Pelotas (RS). ....	38
Figura 10	Uso e cobertura da Bacia Hidrográfica do Arroio Santa Bárbara. ....	40
Figura 11	Gráfico com os maiores índices de uso e cobertura da região da Bacia Hidrográfica do Arroio Santa Bárbara. ....	40
Figura 12	Localização das regiões estabelecidas para as coletas das amostras ..	42
Figura 13	(a) Frascos de amostragem (b) para análises de Chl-a e SST e (c) para a quantificação de fitoplâncton. ....	43

Figura 14	Etapas da análise de Chl-a: (a) filtração, (b) extração com acetona, (c) armazenamento dos extratos sem contato com a luz e (d) extrato a ser lido no espectrofotômetro. ....	44
Figura 15	(a) Etapa de filtração, (b) filtros utilizados e (c) resultado pós secagem na análise de SST. ....	45
Figura 16	(a) Análise de quantificação de organismos do gênero <i>Ceratium</i> , (b) aparelhagem utilizada e (c) amostras conservadas com lugol e adicionadas a câmara de Sedgwick-Rafter. ....	46
Figura 17	Organismos do gênero <i>Ceratium</i> identificados nas amostras coletadas na pesquisa. ....	47
Figura 18	<i>Boxplot</i> para os resultados de clorofila-a. ....	54
Figura 19	<i>Boxplot</i> para os resultados de sólidos suspensos totais. ....	54
Figura 20	Imagens do satélite Sentinel-2 na composição RGB (B4/B3/B2) e os pontos de coletas de cada uma das campanhas: (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022. ....	56
Figura 21	Correlogramas de Chl-a e SST com (a) as bandas Sentinel-2, (b) as razões de banda escolhidas e (c) os índices de água calculados (os valores nas células mostram coeficientes de correlação e as células riscadas indicam valores insignificantes no nível 0,05). ....	57
Figura 22	Índice NDCI elaborado a partir das imagens Sentinel-2 para as datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022. ....	58
Figura 23	Índice NDVI elaborado a partir das imagens Sentinel-2 para as datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022. ....	59
Figura 24	Índice de Toming elaborado a partir das imagens Sentinel-2 para as datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022. ....	59
Figura 25	Regressão linear entre a concentração de clorofila-a <i>in situ</i> e a concentração calculada na Barragem Santa Bárbara (pontos). A linha sólida é a linha 1:1 esperada. ....	61
Figura 26	Concentração <i>in situ</i> e prevista de Chl-a em cada local de amostragem na Barragem Santa Bárbara. ....	62
Figura 27	Mapa de distribuição espacial de Chl-a elaborado a partir do modelo gerado para a Barragem Santa Bárbara para as datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022. ....	63

Figura 28	Regressão linear entre a concentração de sólidos suspensos totais <i>in situ</i> e calculado na Barragem Santa Bárbara (pontos). A linha sólida é a linha 1:1 esperada. ....	65
Figura 29	Concentração <i>in situ</i> e prevista de SST em cada local de amostragem na Barragem Santa Bárbara. ....	65
Figura 30	Mapa de distribuição espacial de SST modelado para a Barragem Santa Bárbara aplicado nas imagens das datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022. ....	66
Figura 31	Gráfico de barras da densidade de células de <i>Ceratium</i> e outros gêneros de cianobactérias ( <i>Cyanophyceae</i> ) e variação de clorofila nos pontos amostrais. ....	67
Figura 32	Concentração <i>in situ</i> e prevista da densidade de <i>Ceratium</i> , em células mL <sup>-1</sup> , para cada local de amostragem na Barragem Santa Bárbara. ....	69
Figura 33	Mapa de distribuição espacial da densidade celular de <i>Ceratium</i> modelado para a Barragem Santa Bárbara nas datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022. ....	69

## Lista de Tabelas

Tabela 1	Parâmetros qualitativos da água mais comumente medidos por meio de sensoriamento remoto. ....	26
Tabela 2	Parâmetros morfológicos da Bacia Hidrográfica do Arroio Santa Bárbara, no município de Pelotas – RS. ....	39
Tabela 3	Referências de imagem do Sentinel-2, datas de coleta e imagem, diferença de dias e porcentagem de nuvens. Em negrito, as imagens utilizadas para obtenção dos dados espectrais. ....	49
Tabela 4	Detalhes dos índices espectrais calculados. ....	50
Tabela 5	Estatística descritiva dos teores de clorofila e sólidos suspensos totais da água para cada uma das sete campanhas de amostragem na Barragem Santa Bárbara e valores da temperatura do ar, temperatura da água e do nível do manancial para as respectivas datas de coleta. ....	53
Tabela 6	Valores médios, mínimos e máximos utilizados para elaboração dos modelos preditivos de clorofila-a e sólidos suspensos totais. ....	56
Tabela 7	Resultados das análises de regressão para clorofila. ....	60
Tabela 8	Resultados das análises de regressão para sólidos suspensos totais. ....	64
Tabela 9	Resultado da análise de regressão para modelagem da concentração de clorofila-a utilizando como variável independente a concentração de <i>Ceratium</i> . ....	68
Tabela 10	Resultado da análise de regressão para modelagem da concentração de <i>Ceratium</i> utilizando o modelo de clorofila previamente desenvolvido. ....	68

## Abreviaturas e Siglas

ESA	Agência Espacial Europeia
API	<i>Application Program Interface</i>
COD	Carbono Orgânico Dissolvido
COT	Carbono orgânico total
Chl-a	Clorofila-a
CV	Coeficiente de Variação
COAs	Componentes Opticamente Ativos
RGB	Composição cor verdadeira (Vermelho, Verde e Azul)
CE	Condutividade elétrica
DBO	Demanda Bioquímica de Oxigênio
DQO	Demanda Química de Oxigênio
ETA	Estação de Tratamento de Água
P	Fósforo
GEE	<i>Google Earth Engine</i>
SWIR	Infravermelho de ondas curtas
NIR	Infravermelho Próximo
CDOM	Matéria orgânica colorida
MERIS	<i>Medium Resolution Imaging Spectrometer</i>
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
MSI	<i>Multispectral Imager</i>
N	Nitrogênio
NH <sub>3</sub>	Nitrogênio Amoniacal
NDCI	<i>Normalized difference chlorophyll index</i>
NDWI	<i>Normalized Difference Water Index</i>
NDVI	<i>Normalized Differences Vegetation Index</i>
NSMI	<i>Normalized Suspended Material Index</i>
OLI	<i>Operational Land Imager</i>
PO <sub>4</sub>	Ortofosfato
SD	Profundidade do Disco de Secchi
REM	Radiações Eletromagnéticas
RMSE	Raiz do Erro Quadrático Médio
MLR	Regressões Lineares Múltiplas
SSS	Salinidade da Superfície do Mar
SR	Sensoriamento Remoto
SST	Sólidos Suspensos Totais
T	Temperatura
TUR	Turbidez
VIS	Visível

## Sumário

<b>1</b>	<b>Introdução</b>	13
<b>2</b>	<b>Objetivos</b>	16
2.1	Geral	16
2.2	Específicos	16
2.3	Hipóteses	17
<b>3</b>	<b>Referencial teórico</b>	18
3.1	Qualidade de água	18
3.1.1	Desafios do monitoramento da qualidade de água	21
3.2	Sensoriamento Remoto	22
3.2.1	Propriedades ópticas da água	24
3.2.2	Clorofila-a e organismos fitoplanctônicos	26
3.2.3	Sólidos em suspensão	28
3.2.4	Modelagem bio-óptica	29
3.2.5	Sentinel-2/MSI	31
3.3	Vantagens e desvantagens do monitoramento remoto da qualidade da água	32
3.4	<i>Google Earth Engine</i> e o processamento em nuvem	34
<b>4</b>	<b>Materiais e Métodos</b>	37
4.1	Caracterização da área de estudo – Barragem Santa Bárbara	38
4.2	Obtenção de dados de campo	41
4.3	Processamento de imagem e extração de dados espectrais	47
4.4	Integração de dados de campo e de sensoriamento remoto	51
<b>5</b>	<b>Resultados e Discussão</b>	53
5.1	Estatística descritiva da qualidade da água	53
5.2	Processamento de imagens e correlações	55
5.3	Modelagem bio-óptica	60
5.3.1	Modelagem de clorofila-a	60
5.3.2	Modelagem de sólidos suspensos totais	63
5.3.3	Modelagem da densidade celular de <i>Ceratium</i>	67
<b>6</b>	<b>Conclusões</b>	71
	<b>Referências</b>	72
	<b>Apêndices</b>	81

## 1 Introdução

Dentro de um sistema de captação e abastecimento, os usos antrópicos da água resultam na deterioração da sua qualidade. Isso afeta o ecossistema aquático e compromete o acesso à água potável para consumo humano (OUMA; NOOR; HERBERT, 2020).

Ambientes lênticos como reservatórios, principal recurso utilizado para o abastecimento urbano, são alvos fáceis para a eliminação de resíduos, gerando consequências que provavelmente se agravarão com o aquecimento global e as mudanças climáticas. Isso pode ser explicado usando as previsões para os anos subsequentes, as quais preveem um aumento de temperatura e padrões de chuva menos frequentes e mais intensos, o que permite períodos de secas, assoreamento e de imensa carga de nutrientes seguidos por períodos de estagnação prolongada das águas, auxiliando na expansão e persistência de poluentes (WEBER *et al.*, 2020). Para lidar com esse problema, há uma necessidade urgente de monitoramento desses recursos de modo abrangente, preciso, rápido e barato, para observar suas condições biológicas, físicas e químicas, e evitar danos graves (SABERIOON *et al.*, 2020).

Os métodos tradicionais de monitoramento dos reservatórios, através de coletas *in situ*, são muito trabalhosos, demorados, caros e é difícil obter uma visão geral das informações espaciais e temporais da qualidade, o que impede sua aplicação para o monitoramento oportuno em grande escala (SHI *et al.*, 2019). Considerando a importância da preservação dos recursos hídricos, e que os problemas de qualidade da água ganham cada vez mais escala global, cria-se a necessidade de um monitoramento constante e dinâmico desses ambientes, sendo necessária a utilização de tecnologias mais baratas e eficazes, automatizadas e não invasivas, com cobertura espaço-temporal adequada (MASOCHA *et al.*, 2018).

Devido às limitações das observações terrestres, a disponibilidade de produtos de sensoriamento remoto tem servido como uma fonte alternativa importante para pesquisadores e gestores de recursos hídricos. O sensoriamento remoto é um método econômico para visualizar corpos d'água com alta cobertura temporal e precisão razoável, o que fisicamente não é possível por meio de medições *in situ* (CHAWLA; KARTHIKEYAN; MISHRA, 2020).

Com o desenvolvimento dessa tecnologia, as imagens de satélite oferecem uma importante fonte de informação para o monitoramento de diferentes componentes opticamente ativos (COAs) na água (RITCHIE; ZIMBA; EVERITT, 2003). As assinaturas espectrais da água capturadas por sensores de sensoriamento remoto podem ser usadas para recuperar diferentes medidas da sua qualidade, como a matéria suspensa e o conteúdo de matéria orgânica colorida, a turbidez, a profundidade de Secchi e a concentração de clorofila-a (LIMA *et al.*, 2019; MULIA *et al.*, 2013; NECHAD; RUDDICK; PARK, 2010; POMPÊO *et al.*, 2021).

A série de satélites Sentinel-2 (S2-A e S2-B), em serviço com sensor MSI (*Multispectral Instrument*), por exemplo, geram imagens que apresentam uma resolução espacial de 10 m, 20 m e 60 m, o que significa que pequenos cursos de águas interiores podem ser estudados (DU *et al.*, 2016). Os dados são adquiridos em 13 bandas espectrais e a resolução radiométrica do sensor é de 12 bits, com tempo de revisita de 5 dias. Essas bandas de medição têm aplicações interessantes na estimativa de sólidos suspensos totais e da composição de algas e cianobactérias com base na medição de clorofila (BARRAZA-MORAGA *et al.*, 2022; KUHN *et al.*, 2019; MISHRA; MISHRA, 2012).

A clorofila (Chl-a) é o principal pigmento fotossintético que ocorre no fitoplâncton. Embora esses organismos sejam a base da cadeia alimentar aquática, seu excesso pode ser prejudicial. A ocorrência de florações (*bloom*) de fitoplâncton em muitos reservatórios do mundo tem sido observada, como gênero *Ceratium* do grupo *Dinophyta*. Apesar de atóxicos, esses organismos podem ser prejudiciais ao ambiente pelo esgotamento de recursos e redução do oxigênio (MATSUMURA-TUNDISI *et al.*, 2010) e ao processo de tratamento de água por prejudicar os processos de coagulação, floculação e sedimentação, além de provocar o entupimento dos filtros (EWERTS; SWANEPOEL; DU PREEZ, 2013).

Os sólidos suspensos totais (SST) incluem uma ampla variedade de material particulado para determinada coluna de água que contêm matéria orgânica e inorgânica e tem um impacto significativo nos aspectos espaciais e temporais das propriedades ópticas dos corpos d'água (MADSEN *et al.*, 2001).

A partir de dados de sensoriamento remoto, com o uso da reflectância da superfície das imagens de satélite, e com os dados das análises de água *in situ*, é possível gerar modelos empíricos, podendo ser utilizados para complementar as informações das análises da água. Embora popular, no uso de algoritmos empíricos,

grandes tamanhos de amostras de qualidade da água são necessários e os modelos são sensíveis às condições ambientais locais e, portanto, não são automaticamente replicáveis para outros estudos de caso ou regiões (OUMA; NOOR; HERBERT, 2020).

Assim, esta pesquisa contribui para uma base de conhecimento mais ampla e fornece novos *insights* sobre o monitoramento remoto da qualidade de água para o corpo d'água responsável pela maior parte do abastecimento urbano da cidade de Pelotas – a Barragem Santa Bárbara. Esse reservatório é uma importante obra de engenharia localizada na cidade de Pelotas, no estado do Rio Grande do Sul. Inaugurada em 1967, ela desempenha múltiplas funções: além de ser uma atração turística, ela tem um papel fundamental na garantia da distribuição de água para a população da região. Segundo dados da autarquia (SANEP, 2021), o reservatório possui um volume de água estimado de 10 bilhões de litros e tem como finalidade fornecer água bruta por gravidade para a planta de tratamento da Estação de Tratamento de Água (ETA) Santa Bárbara através de bombeamento.

## 2 Objetivos

### 2.1 Geral

O objetivo geral desta pesquisa consistiu no desenvolvimento de modelos empíricos para clorofila, sólidos suspensos totais e densidade celular de organismos do gênero *Ceratium* no reservatório utilizado para o abastecimento de água na cidade de Pelotas, no Rio Grande do Sul – a Barragem Santa Bárbara, combinando informações de reflectância de superfície das imagens obtidas por sensoriamento remoto orbital do sensor MSI/Sentinel-2 e dados *in situ*.

### 2.2 Específicos

Os objetivos específicos do trabalho são:

(i) Correlacionar as reflectâncias das diferentes bandas extraídas das imagens do MSI/Sentinel-2 em função das variações das concentrações de clorofila-a e sólidos suspensos totais;

(ii) Gerar um modelo bio-óptico para estimativa de clorofila-a e sólidos suspensos totais a partir de relações empíricas entre as análises *in situ* e as bandas do sensor;

(iii) Testar diferentes estratégias de organização dos dados espectrais nas modelagens;

(iv) Verificar as variações das concentrações de clorofila-a em função da densidade celular de organismos do gênero *Ceratium*;

(v) Avaliar o desempenho dos modelos empíricos gerados para aplicação em águas interiores;

(vi) Desenvolver mapas da distribuição espacial de clorofila-a, sólidos suspensos totais e densidade celular de *Ceratium* utilizando os modelos mais bem avaliados para cada um dos parâmetros.

### 2.3 Hipóteses

- A clorofila-a e o teor de sólidos suspensos totais são parâmetros passíveis de modelagem combinando dados de reflectância de imagens de satélite com dados *in situ*.

- A relação dos dados de sensoriamento remoto e dados de concentração medidos *in situ* apresentam relação, permitindo a geração de um modelo empírico que forneça a concentração desse parâmetro na Barragem Santa Bárbara.

- Há uma relação forte entre a densidade celular de organismos do gênero *Ceratium* e o teor de clorofila-a, possibilitando a modelagem da distribuição dos organismos em função da clorofila e, por conseguinte, em função de relações espectrais.

### **3 Referencial teórico**

No presente capítulo, são revisados alguns termos, definições e conceitos referentes à temática da pesquisa realizada. Primeiramente, foi feita uma abordagem geral sobre a qualidade de água, principalmente relacionado aos processos de eutrofização e com foco nos componentes explorados pelo trabalho – sólidos suspensos totais, clorofila e comunidade fitoplanctônica. Em seguida, é apresentada a visão de alguns autores sobre os desafios no monitoramento dessa qualidade, mostrando, por conseguinte, a alternativa do uso de sensoriamento remoto. Por fim, uma ampla abordagem sobre fundamentos e aplicações do monitoramento remoto foi realizada, levando em consideração os principais métodos citados na literatura especializada.

#### **3.1 Qualidade de água**

De acordo com as definições das agências de proteção sanitária e ambiental, como a Organização Mundial da Saúde (OMS), a qualidade da água se refere às suas características físicas, químicas e biológicas. Essa qualidade determina a adequação desse recurso para diferentes aplicações, como abastecimento público, recreação, consumo, pesca, agricultura e indústria (MOHSENI *et al.*, 2022).

No geral, todos os aspectos de qualidade da água são medidos por uma série de parâmetros, como turbidez, concentrações de clorofila, sedimentos, oxigênio dissolvido, nutrientes, cianobactérias e algas nocivas, entre outros, em função do número de suas partículas dentro da água pura (SAGAN *et al.*, 2020). É importante ressaltar que estes não ocorrem de maneira isolada – pelo contrário, afetam uns aos outros. Por exemplo, o número de partículas suspensas afeta a cor e a turbidez da água; a temperatura e os nutrientes influenciam na quantidade e o tipo de constituição de algas e cianobactérias, que influenciam no teor de clorofila (TOMING *et al.*, 2016).

O estudo desses parâmetros, além de determinar a qualidade dos corpos d'água, ajuda a identificar as possíveis fontes de contaminação que degradam esses recursos (USALI; ISMAIL, 2010). Essa degradação é função das influências naturais e das atividades humanas, individuais ou coletivas (KHATRI; TYAGI, 2015) e é principalmente afetada por cargas de nutrientes e sedimentos.

O excesso de carga de nutrientes, em especial nitrogênio (N) e/ou fósforo (P), pode criar condições para o processo de eutrofização, que está simplificada demonstrado na Figura 1. Esse processo permite o afloramento de organismos como algas eucarióticas e cianobactérias no corpo hídrico, chamado de florações ou *bloom*. Esses organismos constituem o fitoplâncton, que são seres planctônicos que obtêm sua energia da fotossíntese (KHAN; MOHAMMAD, 2014; KUO *et al.*, 2006; O'NEIL *et al.*, 2012; SHOURIAN; MORIDI; KAVEH, 2016).

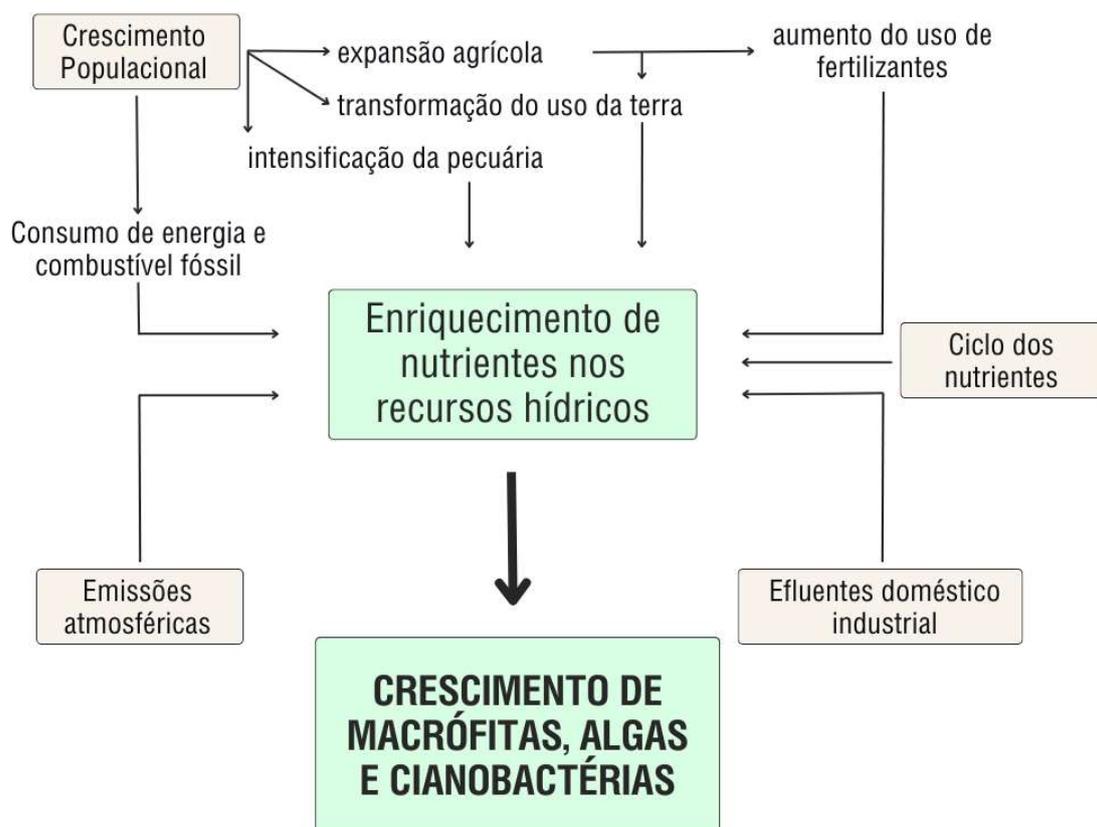


Figura 1 – Esquema simplificado do processo de eutrofização impulsionada pela ação sinérgica de fatores diretos e indiretos.

Fonte: Adaptado de Khan e Mohammad, 2014.

Conforme Hanisch e Freire-Nordi (2015), a concentração e o tipo de fitoplâncton fornecem informações importantes a respeito da qualidade da água, já que causam problemas como variação diurna das disponibilidades de oxigênio, com depleção nas camadas mais profundas, alteração do gosto e odor nas águas (SLONECKER *et al.*, 2021) e problemas operacionais em estações de tratamento de água (BOEIRA *et al.*, 2017).

Corroborando, Watanabe *et al.* (2015) destacam que altas concentrações de algumas espécies podem acarretar problemas de saúde pública, tendo em vista que podem produzir toxinas que, em determinadas quantidades, causam doenças no fígado e no sistema nervoso, o que em situações mais graves pode levar à morte.

Além disso, uma classe em especial tem chamado a atenção dos pesquisadores pela sua ocorrência em ambientes de água doce. Algas dinoflageladas do gênero *Ceratium* geralmente habitam ambientes marinhos; no entanto, em vista da menor frequência em ecossistemas de água doce, esses organismos têm sido considerados invasores em ambientes tropicais e subtropicais (SILVA *et al.*, 2012). Essas espécies de algas eucariontes unicelulares biflageladas e heterotróficas são capazes de formar florações porque são dotadas de relativa mobilidade, o que facilita a ocupação de camadas superficiais e a otimização de recursos como luz e nutrientes (MAC DONAGH; CASCO; CLAPS, 2005). Apesar destas florações não serem consideradas tóxicas, acabam sendo um problema para os sistemas de abastecimento de água, principalmente na etapa de tratamento, já que são seres livre-natante (BICUDO; MENEZES, 2017), resistentes à sedimentação, o que acaba diminuindo significativamente a vida útil do sistema de filtração (BOEIRA *et al.*, 2017).

A proliferação de algas está diretamente relacionada à concentração de clorofila, uma vez que é essencial para a fotossíntese (GUO *et al.*, 2016). Esse parâmetro é o principal indicador do estado trófico do ambiente porque atua como um elo entre a concentração de nutrientes e a produção de algas (GHOLIZADEH; MELESSE; REDDI, 2016), embora também seja afetado por vários outros fatores, como temperatura da água, pH e luz (VISO-VÁZQUEZ *et al.*, 2021).

Além das consequências decorrentes da eutrofização, outro importante impacto que ocorre, principalmente em ambientes lênticos como reservatórios, é o assoreamento. Essa deposição contínua ou gradual do sedimento carregado pelos cursos d'água é devida à diminuição de velocidade e da turbulência das águas, que causa sua perda de capacidade de transporte (SAUNITTI; FERNANDES; BITTENCOURT, 2004). Sua origem pode ser local, como ressuspensão induzida pelo vento, e/ou distante, por exemplo, vindo de tributários (MADSEN *et al.*, 2001).

O sedimento, presente na forma de sólidos suspensos totais (SST), inclui uma ampla variedade de material particulado e pode conter fitoplâncton vivo e morto, substâncias húmicas, argilominerais, detritos etc. (GUSTAFSSON; GSCHWEND, 1997). Esse material contribui para a deterioração da qualidade da água alterando o

sistema hidrológico e influenciando em diversos outros fatores, como no aporte de nutrientes e na distribuição da luz espalhada pelo corpo d'água (ZHAO *et al.*, 2020).

Os sólidos suspensos totais são transportadores essenciais de matéria orgânica, como nitrogênio e fósforo. Ao influenciar a distribuição da luz espalhada no corpo d'água, os SST controlam diretamente a produtividade fitoplanctônica do corpo d'água, que por sua vez afeta a transparência e o conteúdo de oxigênio, e exerce uma parte decisiva no ambiente ecológico aquático (ZHAO *et al.*, 2020).

### 3.1.1 Desafios do monitoramento da qualidade de água

A qualidade da água é conhecida por determinar a saúde da sociedade e dos ecossistemas, e qualquer deterioração em sua qualidade representa um risco para a saúde humana, produtividade alimentar e biodiversidade (RAMADAS; SAMANTARAY, 2018).

A necessidade de abastecimento urbano sustentável de água exige que a qualidade dos recursos hídricos disponíveis existentes, bem como de suas bacias hidrográficas, esteja sob monitoramento contínuo (GHOLIZADEH; MELESSE; REDDI, 2016). Para águas interiores como reservatórios e barragens, principais fontes para o abastecimento de água de cidades e comunidades rurais, a *priori* compreensão da qualidade da água antes do tratamento é fundamental, não apenas para entender a saúde ambiental dentro da área de captação, mas também para minimizar o custo do tratamento da água de abastecimento (OUMA; NOOR; HERBERT, 2020).

Ao longo das últimas décadas, a comunidade científica tem demonstrado grande interesse na investigação da qualidade da água devido aos seus níveis de degradação (DUBE *et al.*, 2015). Para realização desse monitoramento, muitas vezes, é empregado a avaliação convencional por meio de amostragem e medição laboratorial (OUMA; NOOR; HERBERT, 2020). Resumidamente listadas abaixo estão as limitações mais importantes associadas aos métodos convencionais (GHOLIZADEH; MELESSE; REDDI, 2016):

- A amostragem *in situ* e as medições dos parâmetros de qualidade da água são trabalhosas, demoradas e caras;
- A investigação das variações espaciais e temporais e das tendências da qualidade da água é quase impossível;

- Monitoramento, previsão e gerenciamento de corpos d'água podem ser inacessíveis, por exemplo, devido à situação topográfica;
- A exatidão e a precisão dos dados coletados *in situ* podem ser questionáveis devido a erros de amostragem de campo e de laboratório.

Para superar essas limitações, o uso de sensoriamento remoto (SR) na avaliação da qualidade da água pode ser uma ferramenta útil. Por mais de quatro décadas, essa ferramenta ilustrou fortes capacidades para monitorar e avaliar a qualidade das águas interiores.

### **3.2 Sensoriamento Remoto**

Com os avanços da ciência espacial, o aumento do uso de aplicativos de computador e aumento dos poderes de computação nas últimas décadas, as técnicas de sensoriamento remoto tornaram-se ferramentas úteis para o monitoramento de águas interiores (LOPES *et al.*, 2014).

O sensoriamento remoto funciona com base no princípio de que diferentes constituintes refletem ou emitem diferentes quantidades de energia em diferentes faixas (ou bandas) de comprimento de onda do espectro eletromagnético que incidem sobre eles (RAMADAS; SAMANTARAY, 2018). Para o SR da superfície terrestre, a principal fonte de radiações eletromagnéticas (REM) é o Sol, cujo espectro da radiação solar cobre um intervalo de comprimentos de onda desde 0,2 até 25  $\mu\text{m}$  (NOVO, 2010). As principais faixas do espectro eletromagnético estão representadas na Figura 2.

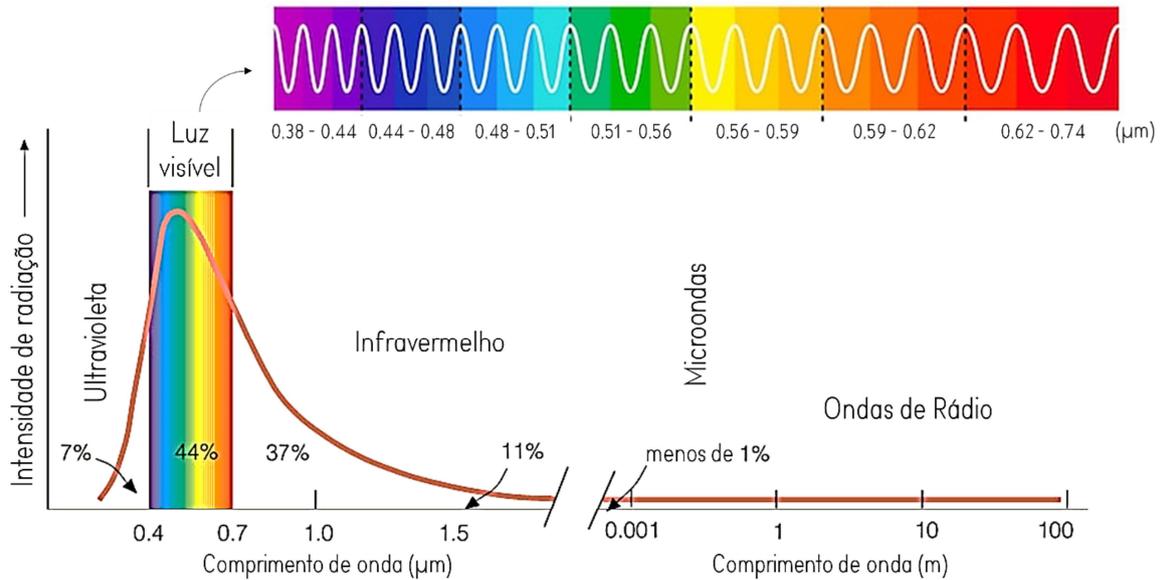


Figura 2 – O espectro eletromagnético, com destaque da porção correspondente à luz visível.

Fonte: Adaptado de Hakim, [s.d.]

Sensores a bordo de aeronaves, satélites de sensoriamento remoto e veículos aéreos são capazes de registrar a energia refletida/emitada e processar para formar uma imagem, que fornece informações valiosas sobre a extensão da contaminação dos corpos d'água e concentração de contaminantes. As imagens recuperadas do SR variam em qualidade com base em diferentes características do sensor, como resolução espacial (tamanho de pixel), resolução espectral (número de bandas), resolução radiométrica (níveis de cinza) e resolução temporal (frequência de passagem) (JENSEN, 2009). Uma representação dessas diferentes características está apresentada na Figura 3.

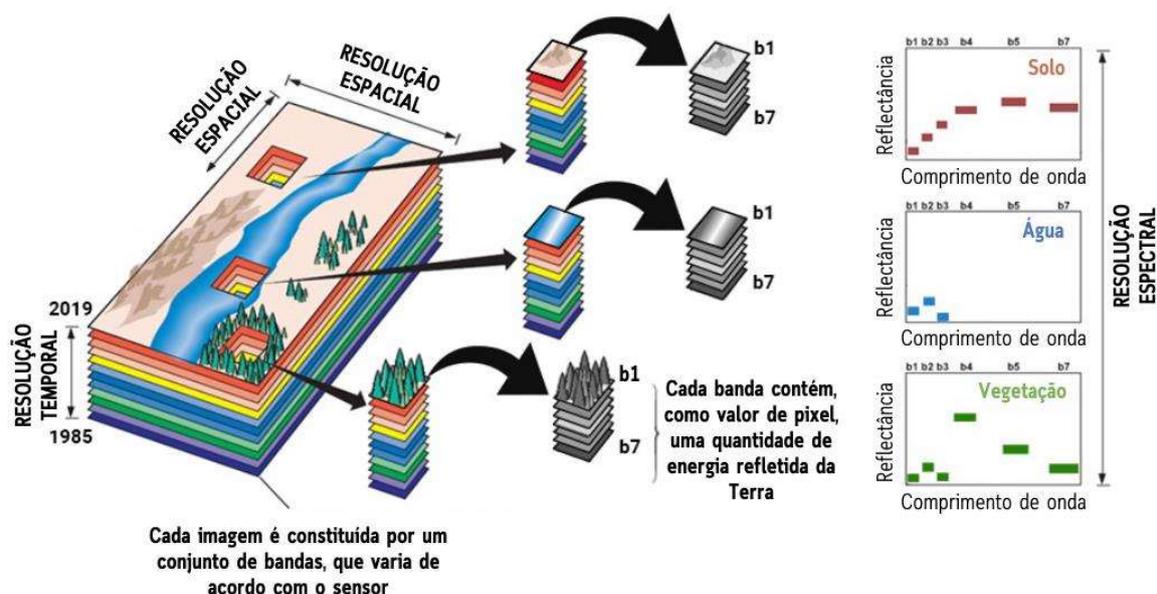


Figura 3 – Os três principais domínios de informação do sensoriamento remoto: as resoluções de espectro, de tempo e de espaço.

Fonte: Adaptado de Diniz, 2020.

A maior parte dos estudos inerentes ao sensoriamento remoto se baseiam no desenvolvimento de uma relação entre a quantidade de energia eletromagnética refletida, emitida ou espalhada e as características químicas, biológicas e físicas dos fenômenos, superfícies ou objetos que se investigam (JENSEN, 2009). Nesse sentido, é o aspecto espectral que fornece a informação responsável pela separação entre os alvos “A” ou “B” na superfície terrestre, no qual a resolução espectral é definida pelo número e dimensão (tamanho) dos intervalos de comprimento de onda (bandas) para o qual um sensor é sensível (JENSEN, 2009; NOVO, 2010).

Desde o advento das missões Landsat, na década de 1970, o sensoriamento remoto por satélite está sendo cada vez mais usado para avaliar os parâmetros de qualidade da água (CHAWLA; KARTHIKEYAN; MISHRA, 2020).

### 3.2.1 Propriedades ópticas da água

A água é composta de moléculas contendo muitos materiais suspensos e dissolvidos, orgânicos e inorgânicos, vivos e não vivos, e essa composição altera significativamente suas características espectrais (NOVO, 2010). Quando a radiação solar incidente ou outra luz atinge a superfície de um corpo d'água, parte é refletida

na superfície enquanto uma porção maior penetra na própria coluna d'água iniciando interações com matéria suspensa e dissolvida (JENSEN, 2009).

Um corpo de água limpa absorve cerca de 97-99% da energia incidente e reflete apenas 1-3% das radiações (BÜTTNER *et al.*, 1987). Esta porcentagem varia com a alteração da qualidade da água, sendo que a água poluída apresenta maior reflectância. Além disso, o comprimento de onda refletido dominante muda com a mudança nos constituintes da água. Como os sistemas SR medem a radiação ou emissão da água em diferentes partes do espectro eletromagnético, o conceito subjacente é que a presença de diferentes substâncias no corpo d'água resultam em características espectrais únicas. (CHAWLA; KARTHIKEYAN; MISHRA, 2020; MOHSENI *et al.*, 2022; NOVO, 2010). Essas diferenças podem ser usadas direta ou indiretamente para detectar diferentes indicadores de qualidade da água, que podem ser classificados de acordo com sua atividade óptica em ativos e inativos.

Os Constituintes Opticamente Ativos (COAs) são parâmetros de qualidade de água que apresentam propriedades ópticas de absorção e espalhamento e que podem ser determinados diretamente (NOVO, 2010). Os constituintes não opticamente ativos são aqueles que não absorvem luz e, portanto, não podem ser medidos diretamente por métodos espectrais. Métodos indiretos, no entanto, podem ser usados para estimar ou medir vários desses importantes parâmetros de qualidade da água (SAGAN *et al.*, 2020).

A Tabela 1 apresenta alguns dos principais parâmetros determinados por SR encontrados na literatura e suas propriedades ópticas.

Tabela 1 – Parâmetros qualitativos da água mais comumente medidos por meio de sensoriamento remoto.

Parâmetro de qualidade da água	Abreviação	Unidade	Atividade óptica
Clorofila-a	Chl-a	$\mu\text{g L}^{-1}$ ou $\text{mg m}^{-3}$	Ativo
Profundidade do Disco Secchi	SDD	m	Ativo
Temperatura	T	$^{\circ}\text{C}$	Ativo
Matéria orgânica colorida	CDOM	$\text{mg L}^{-1}$	Ativo
Carbono orgânico total	TOC	$\text{mg L}^{-1}$	Ativo
Carbono Orgânico Dissolvido	COD	$\text{mg L}^{-1}$	Inativo
Sólidos Suspensos Totais	SST	$\text{mg L}^{-1}$	Ativo
Turbidez	TUR	NTU	Ativo
Salinidade da Superfície do Mar	SSS	SSS	Ativo
Fósforo Total	P	$\text{mg L}^{-1}$	Inativo
Ortofosfato	$\text{PO}_4$	$\text{mg L}^{-1}$	Inativo
Demanda Química de Oxigênio	DQO	$\text{mg L}^{-1}$	Inativo
Demanda Bioquímica de Oxigênio	DBO	$\text{mg L}^{-1}$	Inativo
Condutividade elétrica	CE	$\mu\text{S cm}^{-1}$	Ativo
Nitrogênio Amoniacal	$\text{NH}_3$	$\text{mg L}^{-1}$	Inativo

Fonte: Adaptado de Gholizadeh; Melesse; Reddi, 2016.

### 3.2.2 Clorofila-a e organismos fitoplanctônicos

Entre os diferentes parâmetros de qualidade da água, a clorofila-a (Chl-a) é um dos parâmetros mais amplamente examinados usando sensoriamento remoto (CHAWLA; KARTHIKEYAN; MISHRA, 2020). A interação entre a luz e a Chl-a permite a detecção da proliferação de algas a partir de imagens espaciais.

Este pigmento exibe uma característica espectral com picos perceptíveis nos comprimentos de onda azul ( $\sim 440$  nm) e vermelho ( $\sim 675$  nm), oferecendo uma base física teórica para sua estimativa (BREWIN *et al.*, 2015; GONS; AUER; EFFLER, 2008; MATTHEWS; BERNARD; ROBERTSON, 2012). Entretanto, os modelos baseados nessa relação são predominantemente restritos a águas oligotróficas, onde a concentração de Chl-a atinge até  $10 \text{ mg m}^{-3}$  (CAIRO *et al.*, 2019; SHI *et al.*, 2019).

Conforme mostra a Figura 4, para concentrações acima de  $10 \text{ mg m}^{-3}$ , algoritmos baseados na relação entre as bandas do vermelho e do infravermelho são

mais adequados (CAIRO *et al.*, 2019; GITELSON *et al.*, 2011; HUNTER *et al.*, 2008; SABERIOON *et al.*, 2020). Esse aumento na reflectância na região espectral NIR ocorre devido ao aumento da dispersão da biomassa de algas, que está relacionada a um aumento de Chl-a para a maioria das espécies de fitoplâncton (BRESCIANI *et al.*, 2018). Essas densas florações têm características de reflectância espectral semelhantes às da vegetação terrestre (SHI *et al.*, 2015).

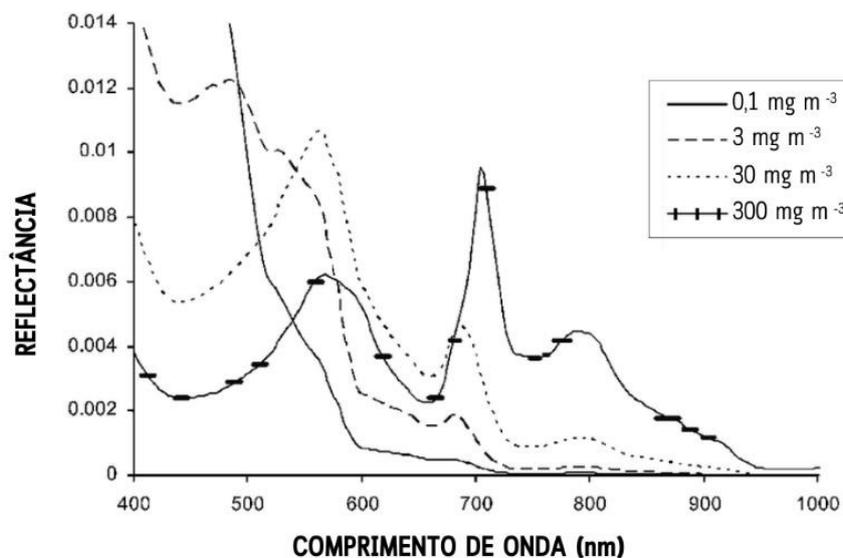


Figura 4 – Espectros de reflectância da água modelados para concentrações de clorofila-a de  $0,1 \text{ mg m}^{-3}$ ,  $3 \text{ mg m}^{-3}$ ,  $30 \text{ mg m}^{-3}$  e  $300 \text{ mg m}^{-3}$ , mostrando o pico em  $685 \text{ nm}$  para concentrações de Chl-a mais baixas e o pico na faixa de comprimento de onda  $700\text{-}710 \text{ nm}$  para concentrações de Chl-a a acima de  $100 \text{ mg m}^{-3}$ .

Fonte: Adaptado de GOWER *et al.*, 2005.

O pigmento fitoplâncton onipresente Chl-a é geralmente considerado um importante indicador da biomassa algal e cianobacteriana, que pode responder rapidamente às mudanças ambientais (SHI *et al.*, 2015). No entanto, a quantificação de Chl-a não é a melhor maneira de determinar com precisão a abundância desses organismos porque esse pigmento existe em todas as comunidades fitoplanctônicas (SLONECKER *et al.*, 2021).

Segundo Stumpf *et al.* (2016), o mapeamento de algas e cianobactérias com sensoriamento remoto exige uma estratégia de modelo duplo: (1) caracterizar uma relação entre a quantidade de organismos e o pigmento que pode ser detectado com segurança por satélite e (2) estabelecer a relação entre as observações de satélite e o pigmento. Este conceito tem sido usado em outras aplicações de sensoriamento remoto para ambientes aquáticos. Um dos exemplos mais simples envolve estimar a

salinidade em águas costeiras usando matéria orgânica dissolvida colorida (CDOM) (SALISBURY *et al.*, 2011).

### 3.2.3 Sólidos em suspensão

A determinação de SST por sensoriamento remoto é baseada na interação entre a REM e as partículas suspensas do sistema aquático. Essa interação é afetada pelas propriedades físicas das partículas, como o índice de refração e sua granulometria (MACIEL *et al.*, 2019).

Em geral, a presença de SST e, conseqüentemente, turbidez em corpos d'água, aumenta a reflectância das regiões verde, vermelha e infravermelho próximo (NIR) do espectro eletromagnético (DOGLIOTTI *et al.*, 2015; FENG *et al.*, 2012; RITCHIE; SCHIEBE; MCHENRY, 1976), embora sua magnitude dependa da concentração e dos tipos de COAs presentes na coluna de água.

Ritchie *et al.* (1976) descobriram que, em geral, o comprimento de onda ideal para quantificar o material suspenso em corpos d'água é de 700 a 800 nm, conforme mostra a Figura 5. Vários modelos foram desenvolvidos para relacionar a reflectância espectral com a concentração de material em suspensão em corpos d'água. Para SST em concentrações mais baixas (até 50 mg L<sup>-1</sup>), relações com as bandas espectrais verdes ou vermelhas são os mais adequados para modelagem. Em concentração maior, acima de 100 mg L<sup>-1</sup>, aproximadamente, a reflectância nas bandas verde e vermelha satura e a concentração tende a ser subestimada. Portanto, as bandas NIR tornam-se a escolha indicada (MACIEL *et al.*, 2019).

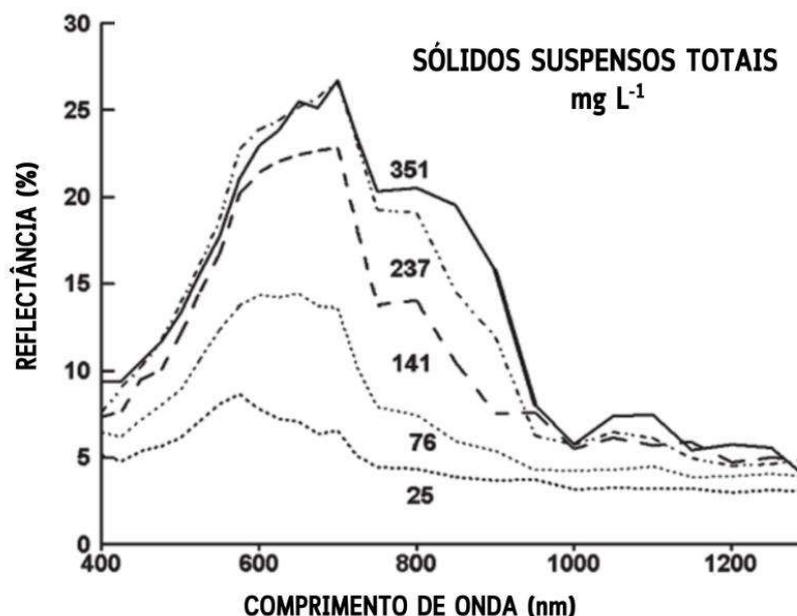


Figura 5 – Espectros de reflectância da água modelados para concentrações de sólidos suspensos totais de 25 mg L<sup>-1</sup>, 76 mg L<sup>-1</sup>, 141 mg L<sup>-1</sup>, 237 mg L<sup>-1</sup> e 351 mg L<sup>-1</sup>.

Fonte: Adaptado de Ritchie; Schiebe; Mchenry, 1976

### 3.2.4 Modelagem bio-óptica

As equações que modelam as relações entre as propriedades ópticas do corpo d'água e a concentração de constituintes opticamente ativos da qualidade da água são comumente chamadas de modelos bio-ópticos (VIRDIS *et al.*, 2022). Esses modelos podem ser de origem empírica ou semianalítica.

Os modelos empíricos se baseiam no desenvolvimento de algoritmos uni ou multivariados entre medidas concomitantes da reflectância nas bandas dos sensores (uma ou várias bandas, razões de banda etc.) e de concentrações dos COAs (BARBOSA; DE MORAES NOVO; MARTINS, 2019). As abordagens empíricas, geralmente, são válidas somente para o conjunto de dados (imagem e dados *in situ*) a partir do qual as relações estatísticas foram determinadas.

A teoria mostra que o uso de uma única banda espectral fornece um algoritmo robusto e sensível a Chl-a e SST, desde que a banda seja escolhida apropriadamente (NECHAD; RUDDICK; PARK, 2010). No entanto, as substâncias complexas na água alteram a reflectância do corpo d'água. Para contornar esse problema, um dos métodos amplamente utilizados para a recuperação das propriedades da qualidade da água a partir de dados de sensoriamento remoto para águas opticamente

complexas (isto é, águas interiores) são os algoritmos baseados em razão de banda, já que podem reduzir substancialmente o efeito da atmosfera e aumentar a relação sinal-ruído (CHAWLA; KARTHIKEYAN; MISHRA, 2020). Normalmente, essas bandas são uma combinação de uma banda no espectro vermelho e outra no espectro do infravermelho próximo (NIR) (SHI *et al.*, 2015, 2019).

Uma questão que não deve ser negligenciada na modelagem da qualidade da água por sensoriamento remoto é a revisão e avaliação completa dos sensores apropriados no contexto de um corpo d'água específico (que possui propriedades espaciais e temporais únicas), já que as características de cada sensor podem ter grandes implicações no conjunto de dados resultantes. Hansen *et al.* (2017) citam alguns fatores que devem ser levados em conta para a escolha do sensor: a resolução espacial (que é limitada pelo tamanho do corpo d'água), o tempo de retorno desejado (que é influenciado pela variabilidade temporal dos processos de qualidade da água), a duração do registro histórico (desde quando o sensor está em operação e o intervalo de geração de imagens), a resolução espectral (que determina a capacidade do sensor de discriminar ou determinar com mais precisão as condições e quais parâmetros podem ser estimados), os recursos de processamento disponíveis (desde os dados de imagens e produtos de dados, custo de aquisição das imagens e até o pessoal que executará o processamento e a análise dos dados) e o escopo do algoritmo desejado (espacial e/ou temporal).

A literatura sugere que, para monitoramento de recursos hídricos, a escolha do uso de satélites de resolução espacial média, como o Landsat (30 m) e o Sentinel (10 - 20 m), ou de satélites de resolução espacial menor, como o *Moderate Resolution Imaging Spectroradiometer* (MODIS) e o *Medium Resolution Imaging Spectrometer* (MERIS) (300 - 1000 m), se baseie principalmente no tamanho do corpo d'água (OLMANSON; BREZONIK; BAUER, 2011; TOMING *et al.*, 2016). Para se ter uma perspectiva, o menor corpo de água que pode ser medido por um sensor de satélite com tamanho de pixel de 1 km é de aproximadamente 1000 hectares, enquanto uma resolução espacial de 30 m permite medições em corpos d'água maiores que 4 hectares (OLMANSON; BREZONIK; BAUER, 2015).

Além disso, a variabilidade temporal observada no sistema é essencial na avaliação dos sensores (TOMING *et al.*, 2016). Por exemplo, o tempo de revisita do Landsat (16 dias) pode ser uma desvantagem quando comparado com Sentinel-2 (5

dias) e MODIS (1–2 dias) para detectar eventos curtos, enquanto pode ser suficiente para outras áreas do sistema com menor variabilidade de curto prazo.

Para corpos d'água interiores, o Sentinel-2 é líder no campo de monitoramento remoto devido à sua variedade espectral em comprimentos de onda de borda vermelha e NIR, média/alta resolução temporal e média/alta resolução espacial (ANSFER; ALIKAS, 2018; DOGLIOTTI *et al.*, 2018; KISLIK *et al.*, 2022).

### 3.2.5 Sentinel-2/MSI

O lançamento do *Multispectral Imager* (MSI) a bordo do Sentinel-2, em 2015, abriu um novo e grande potencial no sensoriamento remoto de corpos hídricos. A missão Sentinel-2, da Agência Espacial Europeia (ESA), carrega o MSI a bordo dos satélites gêmeos Sentinel-2A e Sentinel-2B, que foram lançados em 23 de junho de 2015 e 7 de março de 2017, respectivamente (ESA, 2012). As imagens geradas têm resolução espacial de 10 m, 20 m e 60 m, o que significa que pequenos corpos d'água podem ser estudados. Os dados são adquiridos em 13 bandas espectrais e a resolução radiométrica do sensor é de 12 bits (CABALLERO; STUMPF, 2020). Uma representação dessas características está na Figura 6.

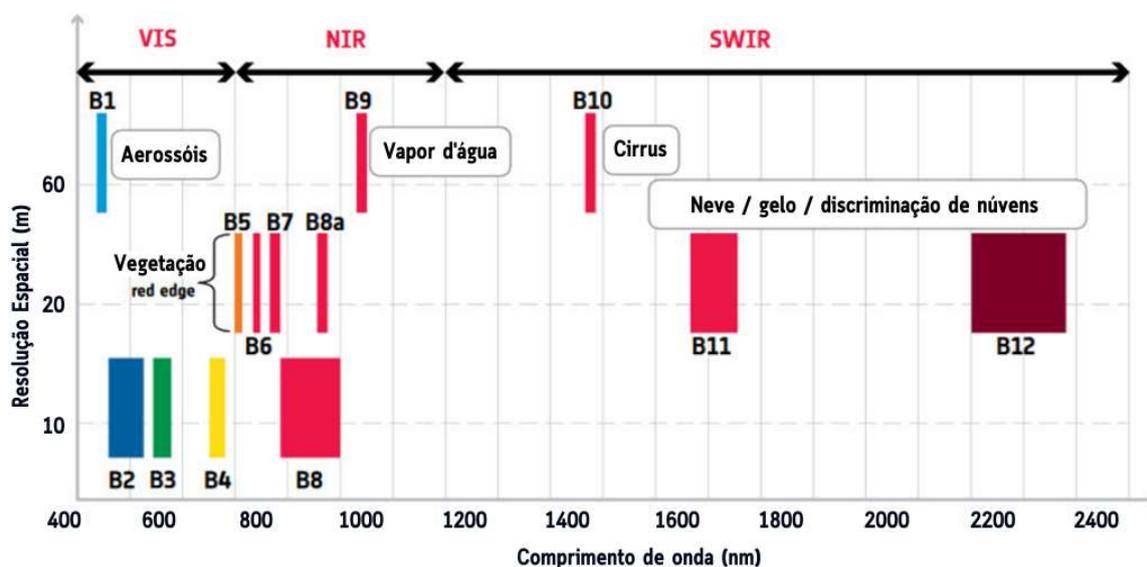


Figura 6 – Resolução espacial do MSI versus comprimento de onda: 13 bandas espectrais do Sentinel-2, do visível (VIS) e infravermelho próximo (NIR) até infravermelho de ondas curtas (SWIR) com diferentes resoluções espaciais, variando de 10m a 60m.

Fonte: ESA, 2012.

A missão Sentinel-2, além de apresentar boa resolução espacial, múltiplas bandas espectrais, curtos tempos de revisita, possui uma política de dados aberta e gratuita, o que a tornou um rico arquivo de dados de satélite disponível para o público em geral (SOVDAT *et al.*, 2019). Com um projeto de vida útil de sete anos, os satélites gêmeos existentes estão planejados para serem substituídos por novas missões idênticas, levando o registro de dados para o período de 2030 (PAHLEVAN *et al.*, 2019).

Pesquisadores mostraram que o Sentinel-2 não só pode melhorar o mapeamento global de águas interiores (DU *et al.*, 2016), mas também pode oferecer uma gama útil de informações para monitorar certos indicadores de qualidade da água (PAHLEVAN *et al.*, 2017; TOMING *et al.*, 2016).

Utilizando o sensor MSI, Toming *et al.* (2016) conduziram um estudo na Estônia no qual mostraram a adequação dos dados remotos para mapear diferentes parâmetros, nomeadamente Chl-a, cor da água, CDOM e COD. Os resultados obtidos mostraram uma forte correlação entre as bandas de razão Sentinel-2 MSI e os diferentes parâmetros de qualidade da água do lago, como Chl-a ( $R^2 = 0,83$ ).

Na República Tcheca, foi realizado um estudo por Saberioon *et al.* (2020) com o objetivo de desenvolver um modelo semiempírico para Chl-a e SST, combinando dados do Sentinel-2 e métodos de aprendizado de máquina. Os resultados mostraram uma precisão de predição adequada para Chl-a ( $R^2 = 0,85$ , RMSE = 48,57) e SST ( $R^2 = 0,80$ , RMSE = 19,55).

Para o monitoramento de lagos eutróficos na Lituânia, Grendaite *et al.* (2018) utilizaram imagens do Sentinel-2 para prever a concentração de Chl-a, com uma faixa de precisão entre 0,45 e 0,76. Kutser *et al.* (2018) utilizaram dados do Sentinel-2 para mapear Chl-a e SST para águas rasas no mar Báltico. Além disso, Pahlevan *et al.* (2019) compararam os dados dos satélites Landsat 8 e Sentinel-2A/B para estimar SST. Giardino *et al.* (2019) usaram o Sentinel-2 para determinar a cor da água de 170 lagos italianos como um atributo de qualidade da água.

### **3.3 Vantagens e desvantagens do monitoramento remoto da qualidade da água**

Usali e Ismail (2010) mencionaram quatro vantagens de aplicar o sensoriamento remoto em conformidade com outros programas de monitoramento da qualidade da água, conforme abaixo:

- Oferece uma visão sinóptica de todo o corpo d'água para um monitoramento mais eficaz da variação espacial e temporal;
- Possibilita a visualização sincronizada da qualidade da água de um conjunto de corpos hídricos em uma vasta região;
- Fornece um registro histórico abrangente da qualidade da água em uma área e representa as tendências ao longo do tempo;
- Prioriza os locais de amostragem e os horários de levantamento de campo.

O sensoriamento remoto é uma técnica adequada para estudar as variações espaciais e temporais das variáveis de qualidade da água. No entanto, uma série de restrições importantes requerem considerações antes de conduzir esta técnica.

Os modelos desenvolvidos a partir de dados de sensoriamento remoto requerem calibração adequada e validação usando medições *in situ*, e podem ser usados apenas na ausência de nuvens (MARTINS *et al.*, 2018). Além disso, a precisão dos parâmetros de qualidade da água extraída pode ser discutível em algumas situações devido às limitações de resolução espacial, temporal e espectral; por exemplo, Kutser *et al.* (2016) afirmam que as áreas mais densas de proliferação de cianobactérias no Mar Báltico geralmente não são detectadas por produtos de satélite padrão devido à correção atmosférica ou erros de processamento.

Independentemente de algumas questões técnicas, o sensoriamento remoto tem se mostrado um método eficaz para monitorar a qualidade da água (CHAWLA; KARTHIKEYAN; MISHRA, 2020), tendo uma vantagem na cobertura temporal e espacial em comparação com os métodos *in situ*. Sobral *et al.* (2017) apontam que a aplicação desses dados pode ajudar pesquisadores, gestores ambientais e tomadores de decisão a conhecerem quando, onde e por que a proliferação demasiada de algas ou a carga extra de sedimentos ocorre em determinado corpo hídrico. Nesse sentido, o SR não vem substituir o monitoramento de campo, mas sim fazer parte do sistema de monitoramento integrado de um determinado corpo hídrico.

Infelizmente, as possíveis sinergias do uso de produtos de sensoriamento remoto com dados *in situ* em programas nacionais de monitoramento de águas interiores ou sistemas de gestão ainda permanecem amplamente inexploradas, devido às suposições de custo, conhecimento insuficiente do produto, continuidade incerta dos dados e falta de suporte programático (treinamento, software e capacidade de processamento) (USALI; ISMAIL, 2010). Essa carga pode colocar essas

ferramentas fora do alcance de muitos pesquisadores, restringindo o acesso às informações contidas em grandes conjuntos de dados de sensoriamento remoto a especialistas na área com acesso especial a recursos de computação de alto desempenho (GORELICK *et al.*, 2017). No entanto, com o advento de serviços como o *Google Earth Engine* (GEE), uma conexão robusta com a Internet agora é tudo o que é necessário para acessar, manipular e analisar grandes volumes de dados, expandindo a fronteira da ciência do sensoriamento remoto.

### 3.4 *Google Earth Engine* e o processamento em nuvem

O *Google Earth Engine* é uma aplicação baseada em computação em nuvem e é uma plataforma de desenvolvimento com poderosas capacidades de armazenamento, gerenciamento e processamento de dados, fornecendo meios técnicos para uma gama de aplicações (ZHAO *et al.*, 2021). É composto por quatro elementos principais:

- (i) *Infraestrutura* – o Google coloca seus servidores à disposição do usuário, permitindo análises paralelas em cerca de 10000 CPUs. Por exemplo, o trabalho de alguns dias para o desenvolvimento do mapa global sem nuvens do Google Earth e o Google Maps teria um atraso de 14 anos caso fosse feito em apenas um computador pessoal (PERILLA; MAS, 2020).
- (ii) *Datasets* - o GEE fornece acesso gratuito a um catálogo de dados geoespaciais, que englobam mais de 40 anos de imagens históricas e atuais de observação da Terra, incluindo imagens de diferentes satélites (por exemplo, Sentinel, Landsat e MODIS), bem como modelos digitais de elevação (GORELICK *et al.*, 2017; TELUGUNTLA *et al.*, 2018). Além disso, seu repositório é diariamente atualizado com cerca de 6000 novas cenas de imagens dos atuais sensores de satélite ativos, tornando-o um repositório de imagens quase em tempo real (WANG *et al.*, 2020).
- (iii) *Interface de Programação de Aplicação (API)* - consiste em uma série de comandos e funções pré-estabelecidos, escritos em linguagem *JavaScript* ou *Python*, que permite uma fácil programação na hora de desenvolver algoritmos para investigações (GORELICK *et al.*, 2017; TELUGUNTLA *et al.*, 2018).

- (iv) *Editor de código* - é um ambiente de desenvolvimento integrado online, no qual todos os elementos se juntam. É aqui que o usuário pode, por meio de código de trabalho (*scripts*), acessar os dados, processá-los e visualizá-los virtualmente com os servidores do Google, tendo assim seus resultados e informações na nuvem (Figura 7).

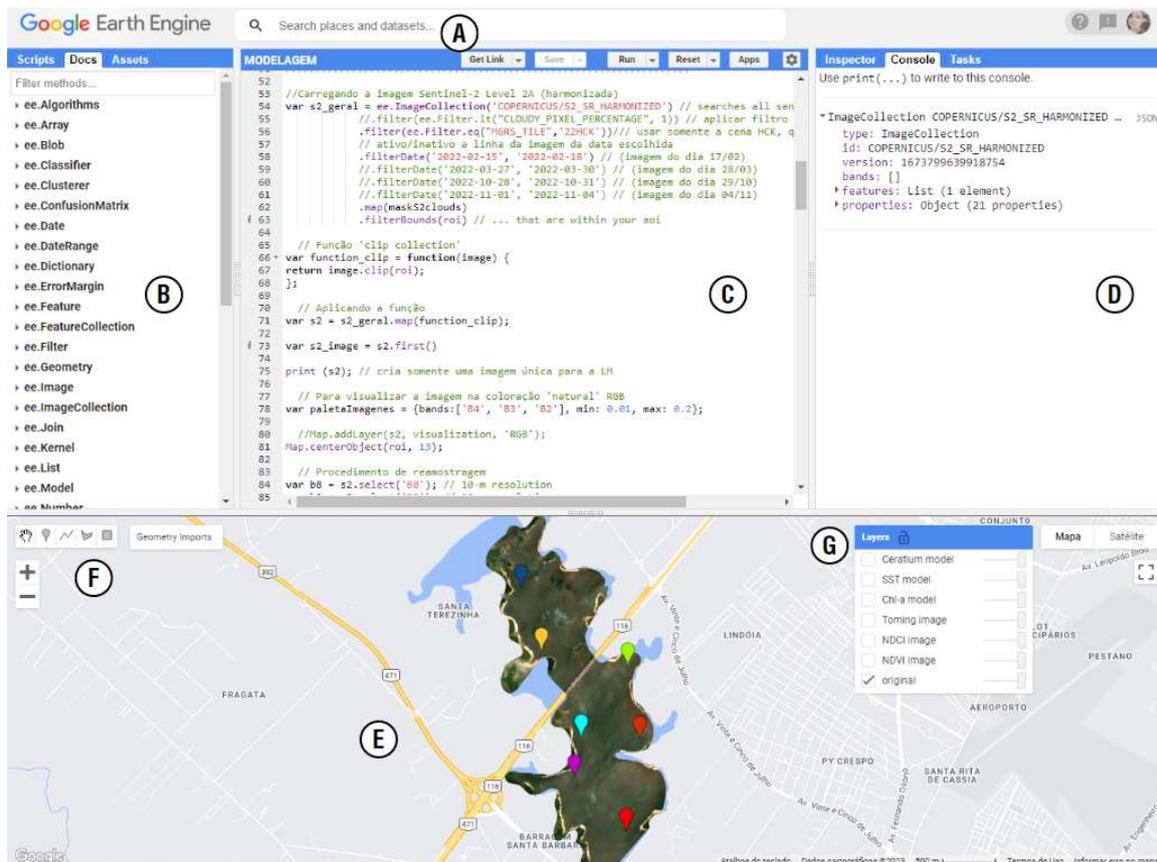


Figura 7 - Ambiente de trabalho GEE (*code editor*) e código para obtenção de imagens Sentinel-2. (A) Mecanismo de pesquisa; (B) painel das funções pré-estabelecidas da API; (C) painel de programação para o usuário gerar seus *scripts*; (D) console no qual são exibidos apenas os resultados; (E) painel de exibição no qual são mostrados os mapas gerados; (F) ferramentas de desenho para selecionar uma região de interesse através de um ponto, uma linha ou um polígono; (G) camadas ativas e inativas na visualização.

O poder computacional da plataforma junto com seu abrangente catálogo de dados e métodos de processamento de dados fazem do GEE permite que pesquisadores e profissionais se concentrem no desenvolvimento e solução de seus problemas de domínio, facilitando a recuperação de dados e algoritmos e a computação em um só lugar. Por exemplo, os arquivos Landsat e Sentinel já são pré-processados para efeitos atmosféricos e topográficos - isso economiza tempo e

esforço substancial de pesquisadores e profissionais em termos de download e pré-processamento de dados (TELUGUNTLA *et al.*, 2018; WANG *et al.*, 2020).

De acordo com Hird *et al.* (2017), o monitoramento de recursos hídricos por GEE é promissor, pois oferece acesso a um grande banco de dados de imagens de vários satélites (por exemplo, programas Sentinel e Landsat) permitindo análises temporais em grandes áreas. Cairo *et al.* (2019) usaram o GEE para mapear a concentração de Chl-a e sua dinâmica temporal em um reservatório tropical brasileiro, em São Paulo, mostrando sua capacidade de monitorar a abundância de fitoplâncton usando imagens de satélite.

## 4 Materiais e Métodos

A descrição que segue dos procedimentos que foram utilizados no desenvolvimento desta pesquisa é fundamental para a apropriada compreensão de suas concepções. A estrutura segue as etapas clássicas utilizadas em trabalhos correlatos para o desenvolvimento do monitoramento de componentes via sensoriamento remoto em águas interiores.

Assim, a metodologia foi dividida em três principais linhas, as quais estão apresentadas de forma simplificada no fluxograma da Figura 8. As duas primeiras linhas, que são a obtenção dos dados de campo e a aquisição de informações por sensoriamento remoto, ocorreram de maneira simultânea e a terceira teve como objetivo correlacionar os resultados das duas anteriores.

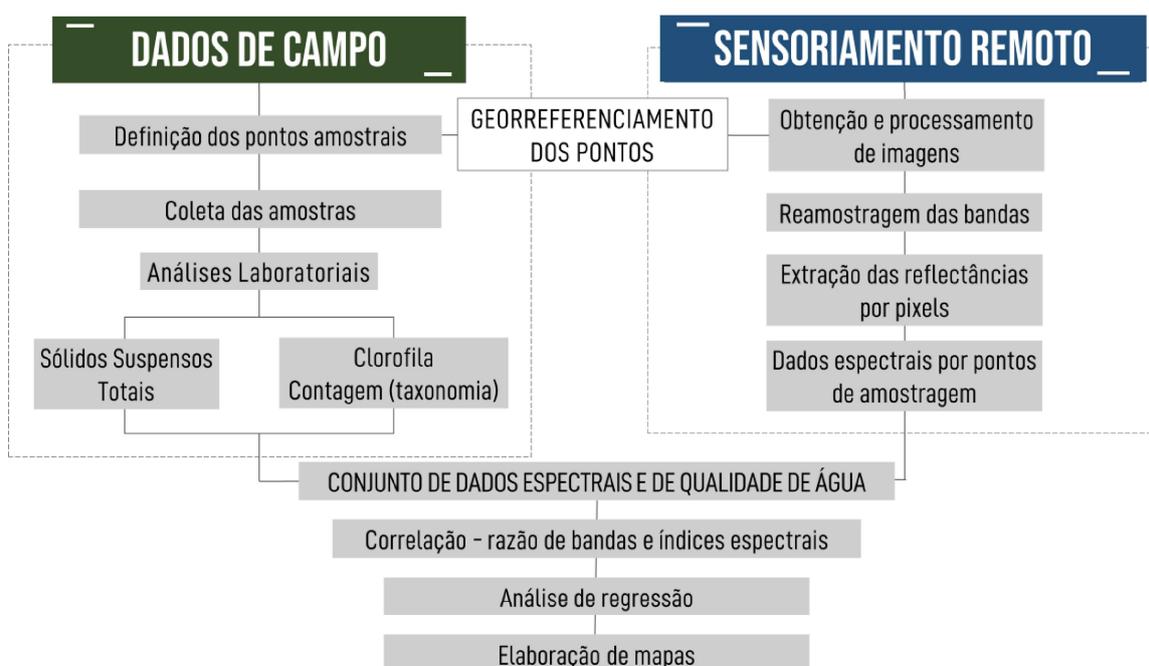


Figura 8 – Esquema metodológico seguindo duas linhas concomitantemente – a obtenção de dados de campo e de sensoriamento remoto.

O trabalho foi realizado em parceria com o Serviço Autônomo de Saneamento de Pelotas (RS), SANEP, autarquia responsável pelos serviços de saneamento básico definidos na Lei 11.445/2007 (BRASIL, 2007). Todas as análises e ensaios foram realizados no Laboratório de Hidrobiologia da Divisão de Laboratório (DLA) da própria estação de tratamento das águas da Barragem (ETA Santa Bárbara).

#### 4.1 Caracterização da área de estudo – Barragem Santa Bárbara

A cidade de Pelotas, RS, com população estimada em 343826 habitantes (IBGE, 2021), encontra-se às margens do Canal São Gonçalo, que liga a Laguna dos Patos e a Lagoa Mirim, onde deságua o principal reservatório de abastecimento atual da cidade – a Barragem Santa Bárbara (SIMON; TRENTIN; CUNHA, 2010). Construída na década de 1960 pelo Departamento Nacional de Obras e Saneamento (DNOS) através do fechamento do Arroio Santa Bárbara para evitar cheias na área urbana de Pelotas e proporcionar reserva para abastecimento público de água potável, a Barragem Santa Bárbara está localizada na porção sudoeste do município (KORB; SUERTEGARAY, 2014), como mostra a Figura 9.

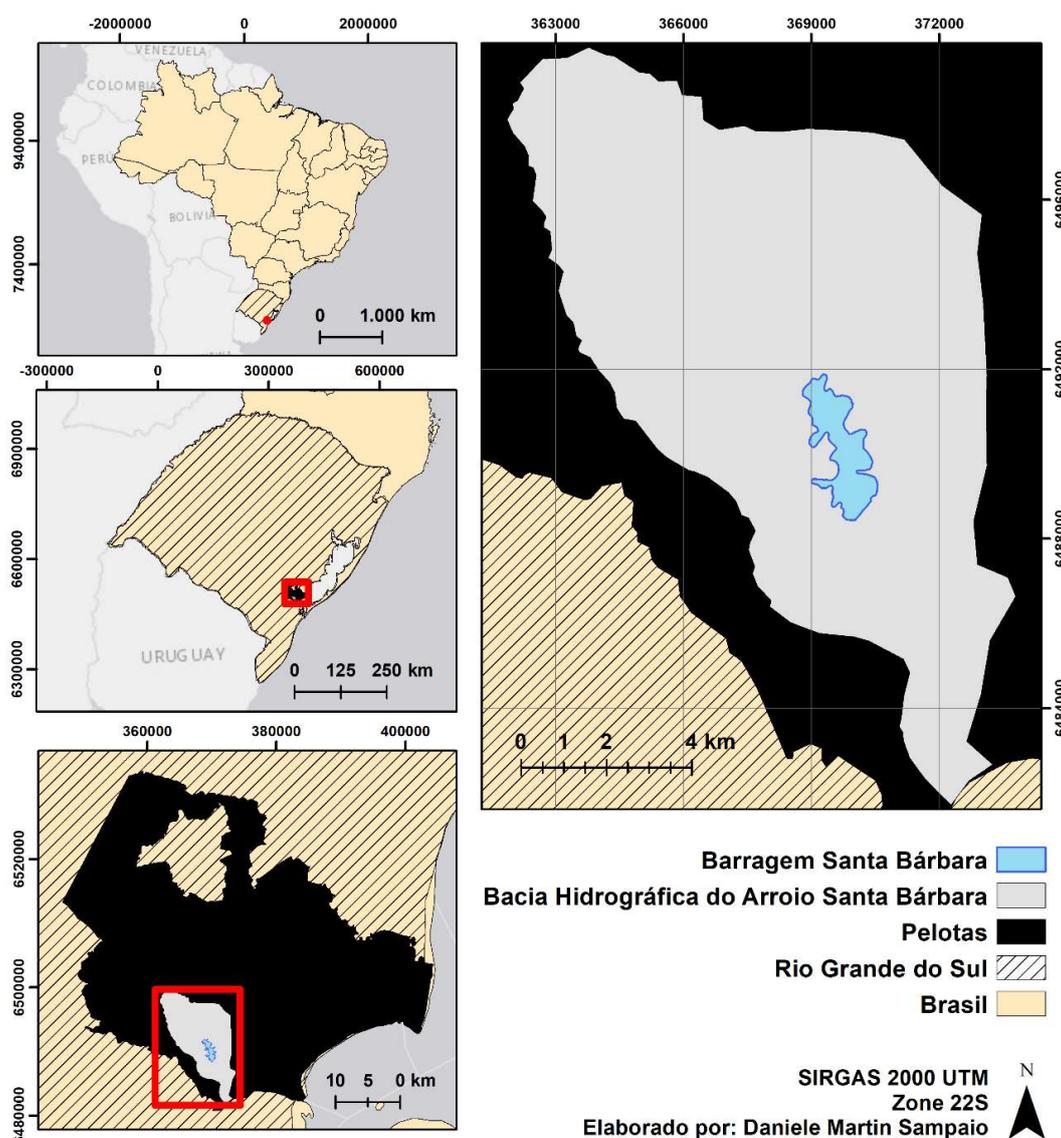


Figura 9 – Localização da Barragem Santa Bárbara – Pelotas (RS).

A Barragem Santa Bárbara tem como afluentes diversos pequenos arroios, que, por sua vez, recebem despejos agrícolas, industriais, domésticos e servem como sistema de drenagem de águas pluviais por onde passam, conduzindo todos esses efluentes à bacia de acumulação da barragem (PIEDRAS *et al.*, 2006). Para uma melhor análise geral da qualidade da água da Barragem, um estudo do uso e cobertura da sua área de drenagem, representada pela Bacia Hidrográfica do Arroio Santa Bárbara, foi elaborado. As características da bacia hidrográfica estão apresentadas na Tabela 2, conforme levantado por Xavier (2017).

Tabela 2 – Parâmetros morfológicos da Bacia Hidrográfica do Arroio Santa Bárbara, no município de Pelotas – RS.

<b>Parâmetro</b>	<b>Unidade</b>	<b>Valor</b>
Ordem hierárquica, segundo Strahler	-	4
Forma da bacia	-	Retangular
Fator de forma	A L <sup>-2</sup>	0,358
Comprimento do canal principal	km	17,51
Área da Bacia	km <sup>2</sup>	109,74
Perímetro da bacia	km	64,19
Declividade média do canal Principal	graus	0,37
Densidade de drenagem total	km km <sup>-2</sup>	1,39

Fonte: Adaptado de Xavier, 2017.

Para o levantamento das informações de uso e cobertura, foi utilizado uma ferramenta do projeto MapBiomias para *Google Earth Engine*. Esse projeto disponibiliza cenas com resolução espacial de 30 m e banda única, referente ao mapeamento de uso e cobertura de solo para o Brasil e algumas regiões vizinhas ao sul do país que são baseadas em mosaicos Landsat (MAPBIOMAS, 2023). O resultado está apresentado na Figura 10 e uma comparação dos usos e suas respectivas coberturas no gráfico da Figura 11.

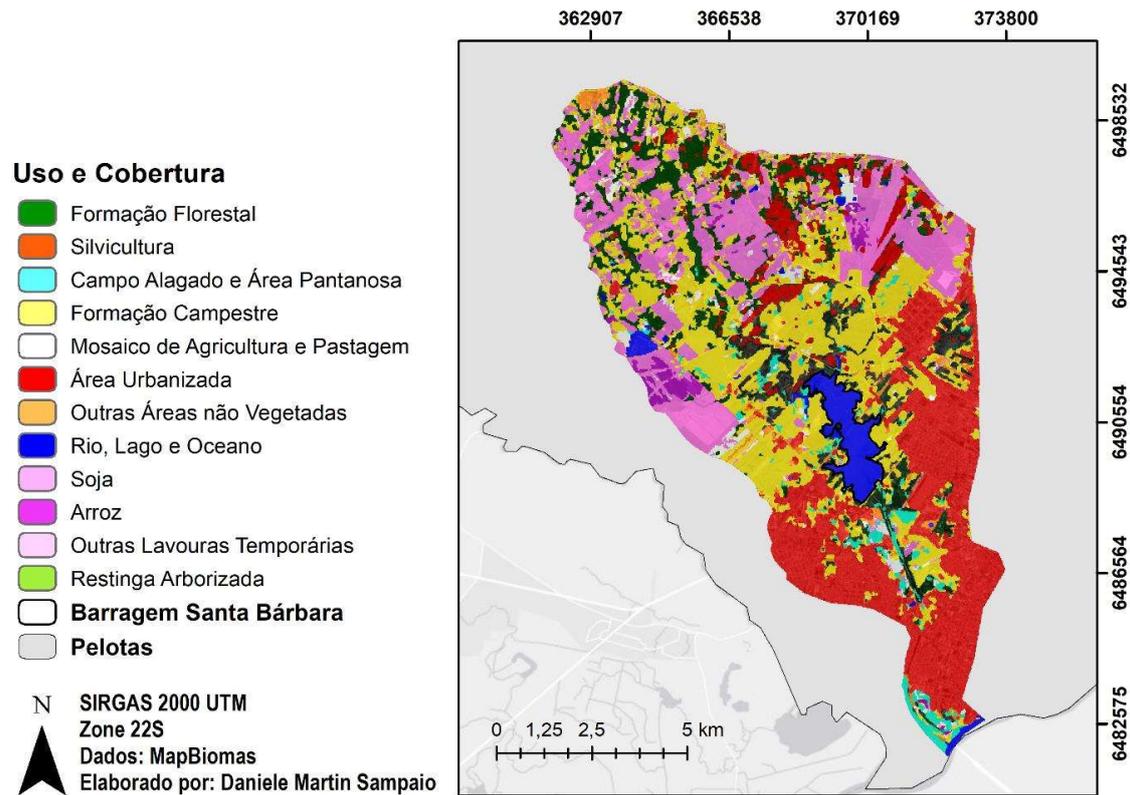


Figura 10 – Uso e cobertura da Bacia Hidrográfica do Arroio Santa Bárbara.  
Fonte: MAPBIOMAS, 2023.

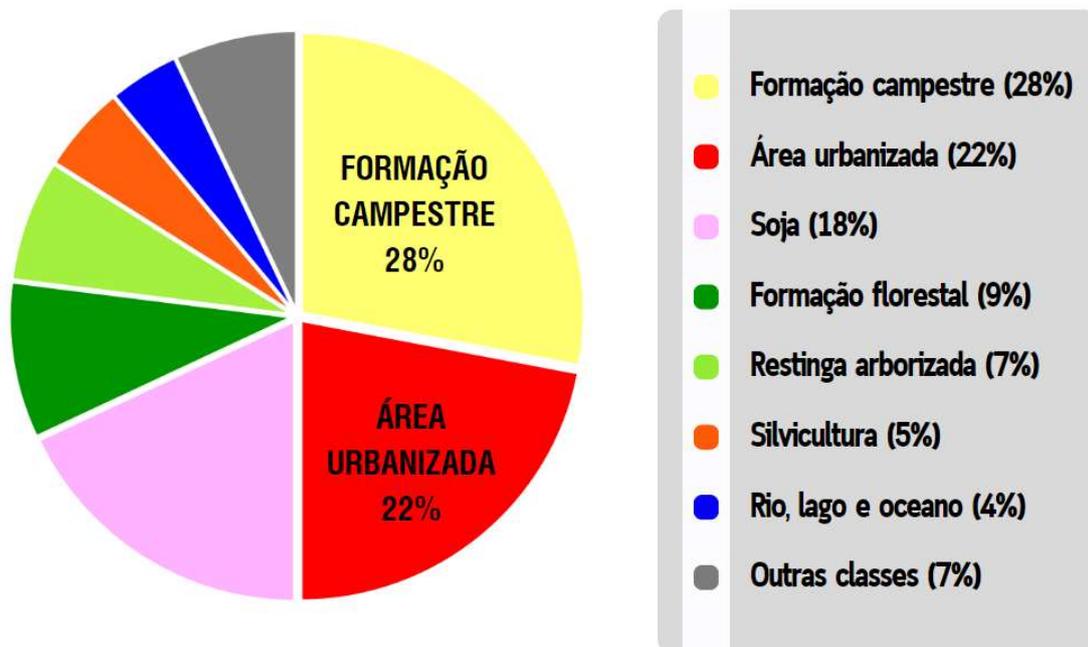


Figura 11 – Gráfico com os maiores índices de uso e cobertura da região da Bacia Hidrográfica do Arroio Santa Bárbara.  
Fonte: MAPBIOMAS, 2023

Conforme o gráfico, ocorre uma predominância de formações campestres e áreas urbanizadas. Corroborando, o trabalho de KORB e SUERTEGARAY (2014) traz a caracterização do entorno do reservatório como um local de expansão urbano-industrial (bairros urbanos, ocupações irregulares, distrito industrial) e de atividades agropecuárias.

## **4.2 Obtenção de dados de campo**

O conjunto de dados *in situ* da Barragem Santa Bárbara foi gerado em 7 campanhas de monitoramento e 8 pontos amostrais, totalizando 56 amostras. Para as coletas das amostras, foi utilizado um bote de casco de alumínio, com motor de 5 HP de potência da marca Kawashima. Os dias de coleta de amostras de água foram sincronizados com a passagem do satélite Sentinel-2 na área de interesse. O motivo da sincronização da coleta de dados foi garantir a comparabilidade dos dados de satélite e terrestres (TOMING *et al.*, 2016).

Os pontos amostrais foram localizados com um receptor de Sistema de Posicionamento Global (GPS), modelo Garmin Etrex – 30X com resolução de posicionamento de até 3 metros, e as regiões estabelecidas estão representadas na Figura 12. Os pontos de amostragem foram distribuídos sobre a área superficial do reservatório priorizando locais estratégicos: as entradas dos principais afluentes (pontos 1, 2 e 3), locais próximos de áreas urbanas (região próxima ao Centro de Distribuição da Cervejaria AMBEV e ao Turist Park Hotel – pontos 4 e 5, respectivamente), um ponto intermediário (ponto 6), um ponto próximo ao barramento do reservatório (ponto 7) e o ponto de captação para abastecimento da ETA Santa Bárbara (ponto 8).

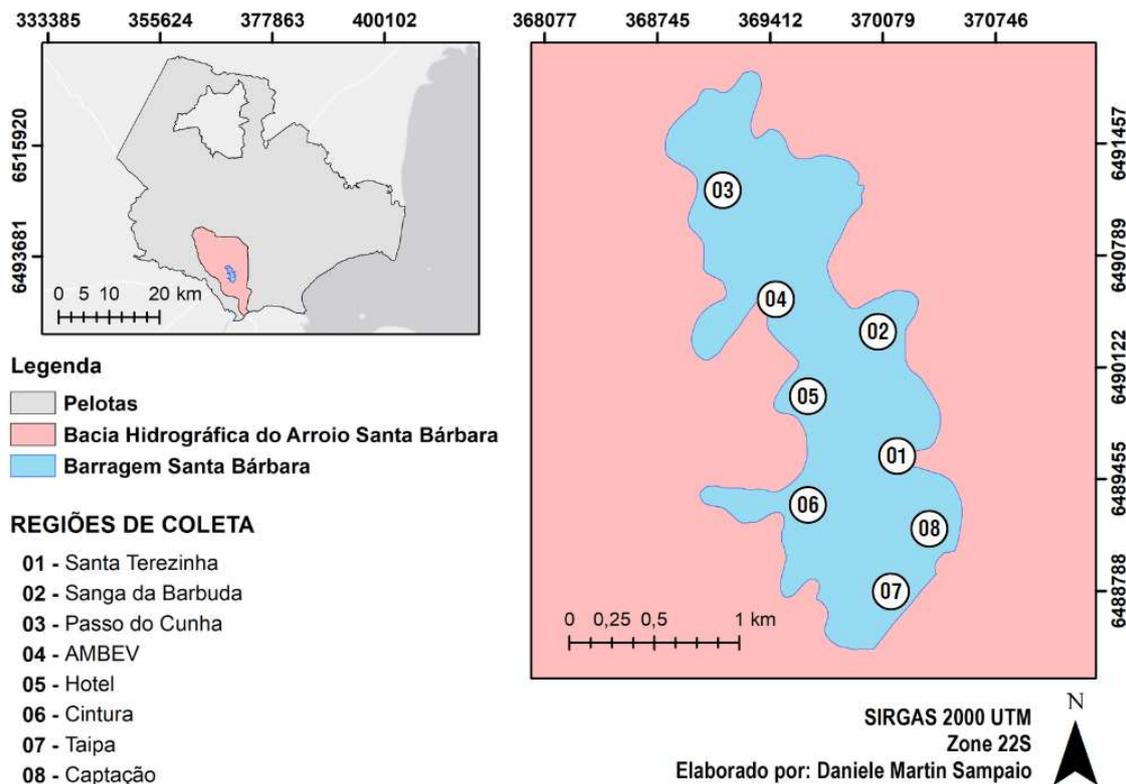


Figura 12 – Localização das regiões estabelecidas para as coletas das amostras

Em laboratório, a concentração de clorofila-a e a concentração de sólidos suspensos totais das amostras de água foram determinadas seguindo o método padrão da *American Public Health Association* (APHA, 2012). Além das análises químicas, também foi levantado o nível do manancial em cada dia da coleta para ajudar na discussão dos resultados. A coleta das amostras usadas para determinação de clorofila e sólidos suspensos totais foi feita utilizando frascos escuros para não haver degradação dos pigmentos, conforme mostra a Figura 13. Os demais frascos foram utilizados para coleta de amostras usadas na identificação e quantificação dos organismos fitoplanctônicos.

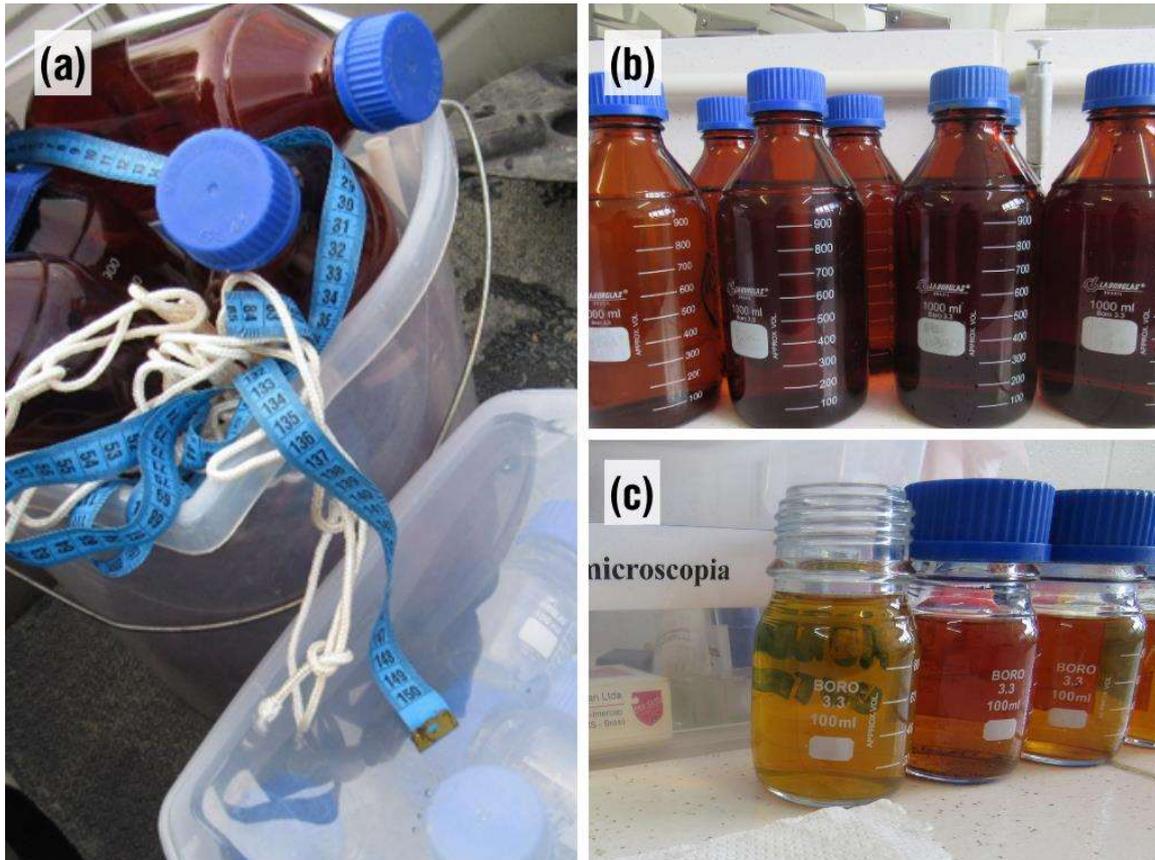


Figura 13 – (a) Frascos de amostragem (b) para análises de Chl-a e SST e (c) para a quantificação de fitoplâncton.

Fonte: Arquivo pessoal.

Para determinação de Chl-a, as amostras de água foram filtradas usando um filtro de fibra de vidro do fabricante *Whatman* GF/F, com diâmetro de 47mm, pré-lavado e depois extraídas em acetona a 90%, conforme Figura 14. O teor de Chl-a dos extratos foi determinado utilizando o Espectrofotômetro UV-VIS DR6000 da empresa HACH.

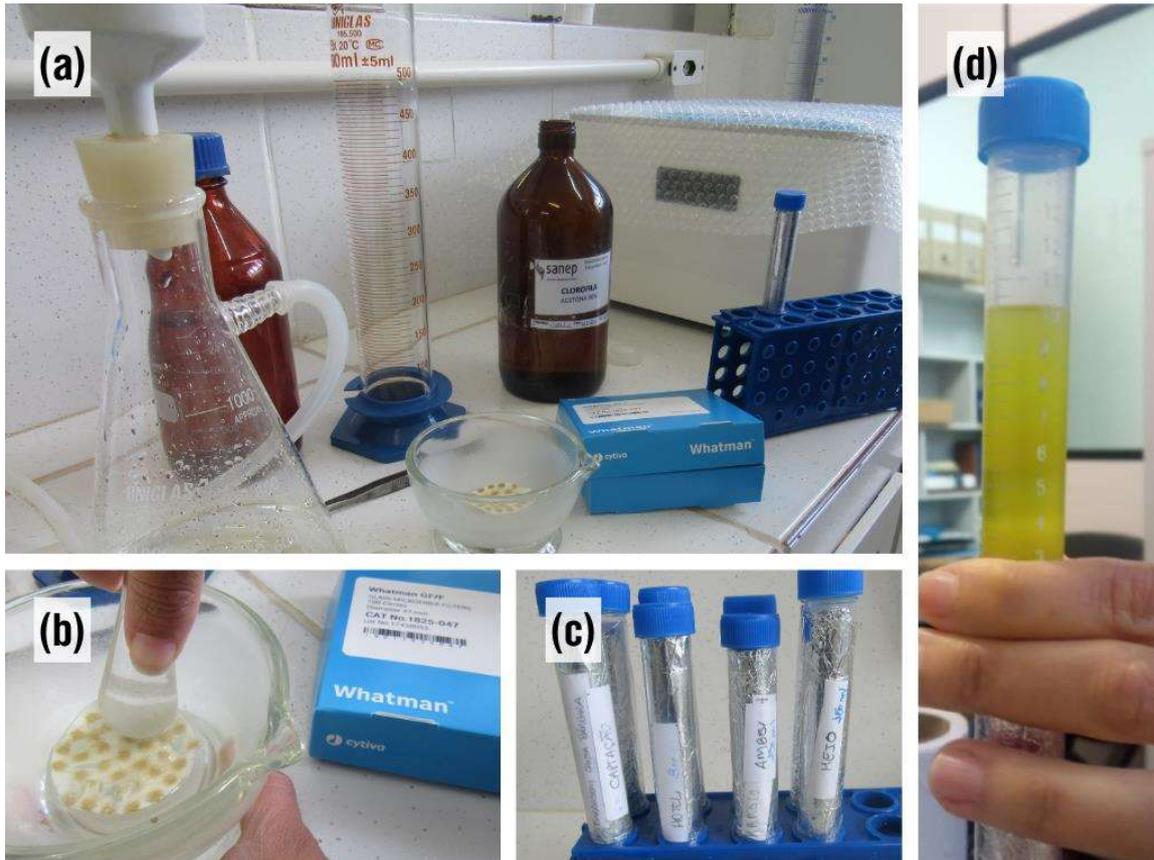


Figura 14 – Etapas da análise de Chl-a: (a) filtração, (b) extração com acetona, (c) armazenamento dos extratos sem contato com a luz e (d) extrato a ser lido no espectrofotômetro.  
Fonte: Arquivo pessoal.

Para o cálculo da concentração de Chl-a, em  $\mu\text{g L}^{-1}$ , foi levado em consideração as medições do espectrofotômetro, o volume de pigmentos extraídos e o volume filtrado. A equação (1) utilizada segue abaixo, na qual  $A$  é absorvância em 664 e 750 nm; 26,7 é constante;  $V$  é o volume de acetona utilizado;  $S$  é volume de água filtrada.

$$\text{Clorofila - a } (\mu\text{g L}^{-1}) = \frac{26,7 \times (A_{664} - A_{750}) \times 100 \times V}{S} \quad (1)$$

Para a análise de sólidos suspensos totais por gravimetria, foi utilizado o Filtro de Microfibra de Vidro do fabricante *Whatman*, classe 934-AHTM, com diâmetro de 110 mm (APHA, 2012), conforme Figura 15.



Figura 15 – (a) Etapa de filtração, (b) filtros utilizados e (c) resultado pós secagem na análise de SST. Fonte: Arquivo pessoal.

A identificação dos organismos fitoplanctônicos em categorias taxonômicas específicas foi realizada em nível genérico de acordo com BICUDO; MENEZES (2017), SANT'ANNA (2006) e FRANCESCHINI *et al.* (2010), e infragenérico utilizando bibliografia especializada.

Para a identificação e quantificação dos organismos presentes na amostra, foram utilizadas as metodologias de contagem descrita por Sedgewick-Rafter (BRANCO, 1978), expressa em número de células por volume de amostra. Para essa análise, apresentada na Figura 16, as amostras são conservadas com lugol, adicionadas à câmara de Sedgewick-Rafter e a contagem ocorre utilizando microscópio. Conhecendo-se o volume de amostra e a área da lamínula, a quantidade de cada gênero de fitoplâncton presente foi determinada. Imagens de alguns dos organismos do gênero *Ceratium*, identificados nas amostras, estão dispostas na Figura 17.

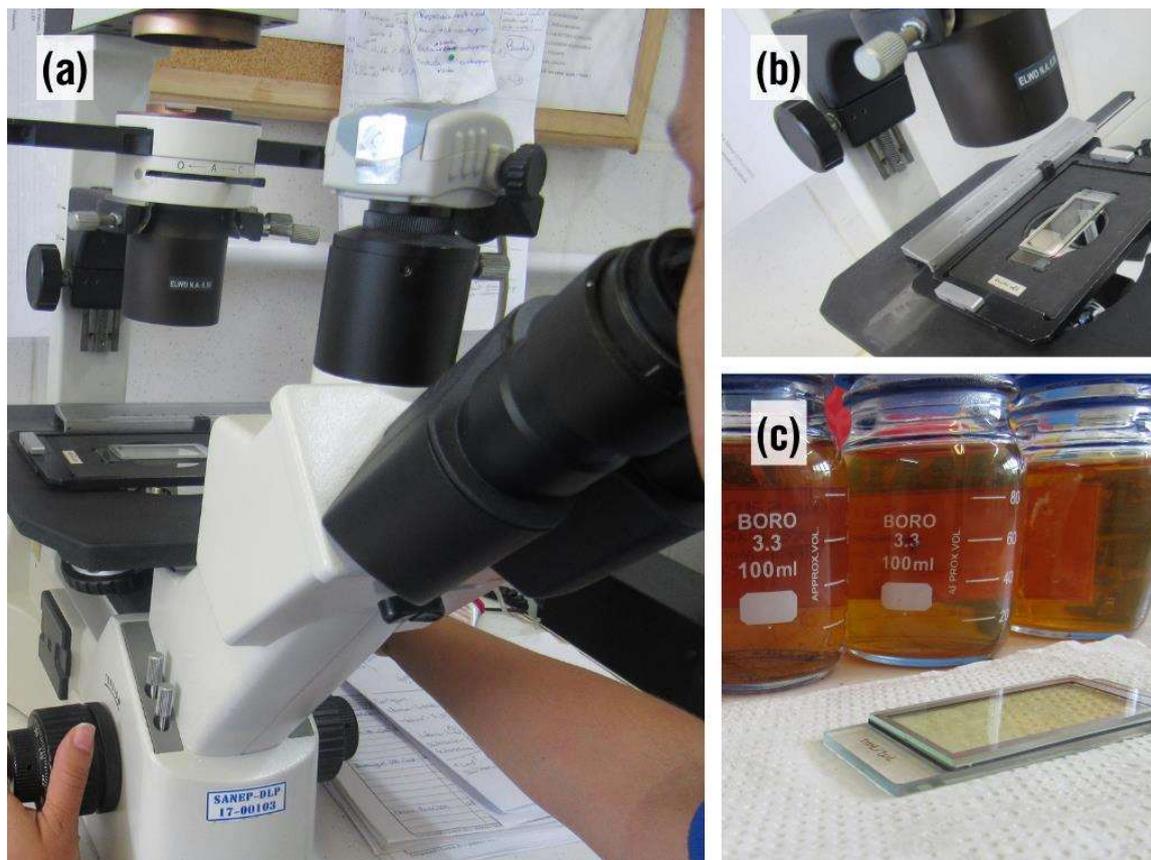


Figura 16 – (a) Análise de quantificação de organismos do gênero *Ceratium*, (b) aparelhagem utilizada e (c) amostras conservadas com lugol e adicionadas a câmara de Sedgwick-Rafter.  
Fonte: Arquivo pessoal.

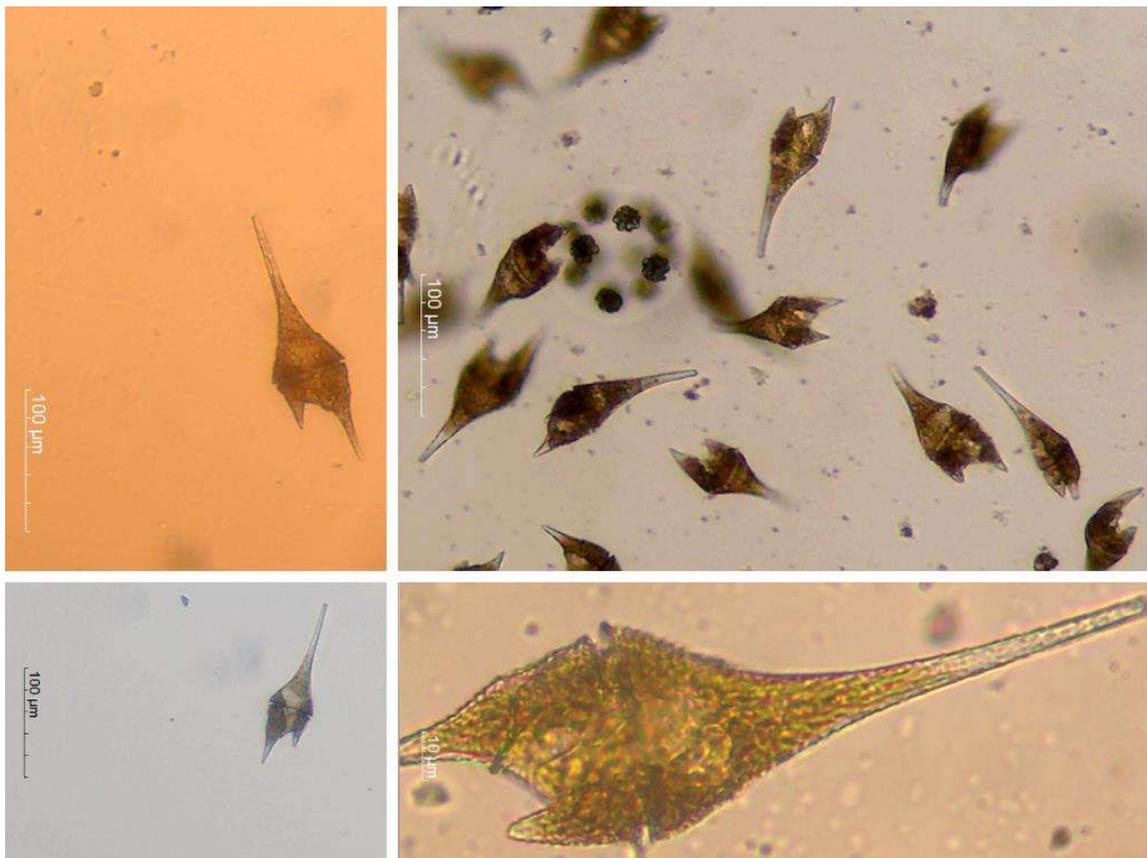


Figura 17 – Organismos do gênero *Ceratium* identificados nas amostras coletadas na pesquisa.  
Fonte: Arquivo pessoal.

Para avaliação das variáveis obtidas na pesquisa foi utilizada uma análise estatística descritiva, abrangendo os parâmetros média, mediana, amplitude, valores mínimos e máximos, desvio padrão e coeficiente de variação.

Além disso, foram medidos valores de temperatura do ar e da água no momento das coletas, utilizando-se termômetro de mercúrio com precisão de 0,5°C, e o nível do manancial utilizando uma régua localizada na própria barragem.

#### 4.3 Processamento de imagem e extração de dados espectrais

Neste estudo, foram utilizados os produtos de dados Sentinel Level-2A (L2A) harmonizados e corrigidos atmosféricamente disponíveis na plataforma GEE (*COPERNICUS/S2\_SR\_HARMONIZED*), adquiridos de acordo com as datas das coletas *in situ*. O produto L2A fornece reflectância de superfície ortorretificada corrigida atmosféricamente, que é baixado do scihub e com correção atmosférica via Sen2cor. A utilização dos produtos harmonizados segue a recomendação da própria

plataforma (Google Earth Engine Data Catalog, 2023). O Sentinel-2 disponibiliza online imagens processadas e prontas para uso (BARRAZA-MORAGA *et al.*, 2022).

O primeiro passo foi mascarar os pixels com nuvens aplicando o produto *COPERNICUS/S2\_CLOUD\_PROBABILITY*, disponível no GEE. Este é um produto criado usando o detector de nuvens do Sentinel Hub (pacote *s2cloudless*), que fornece detecção automatizada de nuvens para imagens do Sentinel-2. O conjunto de dados *s2cloudless* fornece um método flexível para mascarar com precisão pixels nublados em imagens de nível 1C e 2A para gerar compostos sem nuvens. Ao unir o algoritmo do Sentinel Hub com os recursos de computação do Google, foi calculada a probabilidade de nuvem por pixel para todo o arquivo Sentinel-2. Apenas os pixels com probabilidade de nuvem inferior a 10% foram incluídos nas etapas a seguir.

Como as imagens contêm números de 16 bits que vão até 65535, foi aplicado um fator de 1/10000 nos valores de pixel para obter um valor capaz de armazenar e manipular, conforme Ivanda *et al.* (2021). Para manter a consistência e facilitar os cálculos, as bandas das imagens com resolução de 20 m foram reamostradas para 10 m usando método de interpolação bilinear, para que as informações mais espacialmente resolvidas do Sentinel-2 não fossem perdidas (LI *et al.*, 2017). As três bandas de 60 m do Sentinel-2, com comprimentos de onda central de 442 nm (B1), 490 nm (B9) e 1375 nm (B10), não foram usadas, pois são projetadas para triagem de nuvens e correção atmosférica e não para monitoramento de superfície (LI *et al.*, 2020).

A cobertura frequente de nuvens geralmente impede a obtenção de imagens adequadas (LI *et al.*, 2021). A variabilidade sazonal do regime de nebulosidade na região estudada representa um desafio para o sensoriamento remoto (MARTINS *et al.*, 2018). Para uma análise exploratória da nebulosidade, foram considerados os dados de porcentagem de cobertura nuvens dos produtos utilizados no estudo, obtidos pelas próprias propriedades de cada imagem. Para uso nesse trabalho, foram considerados como dados úteis o grupo de imagens com porcentagem de nuvens menor do que 1%.

Devido à presença de nuvens, as imagens nem sempre forneceram dados para combinação com os dados *in situ*. Portanto, devido ao reduzido número de imagens úteis disponíveis para o período e dificuldade de coleta de barco por condições adversas de tempo, o que acabou reduzindo o número de pontos utilizados para as relações com o sensoriamento remoto, optou-se pela utilização de imagens do

Sentinel-2 com no máximo 7 dias de diferença entre a passagem do satélite e a data da coleta. Essa janela também foi considerada pelos autores Li *et al.* (2021). Corroborando, Toming *et al.* (2016) confirmaram que a janela de tempo de vários dias pode ser utilizada. Um compilado com as porcentagens de nebulosidade, os dados das imagens e as diferenças de dias entre as coletas está apresentado na Tabela 3.

Tabela 3 – Referências de imagem do Sentinel-2, datas de coleta e imagem, diferença de dias e porcentagem de nuvens. Em negrito, as imagens utilizadas para obtenção dos dados espectrais.

Data		ID da imagem	Diferença de dias	% Nuvens
Coleta	Imagem			
10/02/2022	06/02/2022	20220206T133219_20220206T133218_T22HCK	4	68%
	11/02/2022	20220211T133221_20220211T133524_T22HCK	1	20%
<b>17/02/2022</b>	<b>16/02/2022</b>	<b>20220216T133219_20220216T133218_T22HCK</b>	<b>1</b>	<b>0,35%</b>
03/03/2022	26/02/2022	20220226T133219_20220226T133220_T22HCK	5	30%
	03/03/2022	20220303T133231_20220303T134003_T22HCK	0	17%
07/03/2022	08/03/2022	20220308T133219_20220308T133222_T22HCK	1	73%
	13/03/2022	20220313T133231_20220313T133843_T22HCK	6	96%
<b>28/03/2022</b>	<b>28/03/2022</b>	<b>20220313T133231_20220313T133843_T22HCK</b>	<b>0</b>	<b>0,01%</b>
11/04/2022	12/04/2022	20220412T133231_20220412T133451_T22HCK	1	44%
	17/04/2022	20220417T133219_20220417T133220_T22HCK	6	70%
	<b>29/10/2022</b>	<b>20221029T133151_20221029T133226_T22HCK</b>	<b>7</b>	<b>0,01%</b>
<b>04/11/2022</b>	03/11/2022	20221103T133149_20221103T133143_T22HCK*	1	0,04%
	08/11/2022	20221108T133151_20221108T133324_T22HCK	4	39%

\* imagem visivelmente prejudicada.

A extração dos pixels da imagem foi realizada considerando a mediana de uma janela de 3x3 pixels, com a coordenada do ponto amostral sendo o pixel central, a fim de remover algum ruído e variabilidade inter-pixel (CABALLERO; STUMPF, 2020). Os dados espectrais foram divididos em três conjuntos de variáveis:

- (i) Reflectâncias da superfície  $\rho_w$  – utilizadas 10 bandas do Sentinel-2 (B2, B3, B4, B5, B6, B7, B8, B8a, B11 e B12), que variam de comprimentos de onda visível e infravermelho próximo (NIR) a infravermelho de ondas curtas (SWIR);
- (ii) *Razões de banda* - foram avaliadas aquelas relações com desempenho satisfatório em águas opticamente complexas (HA *et al.*, 2017a),

incluindo uma razão de banda verde-azul ( $B3/B2$ ), uma razão de banda verde-vermelho ( $B3/B4$ ), cinco relações NIR-banda vermelha ( $B5/B4$ ,  $B6/B4$ ,  $B7/B4$ ,  $B8a/B4$  e  $B8/B4$ ) e uma relação de três bandas ( $(B5 + B6)/B4$ ).

- (iii) *Índices espectrais* – 9 índices (Tabela 4), os quais incluem índices de vegetação (que são sensíveis a Chl-a) e índices de água (que são sensíveis a SST), foram calculados para recuperar indiretamente as variáveis através da intercorrelação entre as características alvo, a fim de melhorar a capacidade de previsão (SABERIOON *et al.*, 2020).

Tabela 4 - Detalhes dos índices espectrais calculados.

Índice	Baseado no MSI/Sentinel-2	Referência
NDCI	$(B5 - B4)/(B5 + B4)$	(MISHRA; MISHRA, 2012)
NDVI	$(B8 - B4)/(B8 + B4)$	(ROUSE JR <i>et al.</i> , 1973)
NDWI1	$(B3 - B8)/(B8 + B3)$	(MCFEETERS, 2007)
NDWI2	$(B8 - B11)/(B8 + B11)$	(GAO, 1996)
NDWI3	$(B8 - B12)/(B8 + B12)$	(GAO, 1996)
NDWI4	$(B8 - B11)/(B8 + B12)$	(GAO, 1996)
NDWI5	$(B8 - B12)/(B8 + B11)$	(GAO, 1996)
NSMI	$(B4 + B3 - B2)/(B4 + B3 + B2)$	(HAUBROCK <i>et al.</i> , 2010)
Índice de Toming	$B5 - \frac{B4/B6}{2}$	(TOMING <i>et al.</i> , 2016)

O NDCI (*Normalized difference chlorophyll index*) é projetado para prever a concentração de Chl-a a partir de dados de sensoriamento remoto em águas turvas produtivas estuarinas e costeiras (MISHRA; MISHRA, 2012).

O NDVI (*Normalized Differences Vegetation Index*) é um índice adimensional que descreve a diferença entre a reflectância visível e infravermelha próxima da cobertura vegetal (ROUSE JR *et al.*, 1973).

O NDWI (*Normalized Difference Water Index*), proposto por McFeeters (2007), é projetado para: (1) maximizar a reflectância do corpo d'água na faixa verde; e (2) minimizar a reflectância do corpo d'água na banda NIR. Os índices NDWI2, NDWI3, NDWI4 e NDWI5, como Saberioon *et al.* (2020) apontaram, são índices de água que

têm o SWIR e, com isso, contribuem parcialmente para a recuperação bem-sucedida de SST e Chl-a em águas de alta turbidez, porque eles provaram ser confiáveis para correção atmosférica.

O NSMI (*Normalized Suspended Material Index*) é um índice usado para obter o modelo de SST. Os valores gerados variam entre -1 e 1, onde valores menores indicam a presença de águas mais claras (HAUBROCK *et al.*, 2010).

O índice estudado por Toming *et al.* (2016) é baseado na estimativa de Chl-a utilizando a altura do pico de reflectância de Chl-a entre 700 e 720 nm. Assim, esse índice calcula a altura do pico da banda 5 (705 nm) do Sentinel-2 em relação às linhas de base da banda 4 (665 nm) e da banda 6 (740 nm).

#### 4.4 Integração de dados de campo e de sensoriamento remoto

A integração das coletas de campo e de sensoriamento remoto foi realizada utilizando o conjunto dos dados das três campanhas as quais se obteve dados espectrais. Além disso, foram excluídos *outliers* que, por serem valores discrepantes à distribuição de dados, poderiam estar prejudicando as correlações e as regressões. Neste caso, foi considerado como critério de seleção de outliers aqueles que se encontravam fora dos limites apresentados no *boxplot* de cada coleta e parâmetro, ou seja, valores fora do *range* entre o menor e o maior valor coletado dentro das amplitudes interquartis de 1,5 (MONTGOMERY; RUNGER; HUNBELE, 2004).

Para gerar correlações utilizando as bandas do sensor MSI, abordo do Sentinel-2, foi utilizado o coeficiente de correlação de *Spearman Rho* com nível de significância de 5% ( $p < 0,05$ ). Essas correlações foram base para a escolha dos parâmetros utilizados e das combinações utilizadas na elaboração dos modelos.

Para modelagem, foram programadas regressões lineares múltiplas (MLR) no *Jamovi* (versão 2.3.21), um software de acesso gratuito e multiplataforma (disponível para *Linux*, *Mac*, *Windows* e *ChromeOS*) que usa a linguagem de programação R.

A regressão linear múltipla é uma técnica de modelagem estatística que estende a regressão linear simples. Este modelo foi construído para prever uma variável de resposta ( $y$ ) a partir de múltiplas variáveis explicativas ( $x_1, x_2, x_3 \dots x_n$ ). A equação (IVANDA *et al.*, 2021) para o modelo MLR é a seguinte:

$$y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \dots + \beta_nx_n \quad (2)$$

Em que  $y$  é uma variável dependente, que, nesta pesquisa, são as concentrações dos parâmetros estudados no trabalho;  $\beta_0$  é uma constante, geralmente chamada de viés ou interceptação;  $\beta_i$  é um coeficiente de regressão para uma variável independente  $x_n$ ; e  $x_i$  ( $i=1,\dots,n$ ) são variáveis independentes.

As regressões lineares múltiplas foram desenvolvidas usando combinações entre os parâmetros que obtiveram as melhores as correlações existentes entre as concentrações medidas *in situ* e as bandas e razões de bandas das imagens de satélite em diferentes bandas do Sentinel-2. Foram combinados, nas regressões, três conjuntos de dados: (i) apenas valores de bandas; (ii) apenas razões de bandas; e (iii) uma abordagem híbrida, utilizando tanto bandas quanto razões de bandas.

Para geração de um algoritmo bio-óptico para a densidade celular de *Ceratium*, foram utilizados os dados em que apenas esse gênero foi encontrado, para minimizar os erros relacionados a interferência da clorofila de outras espécies. Um modelo dual foi feito, conforme indicação da literatura: (i) a relação entre a densidade celular e a concentração de Chl-a foi determinada empregando a análise de regressão linear; (ii) foi utilizada a modelagem de clorofila realizada anteriormente.

O erro dos modelos de predição foi avaliado usando a Raiz do Erro Quadrático Médio (RMSE, em inglês). O coeficiente de determinação ( $R^2$ ) também foi medido para mostrar quão bem a variação de uma variável explica a variação no outro. O maior  $R^2$  e o menor valor de RMSE fornecem o melhor modelo de previsão (SABERIOON *et al.*, 2020).

Foram gerados mapas de distribuição espacial para a Barragem Santa Bárbara utilizando os índices espectrais mais bem correlacionados e os modelos bio-ópticos mais bem avaliados para representar de Chl-a, de SST e de densidade celular de *Ceratium*. Os modelos foram programados e executados na plataforma GEE e o código desenvolvido está no final da pesquisa, no Apêndice A. O layout final dos mapas foi realizado usando o software *ArcGIS*.

## 5 Resultados e Discussão

### 5.1 Estatística descritiva da qualidade da água

Os resultados estatísticos descritivos de Chl-a e SST de todas as campanhas de coleta, incluindo o número de pontos, o nível do manancial, média, mínimo, máximo, desvio-padrão e coeficiente de variação (CV) são mostrados na Tabela 5. Esses dados serviram de suporte para geração das correlações e dos modelos de predição de clorofila-a e sólidos suspensos totais.

Tabela 5 – Estatística descritiva dos teores de clorofila e sólidos suspensos totais da água para cada uma das sete campanhas de amostragem na Barragem Santa Bárbara e valores da temperatura do ar, temperatura da água e do nível do manancial para as respectivas datas de coleta.

Data de coleta	Análise	Média	Desvio-padrão	CV	Min	Max	T (ar)	T (água)	Nível
10-fev-22	Chl-a	397	382	137%	82,3	1290	26	25	- 1,68
	SST	22,2	14	84%	8,6	44,4			
17-fev-22	Chl-a	680	236	207%	214	2307	27	27	- 1,80
	SST	28,9	5,63	21%	14,6	66,4			
3-mar-22	Chl-a	674	275	39%	238	1130	27	26	- 2,03
	SST	-	-	-	-	-			
7-mar-22	Chl-a	371	207	59%	60,5	761	25	27	- 1,98
	SST	23,3	2,61	19%	9,6	16,6			
28-mar-22	Chl-a	187	126	89%	53,4	424	24	24	- 2,20
	SST	23,7	5,61	25%	17,2	34,8			
11-abr-22	Chl-a	142	143	211%	21,4	369	22	23	- 2,50
	SST	32,3	6,08	21%	27,2	43,8			
4-nov-22	Chl-a	11,5	2,77	23%	6,41	15,1	23	20	- 0,35
	SST	12,4	0,18	1%	11,6	13,2			

Chl-a – Clorofila-a, em  $\mu\text{g L}^{-1}$ ;

SST – Sólidos suspensos totais, em  $\text{mg L}^{-1}$ ;

T (ar) – Temperatura do ar, em  $^{\circ}\text{C}$ ;

T (água) – Temperatura da água, em  $^{\circ}\text{C}$ ;

Nível – Nível, em metros (m), abaixo da altura normal da Barragem Santa Bárbara.

Média, desvio-padrão, mínimo e máximo – unidade de medida das observações na amostra.

Com base no exposto, pode-se afirmar que a média de teores de sólidos de cada campanha variou de acordo com o nível do manancial, alcançando seu valor máximo de  $32,3 \text{ mg L}^{-1}$  quando o manancial alcançou 2,50 m abaixo do nível normal, e seu valor mínimo de  $12 \text{ mg L}^{-1}$  quando o manancial esteve 0,35 m abaixo do nível normal. Corroborando, Maciel *et al.* (2019), que estudaram parâmetros de qualidade de água do rio Amazonas, mostraram alta dependência entre sólidos em suspensão

e o nível de água. Cabe destaque que o teor de sólidos suspensos totais na campanha do dia 03 de março de 2022 não foi determinado devido a um problema mecânico na balança utilizada na análise.

Para os teores de clorofila-a, as maiores médias ficaram nos meses de fevereiro e março, o que já era esperado já que temperaturas acima de 25°C beneficiam a ocorrência de florações nos ecossistemas aquáticos (SILVA; SOUZA; DUTRA, 2014).

A verificação da existência de *outliers* foi realizada utilizando os gráficos *boxplot* de cada um dos parâmetros avaliados. O gráfico referente à clorofila-a está apresentado na Figura 18 e referente aos sólidos suspensos totais na Figura 19.

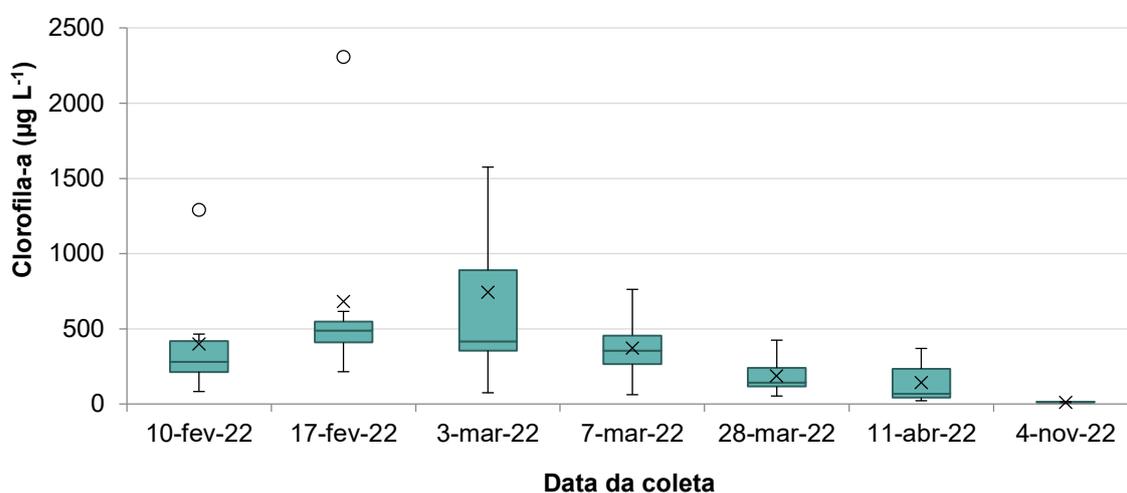


Figura 18 – *Boxplot* para os resultados de clorofila-a.

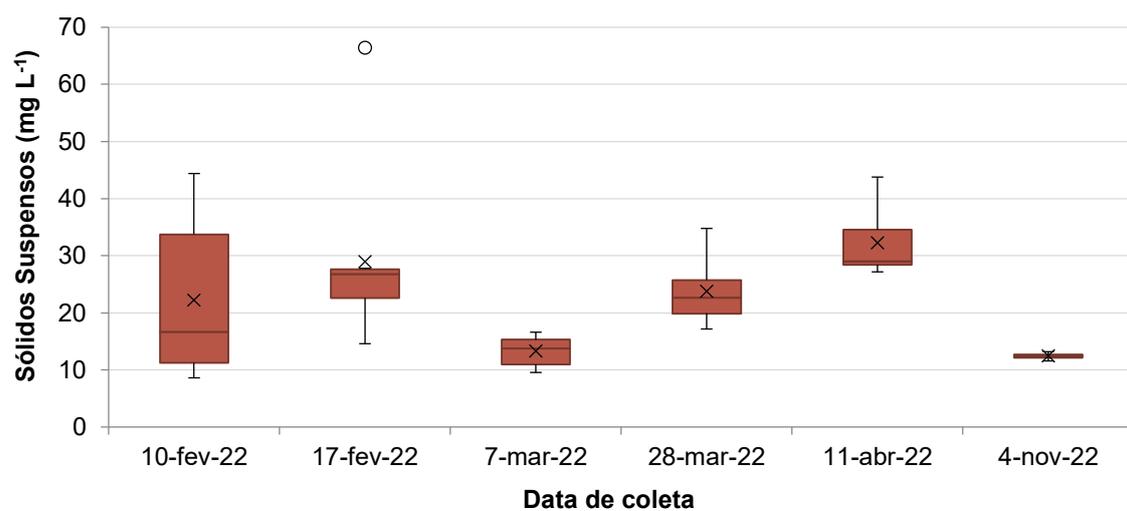


Figura 19 – *Boxplot* para os resultados de sólidos suspensos totais.

Os gráficos acima mostram nitidamente que Chl-a e SST tiveram os menores valores de CV em novembro, o que mostra que suas distribuições são mais homogêneas em novembro do que em outras datas. Nota-se a presença de *outliers* de clorofila-a nas campanhas de 10/02/2022 e de 17/02/2022 e de sólidos suspensos totais apenas na campanha de 17/02/2022. Esses dados foram excluídos para as análises que seguem, a fim de melhorar as relações com o sensoriamento remoto.

## 5.2 Processamento de imagens e correlações

Como primeiro resultado, tem-se os mapas gerados a partir das imagens Sentinel-2 L2A, já corrigidas para valores de reflectância de superfície (Figura 20). Conforme abordado no Capítulo 4, o qual descreve os materiais e métodos, apenas imagens sem cobertura de nuvens foram selecionadas, resultando em um conjunto de três imagens – dias 16/02/2022, 28/03/2022 e 29/10/2022 – e três campanhas de campo – dias 17/02/2022, 28/03/2022 e 04/11/2022, totalizando 23 registros de Chl-a e SST após a exclusão do *outlier* de 17/02/2022. A Tabela 6 mostra os valores médios, mínimos e máximos, por análise, das campanhas utilizadas e após a exclusão do *outlier*. As imagens passaram por tratamentos idênticos de reamostragem e correção de nuvens.

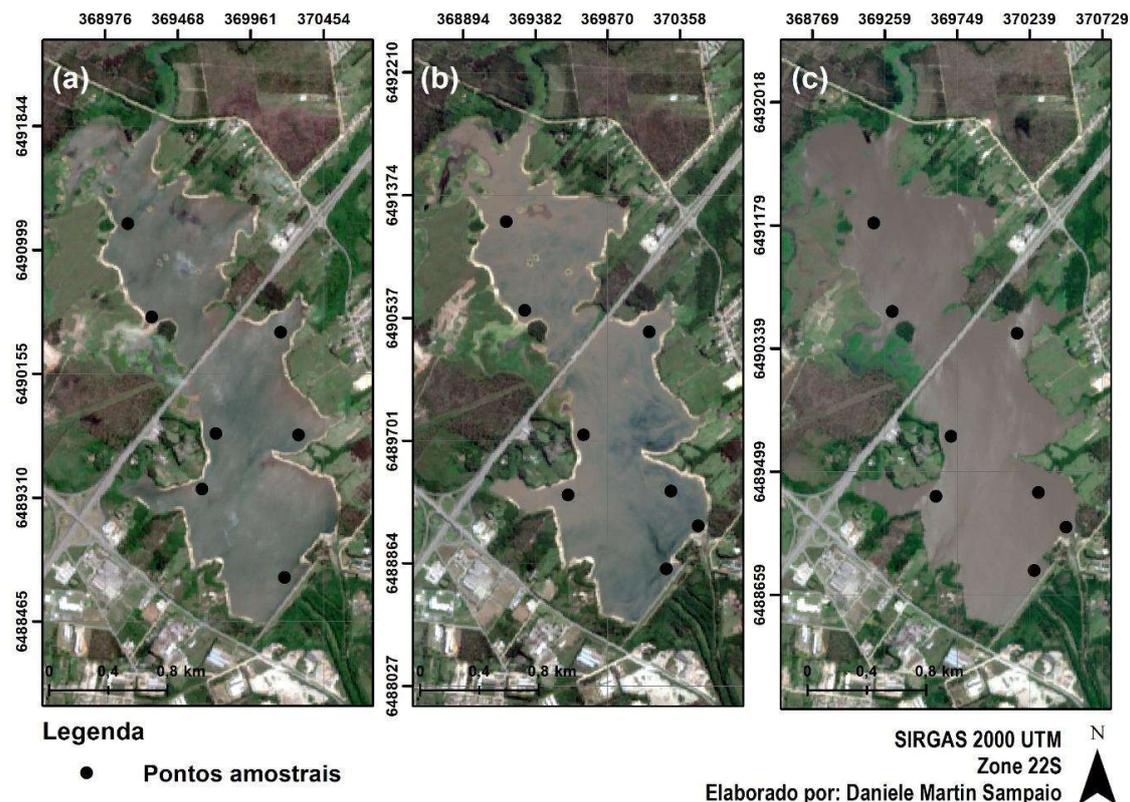


Figura 20 – Imagens do satélite Sentinel-2 na composição RGB (B4/B3/B2) e os pontos de coletas de cada uma das campanhas: (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022.

Tabela 6 – Valores médios, mínimos e máximos utilizados para elaboração dos modelos preditivos de clorofila-a e sólidos suspensos totais.

Parâmetro	Data da coleta	Data da imagem	Média	Mínimo	Máximo
Chl-a	17-fev-22	16-fev-22	447,6	214,3	614,5
	28-mar-22	28-mar-22	187	53,4	424
	04-nov-22	28-out-22	11,5	6,41	15,1
SST	17-fev-22	16-fev-22	23,6	14,6	27,8
	28-mar-22	28-mar-22	23,7	17,2	34,8
	04-nov-22	28-out-22	12,45	11,6	13,2

Chl-a – Clorofila-a, em  $\mu\text{g L}^{-1}$ ;

SST – Sólidos suspensos totais, em  $\text{mg L}^{-1}$ ;

Essa diferença entre a aquisição da imagem e a coleta de dados *in situ* não afeta significativamente a precisão da recuperação dos parâmetros da água, especialmente no caso de parâmetros relativamente estáveis como SST. Os parâmetros da água podem mudar em um curto período principalmente em dois casos: chuva intensa trazendo material dissolvido ou durante a floração do fitoplâncton. Especialmente as florações de cianobactérias podem ser especialmente

muito heterogêneas e a biomassa pode variar de duas a três ordens de magnitude em algumas centenas de metros (KUTSER, 2004). Entretanto, as condições climáticas permaneceram estáveis entre a aquisição da imagem e a amostragem *in situ* e nenhuma floração de cianobactérias foi relatada entre outubro e novembro de 2022.

Para entender melhor quais bandas espectrais e índices espectrais são mais significativas na previsão de Chl-a e SST usando dados do Sentinel-2, foram construídas correlações entre variáveis e os três grupos de dados espectrais– as reflectâncias, as razões de banda e os índices calculados. Desta forma, foi utilizado o coeficiente de correlação de *Spearman Rho*. A Figura 21 apresenta as correlações entre os dados de Chl-a coletados *in situ* na Barragem Santa Bárbara e os dados de sensoriamento remoto.

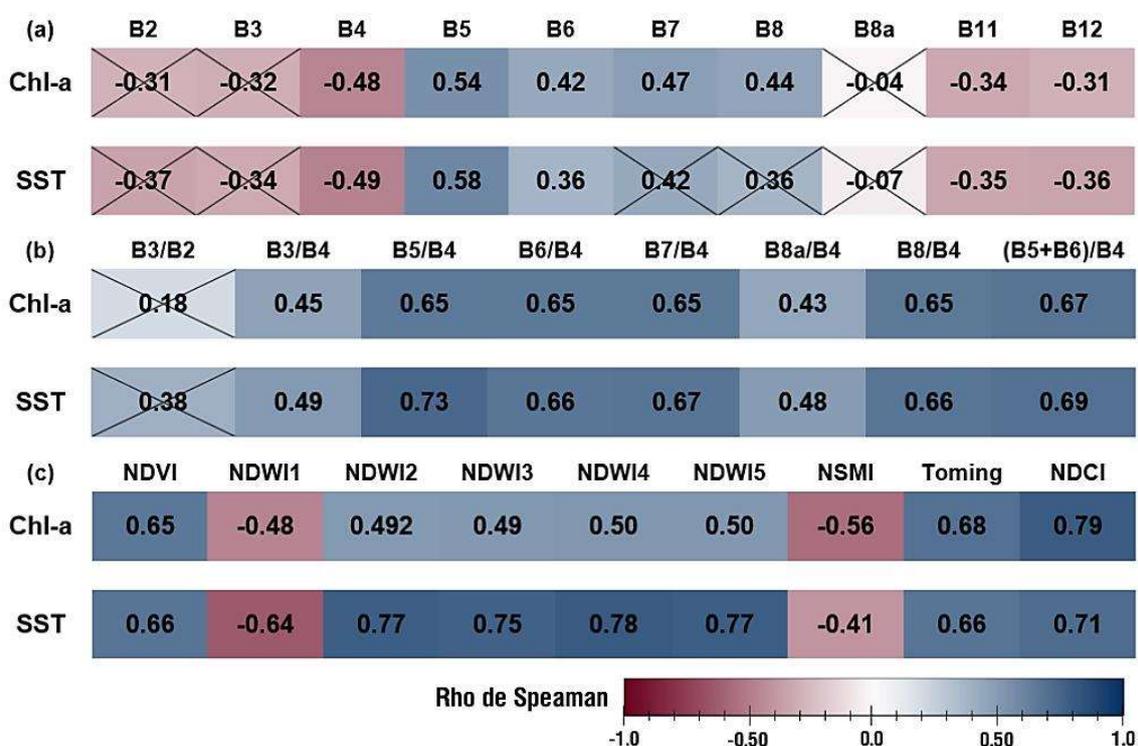


Figura 21 – Correlogramas de Chl-a e SST com (a) as bandas Sentinel-2, (b) as razões de banda escolhidas e (c) os índices de água calculados (os valores nas células mostram coeficientes de correlação e as células riscadas indicam valores insignificantes no nível 0,05).

Considerando o correlograma e o desempenho das bandas extraídas de Sentinel-2, razões de bandas e os índices espectrais de água calculados, a banda espectral específica de B5 (698 – 713 nm) forneceu as correlações mais fortes com Chl-a e SST. Esses resultados podem ser atribuídos principalmente à absorção

características de borda vermelha, que foi amplamente abordada na revisão bibliográfica. Além disso, com exceção da razão de banda B3/B2, todas as razões e os índices utilizados apresentaram boas correlações com Chl-a e SST. Se tratando dos índices, as melhores correlações foram fornecidas pelos índices NDVI, índice de Toming e NDCI, já que representam uma combinação de Vis e NIR.

Os resultados na Figura 21 vão ao encontro aos obtidos por Saberioon *et al.* (2020), que estudaram a distribuição de Chl-a e SST em vários reservatórios de água na parte sul da República Tcheca. Os parâmetros de qualidade de água estudados pelos autores são semelhantes aos da Barragem Santa Bárbara, já que o estudo desenvolvido por eles abordou um range de concentrações de Chl-a de  $10 \mu\text{g L}^{-1}$  a  $600 \mu\text{g L}^{-1}$  e de SST de  $2 \text{ mg L}^{-1}$  até  $23 \text{ mg L}^{-1}$ .

A partir das imagens de reflectância de superfície processadas e delimitadas para a área da Barragem, foram geradas as imagens dos índices NDCI (Figura 22), NDVI (Figura 23) e o Índice de Toming (Figura 24), totalizando 9 mapas. Destaca-se que, embora a mesma paleta de cores tenha sido utilizada, cada imagem possui intervalos de respostas diferentes e, conseqüentemente, as cores que são apresentadas em cada índice não representam o mesmo valor numérico.

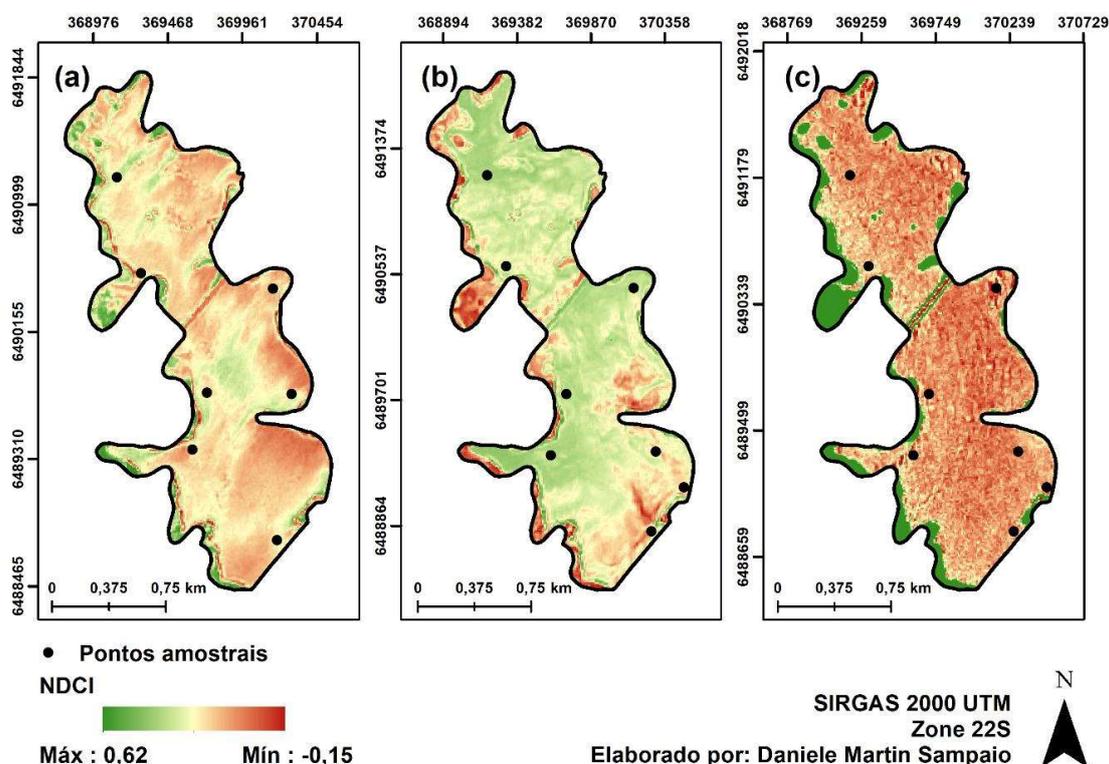


Figura 22 – Índice NDCI elaborado a partir das imagens Sentinel-2 para as datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022.

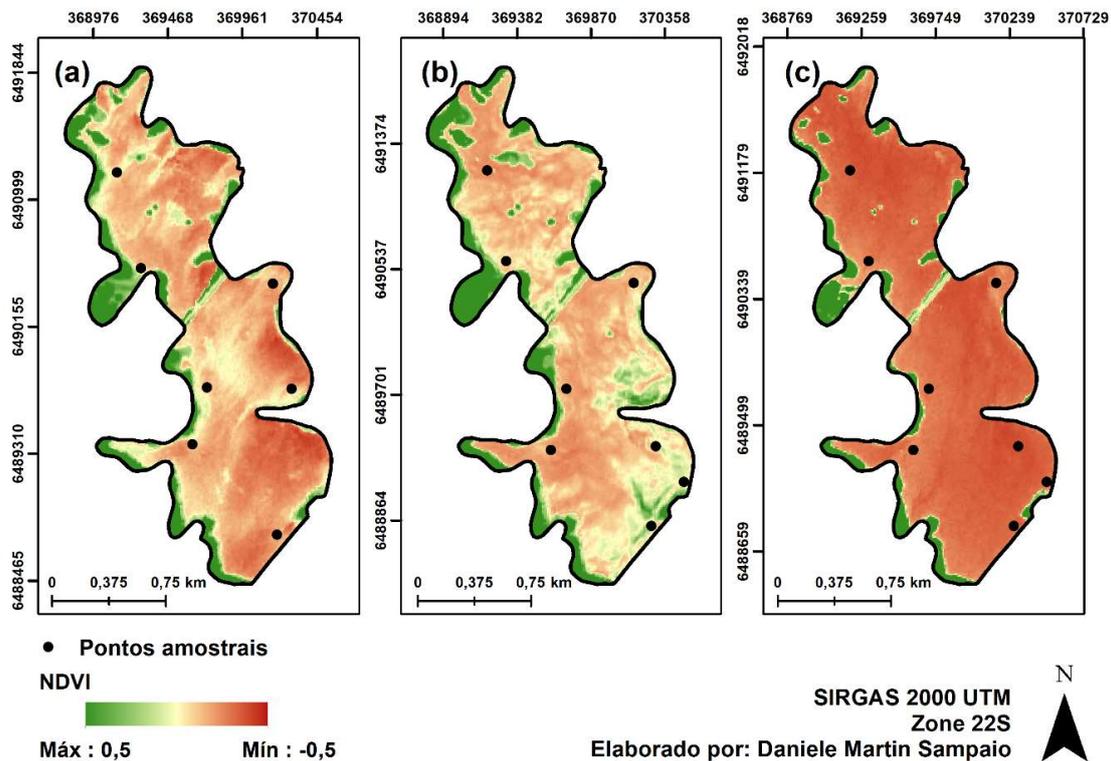


Figura 23 – Índice NDVI elaborado a partir das imagens Sentinel-2 para as datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022.

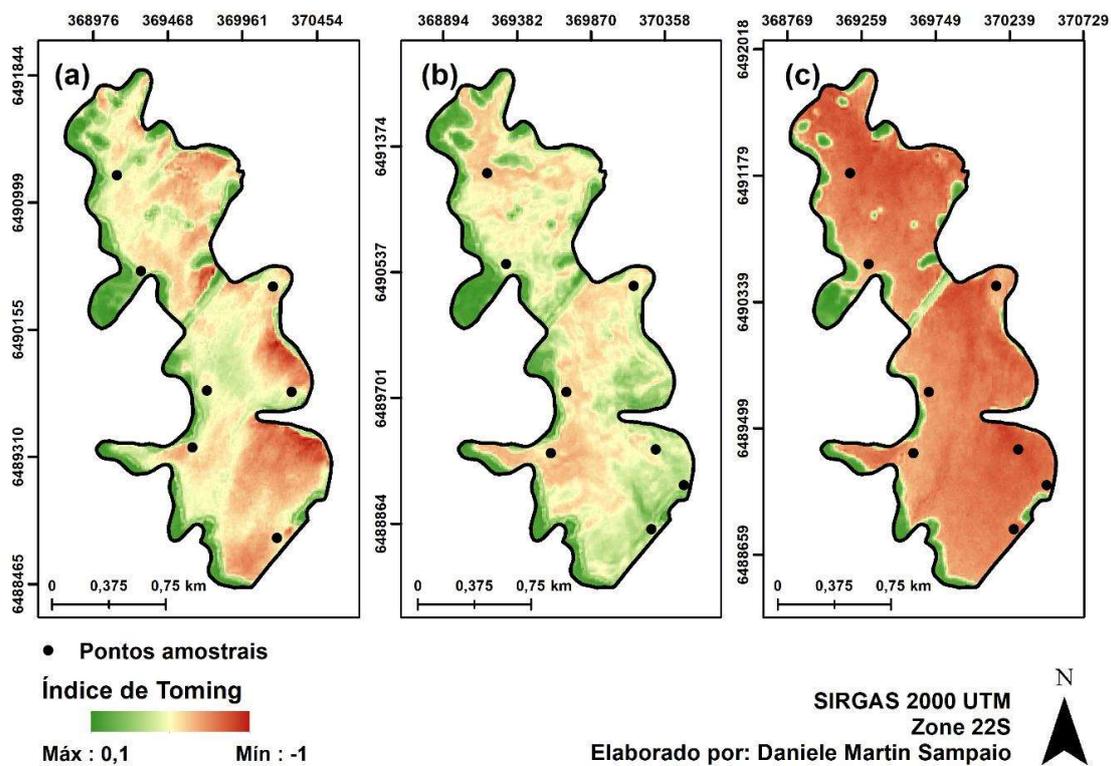


Figura 24 – Índice de Toming elaborado a partir das imagens Sentinel-2 para as datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022.

Ao observar os mapas elaborados utilizando os índices espectrais, nota-se que a coleta do dia 29 de outubro de 2022 gerou os menores índices. Esse resultado condiz com os dados obtidos nas análises *in situ*, nos quais tanto Chl-a quanto SST apresentaram os menores valores, e concorda com as boas correlações encontradas com os dados remotos.

### 5.3 Modelagem bio-óptica

Durante a etapa que englobou as análises de regressão entre os parâmetros de interesse deste estudo e os dados espectrais obtidos das imagens Sentinel-2, inúmeros testes foram realizados com o objetivo de encontrar as variáveis que estavam mais bem correlacionadas com os parâmetros de qualidade e quais melhores combinações. Obtiveram-se 40 combinações de variáveis preditoras para Chl-a e 44 combinações para SST, sendo apresentadas neste trabalho apenas as que obtiveram coeficiente de determinação ( $R^2$ ) igual ou superior a 0,50.

#### 5.3.1 Modelagem de clorofila-a

As regressões obtidas para clorofila-a encontram-se na Tabela 7.

Tabela 7 – Resultados das análises de regressão para clorofila.

Preditores	R	R <sup>2</sup>	RMSE*	Teste F	
				F	p
B4, B5, B6 e B7	0,71	0,51	142	4,48	0,012
B4, B5 e B6	0,70	0,50	145	5,80	0,006
<b>B3/B4, B5/B4, B6/B4, B7/B4 e B8/B4</b>	<b>0,80</b>	<b>0,64</b>	<b>122</b>	<b>5,70</b>	<b>0,003</b>
B6/B4, B7/B4, B8/B4, B8a/B4 e (B5+B6)/B4	0,77	0,59	130	5,40	0,004
B5, B5/B4, B8/B4 e (B5+B6)/B4	0,76	0,58	132	4,36	0,011

\* valor de RMSE em  $\mu\text{g L}^{-1}$

De forma geral, os resultados das regressões realizadas nesse estudo demonstraram correlações significativas. Isso pode ser observado pelo valor de p, no Teste F. Esse valor avalia o nível de significância do modelo. Como todos os modelos apresentaram um p-valor menor que 0,05, confirma que todos os modelos são

adequados para a previsão de Chl-a. Os valores de  $R^2$  variaram de 0,49 a 0,64, enquanto o RMSE variou de  $122 \mu\text{g L}^{-1}$  até  $145 \mu\text{g L}^{-1}$ .

Comparando os modelos, o melhor avaliado foi o que utilizou como preditores somente as razões de banda B3/B4, B5/B4, B6/B4, B7/B4 e B8/B4. O algoritmo gerado concorda com grande parte dos estudos que abordam a mesma metodologia desse, ou semelhantes, indicando a maior sensibilidade da clorofila-a com a razão NIR/vermelho (GRENDAITÉ *et al.*, 2018; LI *et al.*, 2021; SABERIOON *et al.*, 2020). Além disso, Ha *et al.* (2017b) e Le *et al.* (2013) apresentaram resultados que indicam forte correlação entre clorofila e a razão entre as bandas verde e vermelha (B3/B4), que foi incluída como preditora. Com base nesse modelo, a concentração de Chl-a da água do reservatório pode ser estimada usando a seguinte equação:

$$\begin{aligned} Chl - a = & \left( 669 \times \frac{B3}{B4} \right) + \left( 386 \times \frac{B5}{B4} \right) - \left( 4438 \times \frac{B6}{B4} \right) + \left( 3324 \times \frac{B7}{B4} \right) \\ & + \left( 982 \times \frac{B8}{B4} \right) - 682 \end{aligned} \quad (3)$$

Aplicando as equações nos dados de reflectância obtidos pelo sensoriamento remoto, foi construído o gráfico da Figura 25, que apresenta uma comparação dos dados de clorofila analisados e preditos.

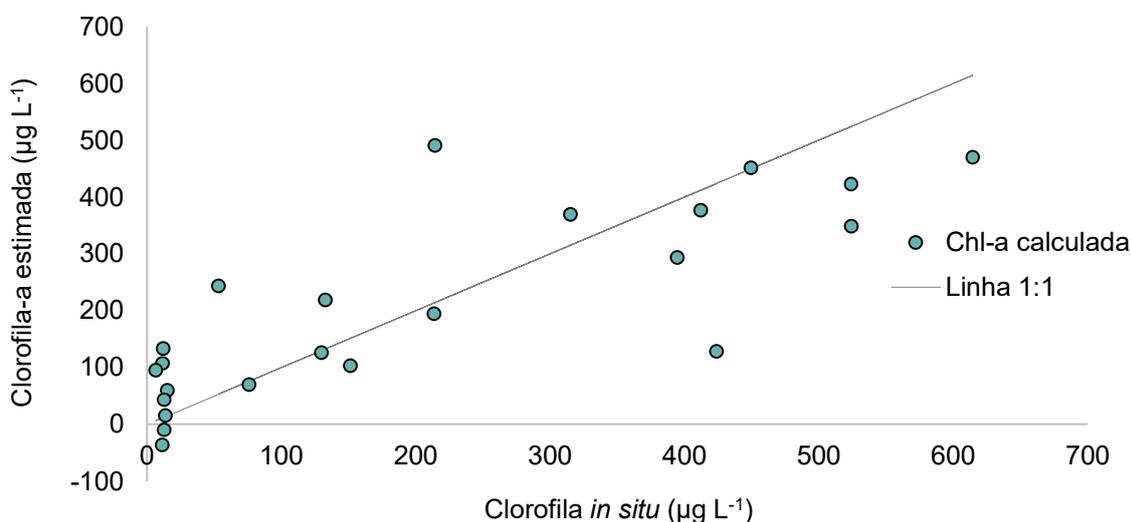


Figura 25 – Regressão linear entre a concentração de clorofila-a *in situ* e concentração calculada na Barragem Santa Bárbara (pontos). A linha sólida é a linha 1:1 esperada.

Além da regressão linear, para reforçar a avaliação da precisão do algoritmo, a variação de Chl-a *in situ* e Chl-a prevista em cada local de amostragem foi representada na Figura 26.

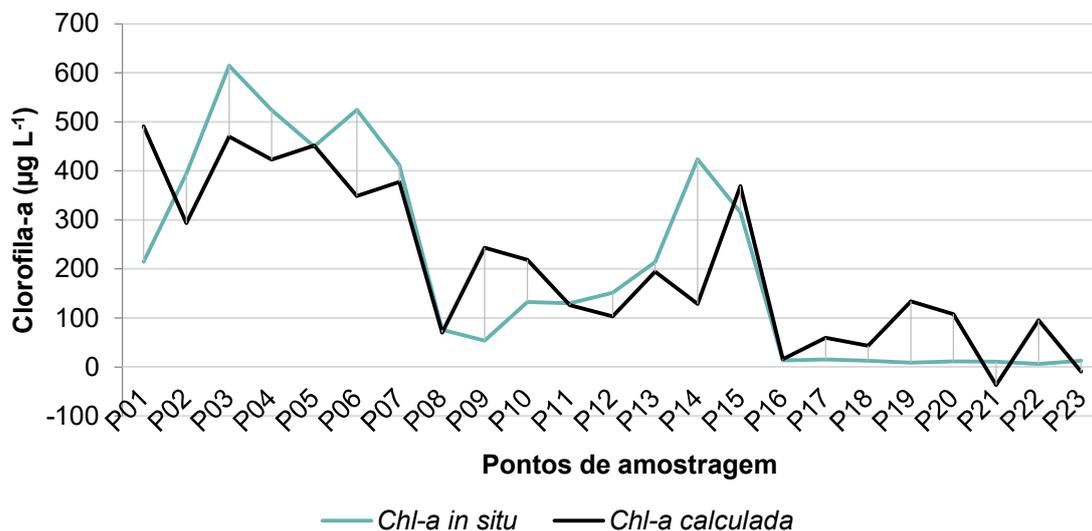


Figura 26 – Concentração *in situ* e prevista de Chl-a em cada local de amostragem na Barragem Santa Bárbara.

É importante destacar que foram obtidos valores negativos na estimativa de clorofila quando a equação foi aplicada a valores baixos de clorofila. Esse erro associado pode ser explicado pelo comportamento espectral diferente dos corpos d'água com baixo teor de clorofila, conforme abordado na revisão de literatura. Portanto, o modelo desenvolvido neste trabalho foi capaz de representar a dinâmica de clorofila-a da Barragem Santa Bárbara para épocas de florações.

Usando o modelo de predição desenvolvido, a variação espacial de Chl-a no reservatório foi determinada utilizando as imagens do Sentinel-2. A Figura 27 mostra os mapas da concentração de Chl-a estimada pelo modelo empírico.

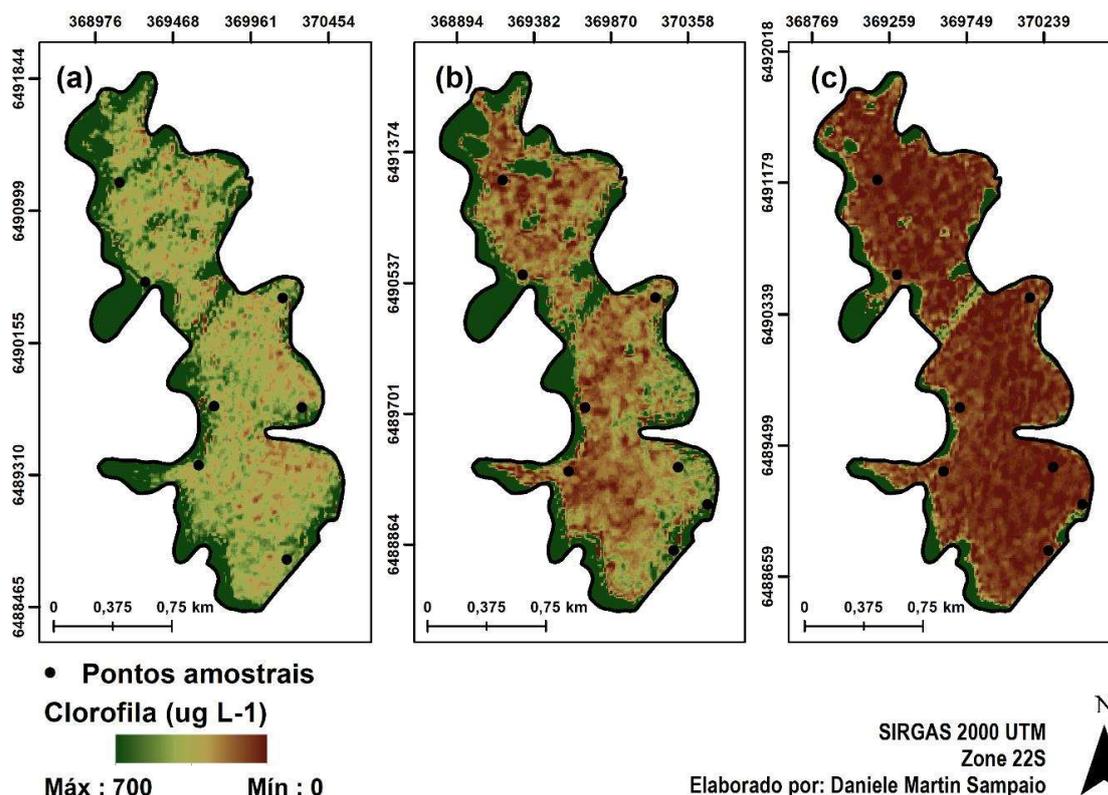


Figura 27 – Mapa de distribuição espacial de Chl-a elaborado a partir do modelo gerado para a Barragem Santa Bárbara para as datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022.

Os mapas gerados condizem com os resultados obtidos nas coletas de campo, já que as análises mostram que as maiores concentrações de clorofila-a foram obtidas na coleta do dia 17 de fevereiro de 2022 (imagem do dia 16 de fevereiro de 2022), com variação de 214 a 614  $\mu\text{g L}^{-1}$ , e as menores concentrações na coleta do dia 04 de novembro de 2022 (imagem do dia 29 de outubro de 2022), com variação de 6,41 a 15,1  $\mu\text{g L}^{-1}$ , condizem com os mapas gerados.

### 5.3.2 Modelagem de sólidos suspensos totais

A Tabela 8 apresenta os resultados obtidos das regressões para sólidos suspensos totais que obtiveram coeficiente de determinação ( $R^2$ ) igual ou superior a 0,50.

Tabela 8 – Resultados das análises de regressão para sólidos suspensos totais.

Preditores	R	R <sup>2</sup>	RMSE*	Teste F	
				F	p
B4, B5 e B6	0,71	0,51	4,84	6,26	0,004
B4 e B5	0,70	0,50	4,97	8,90	0,002
B5/B4, B6/B4, B7/B4, B8/B4	0,76	0,57	4,66	5,80	0,004
B3/B4, B7/B4, B8/B4 e (B5+B6)/B4	0,76	0,58	4,66	4,64	0,008
B4, B5, B8/B4 e (B5+B6)/B4	0,72	0,52	4,97	4,59	0,011
<b>B5, B6/B4 e B8/B4</b>	<b>0,78</b>	<b>0,61</b>	<b>4,58</b>	<b>8,18</b>	<b>0,001</b>

\* valor de RMSE em mg L<sup>-1</sup>

As regressões resultantes geraram coeficientes de determinação R<sup>2</sup> que variaram de 0,50 a 0,61, e RMSE que variaram de 4,97 a 4,33 mg L<sup>-1</sup>. As estatísticas p - valor das regressões foram < 0,05; ou seja, os coeficientes dos modelos de regressão foram adequados para explicar a concentração de SST.

Comparando os modelos, o mais bem adequado foi o que utilizou uma abordagem híbrida como preditores, no qual foram consideradas como variáveis preditivas a banda B5 e as razões de banda B6/B4 e B8/B4. A equação gerada concorda com trabalhos semelhantes para a mesma faixa de concentração, os quais indicam uma maior sensibilidade de sólidos suspensos com as bandas vermelho e NIR (MACIEL *et al.*, 2019; SABERON *et al.*, 2020). Com base nas variáveis preditivas e seus respectivos coeficientes estimados, a concentração de SST da água da Barragem Santa Bárbara pode ser estimada usando a seguinte equação:

$$SST = 243,2 \times B5 + \left(154,1 \times \frac{B6}{B4}\right) - \left(153,3 \times \frac{B8}{B4}\right) - 21,1 \quad (4)$$

A Figura 28 mostra um gráfico comparativo entre as concentrações de sólidos suspensos *in situ* e a concentração de SST estimada a partir do modelo usando as bandas MSI/Sentinel 2 que teve os melhores resultados.

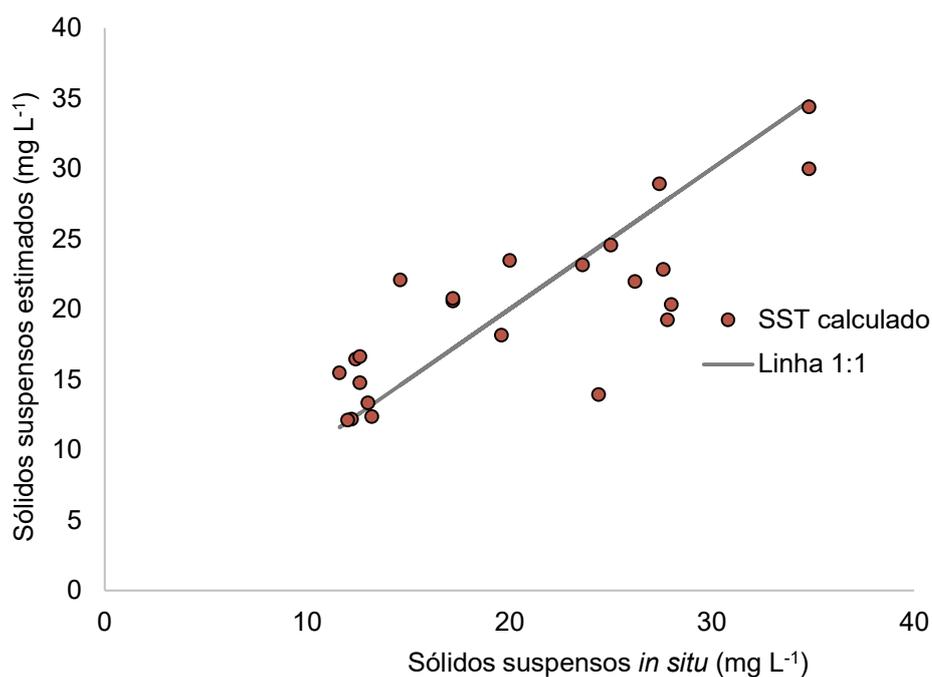


Figura 28 – Regressão linear entre a concentração de sólidos suspensos totais *in situ* e calculado na Barragem Santa Bárbara (pontos). A linha sólida é a linha 1:1 esperada.

Assim como para clorofila, além da regressão linear, para reforçar a avaliação da precisão do algoritmo, a variação de SST *in situ* e SST calculado nos 23 pontos de amostragem foi representada na Figura 29.

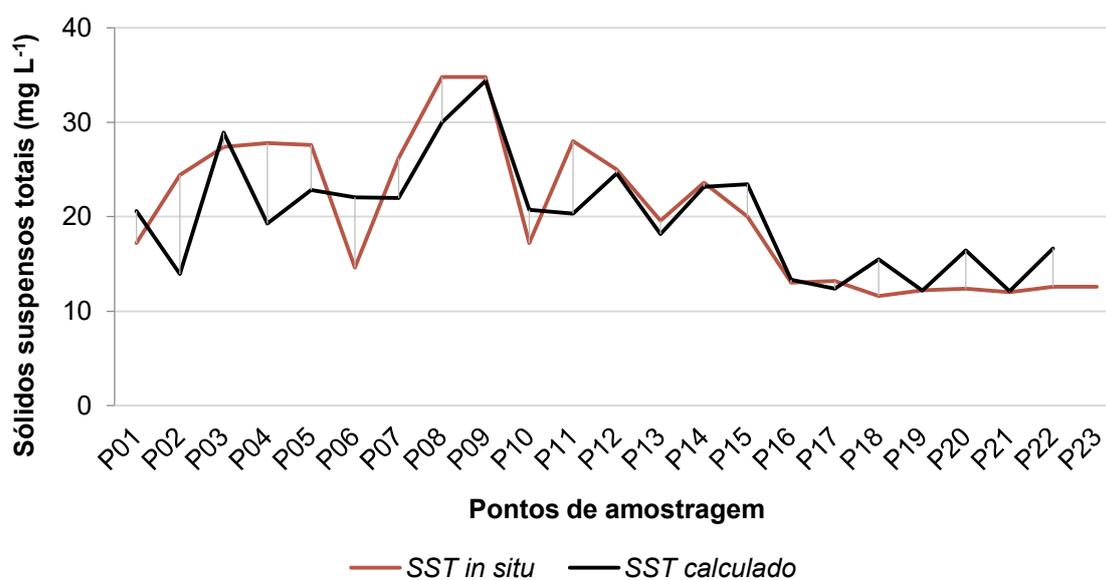


Figura 29 – Concentração *in situ* e prevista de SST em cada local de amostragem na Barragem Santa Bárbara.

Comparando os gráficos, pode-se notar que tanto os dados *in situ* quanto os estimados exibiram a mesma tendência cronológica na concentração de SST, indicando boa precisão de predição do modelo de regressão desenvolvido.

Usando o modelo de predição desenvolvido, a variação espacial de SST na Barragem Santa Bárbara foi desenvolvida utilizando as imagens do Sentinel-2. Os mapas gerados estão expostos na Figura 30.

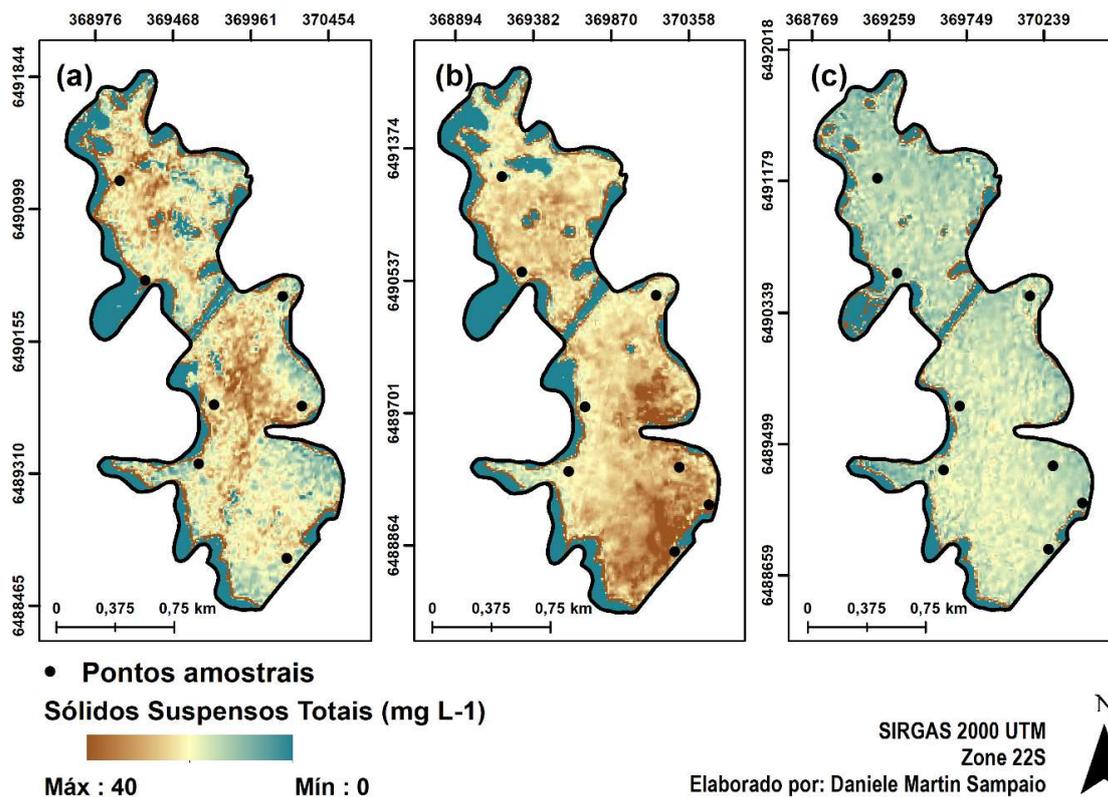


Figura 30 – Mapa de distribuição espacial de SST modelado para a Barragem Santa Bárbara aplicado nas imagens das datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022.

Os mapas condizem com os dados de campo, mostrando as maiores concentrações de SST na coleta do dia 28 de março de 2022 (imagem do dia 28 de março de 2022), em que os teores variaram de 17,2 a 34,8 mg L<sup>-1</sup>, e concentrações menores na coleta do dia 04 de novembro de 2022 (imagem do dia 29 de outubro de 2022) – de 11,6 a 13,2 mg L<sup>-1</sup>.

### 5.3.3 Modelagem da densidade celular de *Ceratium*

O gênero *Ceratium* foi observado em 19 dos 23 das amostras utilizadas na modelagem, enquanto outros gêneros de cianobactérias (*Cyanophyceae*) foram raramente observados. Essa diferença está apresentada na Figura 31, juntamente com a variação de clorofila.

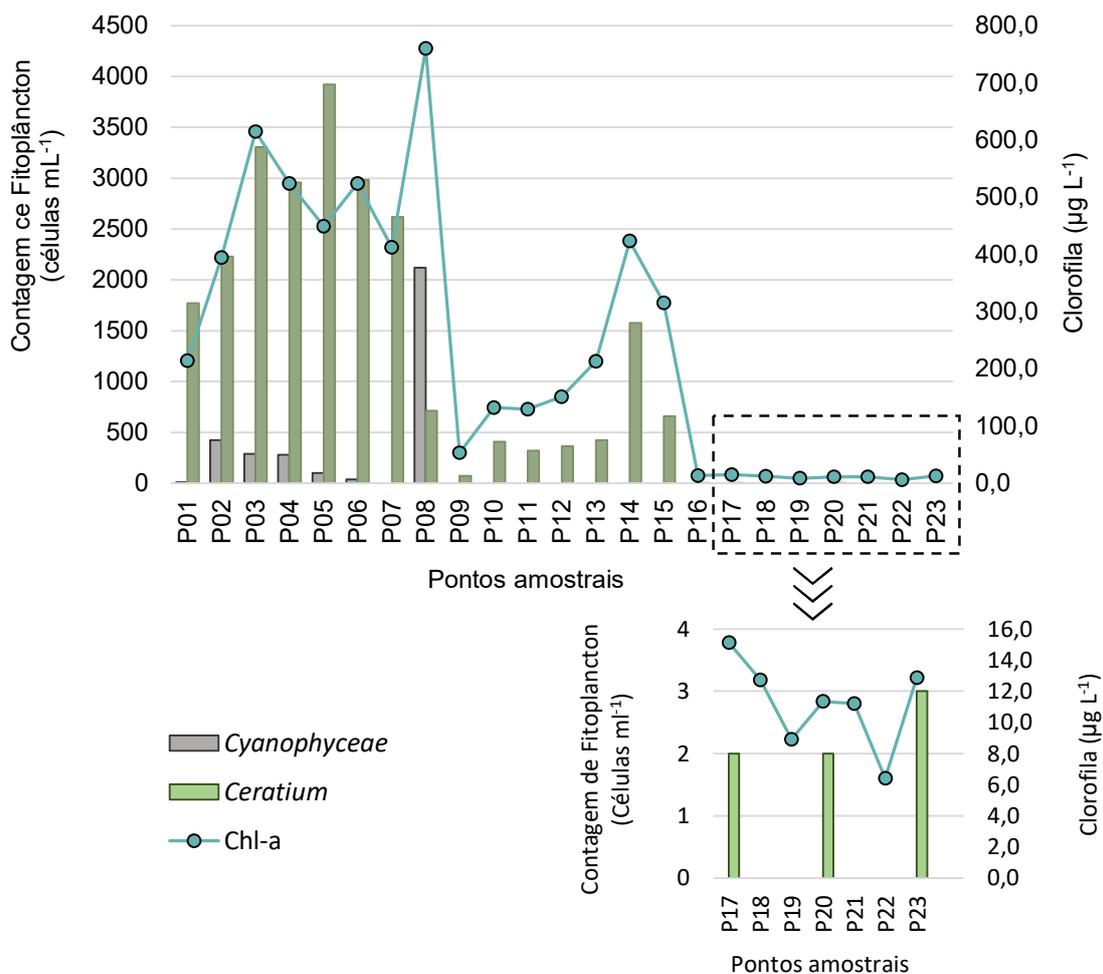


Figura 31 – Gráfico de barras da densidade de células de *Ceratium* e outros gêneros de cianobactérias (*Cyanophyceae*) e variação de clorofila nos pontos amostrais.

Para prever a densidade celular de *Ceratium*, foi determinada sua correlação com a Chl-a utilizando os 13 pontos nos quais apenas a presença desse organismo foi detectada. A Tabela 9 apresenta o resultado da regressão da Chl-a e da densidade celular de *Ceratium*. Os dados mostraram uma forte correlação entre ambos os parâmetros.

Tabela 9 – Resultado da análise de regressão para modelagem da concentração de clorofila-a utilizando como variável independente a concentração de *Ceratium*.

Preditor	Coeficiente	R	R <sup>2</sup>	RMSE*	Teste F	
					F	p
<i>Ceratium</i>	0,149	0,929	0,863	61,3	75,5	< ,001
Intercepto	52,7	-	-	-	-	-

\* valor de RMSE em µg L<sup>-1</sup>

Com base no modelo de regressão desenvolvido (Tabela 9), a densidade celular de *Ceratium* pode ser estimada usando a Equação da predição de Chl-a.

$$Chl - a = 0,15 \times (Ceratum) + 52,7 \quad (5)$$

$$Ceratum = \left(4460 \times \frac{B3}{B4}\right) + \left(2573 \times \frac{B5}{B4}\right) - \left(29586 \times \frac{B6}{B4}\right) + \left(22160 \times \frac{B7}{B4}\right) + \left(6546 \times \frac{B8}{B4}\right) - 4898 \quad (6)$$

A avaliação do modelo gerado para prever *Ceratium* na Barragem Santa Bárbara pela combinação das regressões lineares está apresentada na Tabela 10. O resultado mostra que a previsão foi significativa (R<sup>2</sup> = 0,57, RMSE = 700, p = 0,003). Observa-se um padrão de distribuição espacial semelhante de tendências crescentes ou decrescentes entre valores *in situ* e preditos (Figura 32), destacando a aplicação do modelo preditivo para avaliar a densidade de *Ceratium* e sua distribuição espacial e temporal.

Tabela 10 – Resultado da análise de regressão para modelagem da concentração de *Ceratium* utilizando o modelo de clorofila previamente desenvolvido.

Preditor	R	R <sup>2</sup>	RMSE*	Teste F	
				F	p
<i>Ceratium</i>	0,754	0,570	700	168	0,003

\* valor de RMSE em células mL<sup>-1</sup>

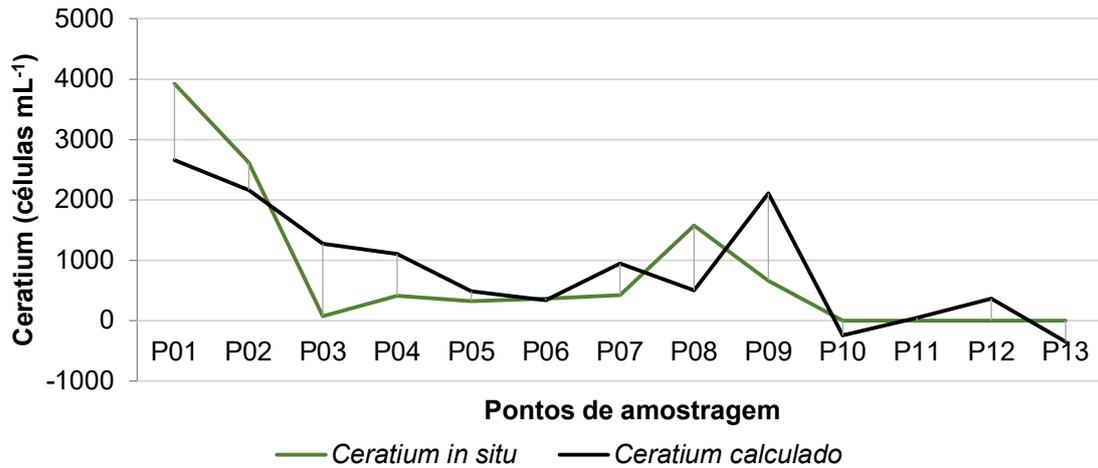


Figura 32 – Concentração *in situ* e prevista da densidade de *Ceratium*, em células mL<sup>-1</sup>, para cada local de amostragem na Barragem Santa Bárbara.

Usando o modelo dual de predição desenvolvido, a variação espacial de *Ceratium* na Barragem Santa Bárbara foi desenvolvida utilizando as imagens do Sentinel-2. Os mapas gerados estão expostos na Figura 33.

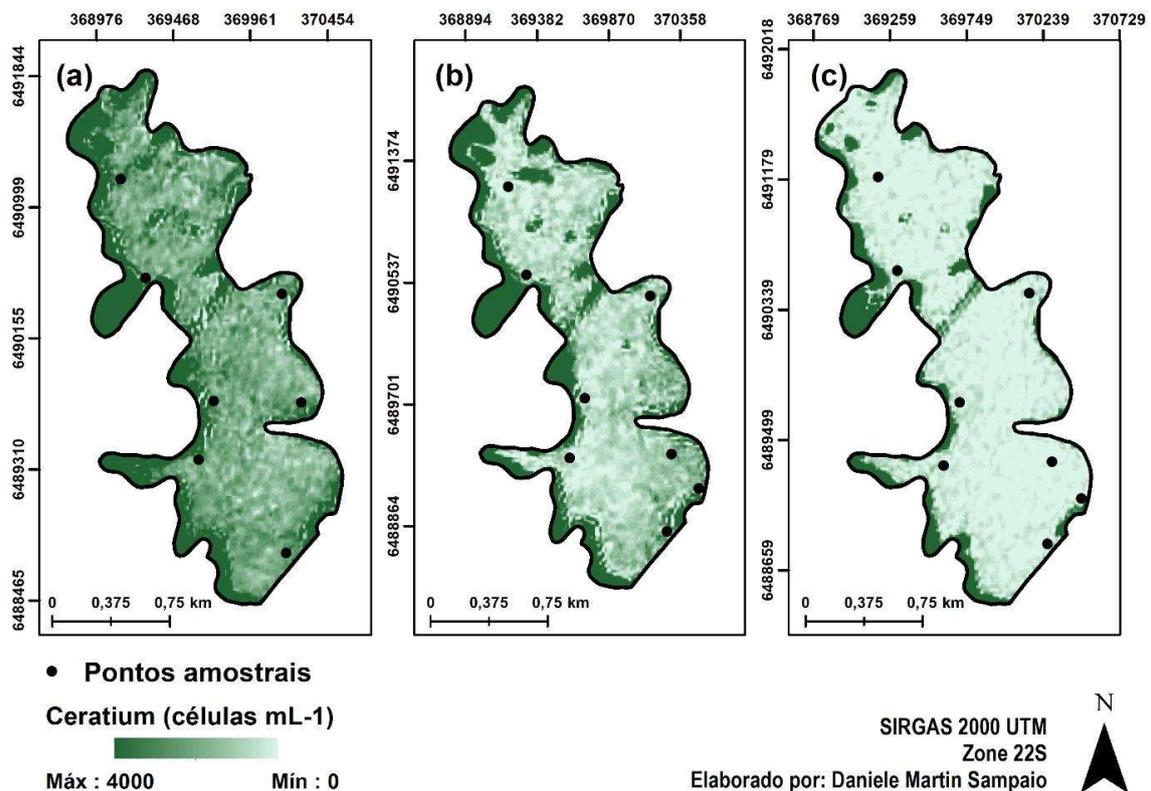


Figura 33 – Mapa de distribuição espacial da densidade celular de *Ceratium* modelado para a Barragem Santa Bárbara nas datas (a) 16 de fevereiro de 2022, (b) 28 de março de 2022 e (c) 29 de outubro de 2022.

Assim como no modelo de clorofila, observa-se valores negativos calculados, mostrando que essa modelagem não se adequou à valores baixos de quantidade de células mL<sup>-1</sup>, servindo o modelo para predizer as contagens em épocas de florações. Porém, observando os mapas da Figura 33, há uma concordância com os dados da Figura 31, mostrando que as maiores densidades de *Ceratium* ocorreram nos primeiros pontos amostrais, ou seja, na coleta do dia 17 de fevereiro de 2022, e as menores concentrações se apresentaram nos últimos pontos amostrais, representando a coleta de novembro.

## 6 Conclusões

Com base na combinação das medições *in situ* com os dados de reflectância das imagens Sentinel-2, a metodologia desenvolvida para a geração de modelos bio-ópticos do teor de clorofila-a, do teor de sólidos suspensos totais e da densidade celular de *Ceratium* se apresenta adequada, na qual foram modelos inicialmente satisfatórios para Chl-a ( $R^2 = 0,64$  e  $RMSE = 122$ ), SST ( $R^2=0,61$  e  $RMSE = 4,33$ ) e densidade celular de *Ceratium* ( $R^2 = 0,57$  e  $RMSE = 700$ ) na Barragem Santa Bárbara, mas que ainda necessitam serem testados com um conjunto de dados externos independentes.

Os mapas obtidos com os resultados da modelagem com a distribuição dos parâmetros analisados na pesquisa na Barragem Santa Bárbara permitiram uma análise espaço-temporal importante, o que é primordial para o monitoramento e gestão adequada dos recursos hídricos.

Recomenda-se, em continuidade a esta pesquisa, a coleta de dados de satélites em outras estações do ano e com um número maior de dados amostrais, visando obter uma melhor representatividade do recurso hídrico durante todo o ano. Com os avanços da tecnologia de computadores e da teoria estatística, os algoritmos de aprendizado de máquina podem apresentar novas ideias e soluções para esse problema, gerando modelos com menores erros e que representem amplas faixas de concentrações. Além da melhoria dos modelos, as aplicações também podem ser estendidas para outros parâmetros, como turbidez, oxigênio dissolvido, nitrogênio e fósforo, para prever, por exemplo, o estado trófico, identificação de bioindicadores de poluição por nutrientes da água etc. No entanto, estas extensões dependem de dados *in situ* para validação do algoritmo, o que poderia ser feito através da continuação da parceria com os órgãos responsáveis pelo monitoramento e fornecidos pelos usuários e colaboradores.

Finalmente, essa pesquisa representa uma importante aplicação da área de sensoriamento remoto e computação em nuvem para fornecer alertas de mudança de qualidade de água, ajudando governos, instituições e tomadores de decisão a agir rapidamente para proteger e mitigar os impactos ambientais e sociais decorrentes de contaminações.

## Referências

ANSPER, A.; ALIKAS, K. Retrieval of Chlorophyll a from Sentinel-2 MSI Data for the European Union Water Framework Directive Reporting Purposes. **Remote Sensing** **2019**, Vol. 11, Page 64, v. 11, n. 1, p. 64, 31 dez. 2018.

APHA. **Standard Methods for the Examination of Water and Wastewater**. Washington, D. C.: American Public Health Association, 2012. v. 22

BARBOSA, C. C. F.; DE MORAES NOVO, E. M. L.; MARTINS, V. S. **Introdução ao sensoriamento remoto de sistemas aquáticos: princípios e aplicações**. [s.l.] Instituto Nacional de Pesquisas Espaciais, 2019. v. 1

BARRAZA-MORAGA, F. *et al.* Estimation of Chlorophyll-a Concentrations in Lanalhue Lake Using Sentinel-2 MSI Satellite Images. **Remote Sensing**, v. 14, n. 22, 2022.

BICUDO, C.; MENEZES, M. **Gêneros de Algas de Águas Continentais do Brasil: chave para identificação e descrições**. 3ª ed. [s.l.] Rima, 2017.

BOEIRA, D. D. *et al.* **Avaliação da adição de auxiliares de coagulação na remoção da alga Ceratium sp. em uma estação de tratamento de água**. 57º Congresso Brasileiro de Química. **Anais...** Gramado, RS: ABQ - Associação Brasileira de Química, 2017.

BRANCO, S. M. Material e técnicas empregadas em Hidrobiologia. Em: **Hidrobiologia Aplicada a Engenharia Sanitária**. 2a. ed. São Paulo: CETESB, 1978. p. 169–243.

BRASIL. Lei Nº 11.445, de 5 de Janeiro 2007. 2007.

BRESCIANI, M. *et al.* Mapping phytoplankton blooms in deep subalpine lakes from Sentinel-2A and Landsat-8. **Hydrobiologia**, v. 824, n. 1, p. 197–214, 25 nov. 2018.

BREWING, R. J. W. *et al.* Regional ocean-colour chlorophyll algorithms for the Red Sea. **Remote Sensing of Environment**, v. 165, p. 64–85, 1 ago. 2015.

BÜTTNER, G. *et al.* Satellite remote sensing of inland waters: Lake Balaton and reservoir Kisköre. **Acta Astronautica**, v. 15, n. 6–7, p. 305–311, 1 jun. 1987.

CABALLERO, I.; STUMPF, R. P. Towards Routine Mapping of Shallow Bathymetry in Environments with Variable Turbidity: Contribution of Sentinel-2A/B Satellites Mission. **Remote Sensing**, v. 12, n. 3, 2020.

CAIRO, C. *et al.* Hybrid Chlorophyll-a Algorithm for Assessing Trophic States of a Tropical Brazilian Reservoir Based on MSI/Sentinel-2 Data. **Remote Sensing** **2020**, Vol. 12, Page 40, v. 12, n. 1, p. 40, 20 dez. 2019.

CHAWLA, I.; KARTHIKEYAN, L.; MISHRA, A. K. A review of remote sensing applications for water security: Quantity, quality, and extremes. **Journal of Hydrology**, v. 585, p. 124826, 1 jun. 2020.

DINIZ, C. G. **Três décadas de mudanças na planície costeira brasileira: O status dos manguezais, da aquicultura e salicultura a partir de séries temporais Landsat e técnicas de aprendizado de máquina**. Tese (Doutorado em Geologia e Geoquímica) — Belém: Universidade Federal do Pará, 2020.

DOGLIOTTI, A. I. *et al.* A single algorithm to retrieve turbidity from remotely-sensed data in all coastal and estuarine waters. **Remote Sensing of Environment**, v. 156, p. 157–168, 1 jan. 2015.

DOGLIOTTI, A. I. *et al.* Detecting and Quantifying a Massive Invasion of Floating Aquatic Plants in the Río de la Plata Turbid Waters Using High Spatial Resolution Ocean Color Imagery. **Remote Sensing 2018, Vol. 10, Page 1140**, v. 10, n. 7, p. 1140, 19 jul. 2018.

DU, Y. *et al.* Water bodies' mapping from Sentinel-2 imagery with modified normalized difference water index at 10-m spatial resolution produced by sharpening the SWIR band. **Remote Sensing**, v. 8, n. 4, p. 354, 2016.

DUBE, T. *et al.* Water quality monitoring in sub-Saharan African lakes: a review of remote sensing applications. **African Journal of Aquatic Science**, v. 40, n. 1, p. 1–7, 2 jan. 2015.

ESA. **Copernicus: Sentinel-2**. Disponível em: <<https://www.eoportal.org/satellite-missions/copernicus-sentinel-2#msi-multispectral-imager>>. Acesso em: 6 jan. 2023.

EWERTS, H.; SWANEPOEL, A.; DU PREEZ, H. Efficacy of conventional drinking water treatment processes in removing problem-causing phytoplankton and associated organic compounds. **Water SA**, v. 39, n. 5, p. 739, 16 out. 2013.

FENG, L. *et al.* Human induced turbidity changes in Poyang Lake between 2000 and 2010: Observations from MODIS. **Journal of Geophysical Research: Oceans**, v. 117, n. C7, jul. 2012.

FRANCESCHINI, I. M. *et al.* **Algas: Uma abordagem filogenética, taxonômica e ecológica**. Porto Alegre: Artmed, 2010.

GAO, B. C. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, n. 3, p. 257–266, 1 dez. 1996.

GHOLIZADEH, M. H.; MELESSE, A. M.; REDDI, L. A Comprehensive Review on Water Quality Parameters Estimation Using Remote Sensing Techniques. **Sensors**, v. 16, n. 8, 2016.

GIARDINO, C. *et al.* The Color of Water from Space: A Case Study for Italian Lakes from Sentinel-2. Em: **Earth Observation and Geospatial Analyses [Working Title]**. [s.l.] IntechOpen, 2019.

GITELSON, A. A. *et al.* Estimation of chlorophyll-a concentration in productive turbid waters using a Hyperspectral Imager for the Coastal Ocean - The Azov Sea case study. **Environmental Research Letters**, v. 6, n. 2, 2011.

GONS, H. J.; AUER, M. T.; EFFLER, S. W. MERIS satellite chlorophyll mapping of oligotrophic and eutrophic waters in the Laurentian Great Lakes. **Remote Sensing of Environment**, v. 112, n. 11, p. 4098–4106, 15 nov. 2008.

**Google Earth Engine Data Catalog | Google Developers**. Disponível em: <<https://developers.google.com/earth-engine/datasets/>>. Acesso em: 5 jan. 2023.

GORELICK, N. *et al.* Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 1 dez. 2017.

GOWER, J. *et al.* Detection of intense plankton blooms using the 709 nm band of the MERIS imaging spectrometer. **International Journal of Remote Sensing**, v. 26, n. 9, p. 2005–2012, 1 maio 2005.

GRENDAITĖ, D. *et al.* Chlorophyll-a concentration retrieval in eutrophic lakes in Lithuania from Sentinel-2 data. **Geologija. Geografija**, v. 4, n. 1, 11 jul. 2018.

GUO, Q. *et al.* Study on Retrieval of Chlorophyll-a Concentration Based on Landsat OLI Imagery in the Haihe River, China. **Sustainability**, v. 8, n. 8, 2016.

GUSTAFSSON, Ö.; GSCHWEND, P. M. Aquatic colloids: Concepts, definitions, and current challenges. **Limnology and Oceanography**, v. 42, n. 3, p. 519–528, 1 maio 1997.

HA, N. T. T. *et al.* Selecting the Best Band Ratio to Estimate Chlorophyll-a Concentration in a Tropical Freshwater Lake Using Sentinel 2A Images from a Case Study of Lake Ba Be (Northern Vietnam). **ISPRS International Journal of Geo-Information**, v. 6, n. 9, 2017a.

HA, N. T. T. *et al.* Landsat 8/OLI Two bands ratio algorithm for chlorophyll-a concentration mapping in hypertrophic waters: An application to west lake in Hanoi (Vietnam). **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 10, n. 11, p. 4919–4929, 1 nov. 2017b.

HAKIM, G. **DEPARTMENT OF ATMOSPHERIC SCIENCES**. Disponível em: <<https://atmos.washington.edu/~hakim/>>. Acesso em: 4 jan. 2023.

HANISCH, W.; FREIRE-NORDI, C. S. Monitoramento. Monitoramento remoto em tempo real de mananciais visando as florações de cianobactéria. Em: **Pompêo et al. (Orgs.) Ecologia de reservatórios e interfaces**. São Paulo: Instituto de Biociências da Universidade de São Paulo, 2015. p. 190–211.

HANSEN, C. *et al.* Spatiotemporal Variability of Lake Water Quality in the Context of Remote Sensing Models. **Remote Sensing**, v. 9, n. 5, p. 409, 26 abr. 2017.

HAUBROCK, S. N. *et al.* Surface soil moisture quantification models from reflectance data under field conditions. <https://doi.org/10.1080/01431160701294695>, v. 29, n. 1, p. 3–29, 10 jan. 2010.

HIRD, J. N. *et al.* Google Earth Engine, Open-Access Satellite Data, and Machine Learning in Support of Large-Area Probabilistic Wetland Mapping. **Remote Sensing 2017, Vol. 9, Page 1315**, v. 9, n. 12, p. 1315, 14 dez. 2017.

- HUNTER, P. D. *et al.* Spectral discrimination of phytoplankton colour groups: The effect of suspended particulate matter and sensor spectral resolution. **Remote Sensing of Environment**, v. 112, n. 4, p. 1527–1544, 15 abr. 2008.
- IBGE. **Estimativa Populacional**. Disponível em: <<https://cidades.ibge.gov.br/brasil/rs/pelotas/panorama>>. Acesso em: 16 set. 2021.
- IVANDA, A. *et al.* Mapping Chlorophyll-a Concentrations in the Kaštela Bay and Brač Channel Using Ridge Regression and Sentinel-2 Satellite Images. **Electronics**, v. 10, n. 23, 2021.
- JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. [s.l.] Parêntese Editora São José dos Campos, 2009.
- KHAN, M. N.; MOHAMMAD, F. Eutrophication: challenges and solutions. Em: **Eutrophication: causes, consequences and control**. [s.l.] Springer, 2014. p. 1–15.
- KHATRI, N.; TYAGI, S. Influences of natural and anthropogenic factors on surface and groundwater quality in rural and urban areas. **Frontiers in Life Science**, v. 8, n. 1, p. 23–39, 2 jan. 2015.
- KISLIK, C. *et al.* Mapping algal bloom dynamics in small reservoirs using Sentinel-2 imagery in Google Earth Engine. **Ecological Indicators**, v. 140, p. 109041, jul. 2022.
- KORB, C. C.; SUERTEGARAY, D. M. A. Identificação de depósitos tecnogênicos em um reservatório de abastecimento de água da cidade de Pelotas (RS). **Quaternary and Environmental Geosciences**, v. 5, n. 1, p. 41–54, 2014.
- KUHN, C. *et al.* Performance of Landsat-8 and Sentinel-2 surface reflectance products for river remote sensing retrievals of chlorophyll-a and turbidity. **Remote Sensing of Environment**, v. 224, n. January, p. 104–118, 2019.
- KUO, J. T. *et al.* Eutrophication modelling of reservoirs in Taiwan. **Environmental Modelling and Software**, v. 21, n. 6, p. 829–844, jun. 2006.
- KUTSER, T. Quantitative detection of chlorophyll in cyanobacterial blooms by satellite remote sensing. **Limnology and Oceanography**, v. 49, n. 6, p. 2179–2189, 1 nov. 2004.
- KUTSER, T. *et al.* Remote sensing of black lakes and using 810 nm reflectance peak for retrieving water quality parameters of optically complex waters. **Remote Sensing**, v. 8, n. 6, p. 497, 2016.
- KUTSER, T. *et al.* **Mapping Shallow Waters of the Baltic Sea with Sentinel-2 Imagery**. 2018 IEEE/OES Baltic International Symposium (BALTIC). **Anais...IEEE**, jun. 2018.
- LE, C. *et al.* Long-term distribution patterns of remotely sensed water quality parameters in Chesapeake Bay. **Estuarine, Coastal and Shelf Science**, v. 128, p. 93–103, 10 ago. 2013.

LI, J. *et al.* Response of total suspended sediment and chlorophyll-a concentration to late autumn typhoon events in the northwestern south china sea. **Remote Sensing**, v. 13, n. 15, 1 ago. 2021.

LI, Z. *et al.* Landsat 15-m Panchromatic-Assisted Downscaling (LPAD) of the 30-m Reflective Wavelength Bands to Sentinel-2 20-m Resolution. **Remote Sensing**, v. 9, n. 7, 2017.

LI, Z. *et al.* Sharpening the Sentinel-2 10 and 20 m Bands to Planetscope-0 3 m Resolution. **Remote Sensing**, v. 12, n. 15, 2020.

LIMA, D. L. *et al.* Bibliometric review about turbidity and suspended solids by remote sensing. **Anuario do Instituto de Geociencias**, v. 42, n. 1, p. 107–116, 2019.

LOPES, F. B. *et al.* Modelagem da qualidade das águas a partir de sensoriamento remoto hiperespectral. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, n. suppl, p. 13–19, 2014.

MAC DONAGH, M. E.; CASCO, M. A.; CLAPS, M. C. Colonization of a Neotropical Reservoir (Córdoba, Argentina) by *Ceratium hirundinella* (O. F. Müller) Bergh. **Annales de Limnologie**, v. 41, n. 4, p. 291–299, 2005.

MACIEL, D. *et al.* Retrieving Total and Inorganic Suspended Sediments in Amazon Floodplain Lakes: A Multisensor Approach. **Remote Sensing 2019, Vol. 11, Page 1744**, v. 11, n. 15, p. 1744, 24 jul. 2019.

MADSEN, J. D. *et al.* The interaction between water movement, sediment dynamics and submersed macrophytes. **Hydrobiologia**, v. 444, p. 71–84, 2001.

**MAPBIOMAS**. Disponível em: <<https://plataforma.brasil.mapbiomas.org/>>. Acesso em: 19 dez. 2022.

MARTINS, V. S. *et al.* Seasonal and interannual assessment of cloud cover and atmospheric constituents across the Amazon (2000–2015): Insights for remote sensing and climate analysis. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, p. 309–327, 2018.

MASOCHA, M. *et al.* Testing utility of Landsat 8 for remote assessment of water quality in two subtropical African reservoirs with contrasting trophic states. **Geocarto International**, v. 33, n. 7, p. 667–680, 2018.

MATSUMURA-TUNDISI, T. *et al.* Occurrence of *Ceratium furcoides* (Levander) Langhans 1925 bloom at the Billings Reservoir, São Paulo State, Brazil. **Brazilian Journal of Biology**, v. 70, n. 3 suppl, p. 825–829, out. 2010.

MATTHEWS, M. W.; BERNARD, S.; ROBERTSON, L. An algorithm for detecting trophic status (chlorophyll-a), cyanobacterial-dominance, surface scums and floating vegetation in inland and coastal waters. **Remote Sensing of Environment**, v. 124, p. 637–652, 1 set. 2012.

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. <https://doi.org/10.1080/01431169608948714>, v. 17, n. 7, p. 1425–1432, 2007.

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, 15 fev. 2012.

MOHSENI, F. *et al.* Ocean water quality monitoring using remote sensing techniques: A review. **Marine Environmental Research**, v. 180, p. 105701, set. 2022.

MONTGOMERY, D. C.; RUNGER, G. C.; HUNBELE, N. F. **Estatística aplicada à engenharia**. LTC ed. [s.l: s.n.].

MULIA, I. E. *et al.* Hybrid ANN-GA model for predicting turbidity and chlorophyll-a concentrations. **Journal of Hydro-Environment Research**, v. 7, n. 4, p. 279–299, dez. 2013.

NECHAD, B.; RUDDICK, K. G.; PARK, Y. Calibration and validation of a generic multisensor algorithm for mapping of total suspended matter in turbid waters. **Remote Sensing of Environment**, v. 114, n. 4, p. 854–866, 15 abr. 2010.

NOVO, E. M. L. DE M. **Sensoriamento Remoto: princípios e aplicações**. [s.l.] Editora Blucher, 2010.

OLMANSON, L. G.; BREZONIK, P. L.; BAUER, M. E. Evaluation of medium to low resolution satellite imagery for regional lake water quality assessments. **Water Resources Research**, v. 47, n. 9, set. 2011.

OLMANSON, L. G.; BREZONIK, P. L.; BAUER, M. E. Remote sensing for regional lake water quality assessment: Capabilities and limitations of current and upcoming satellite systems. **Handbook of Environmental Chemistry**, v. 33, p. 111–140, 2015.

O'NEIL, J. M. *et al.* The rise of harmful cyanobacteria blooms: The potential roles of eutrophication and climate change. **Harmful Algae**, v. 14, p. 313–334, fev. 2012.

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**, v. 2020, p. 8858408, 2020.

PAHLEVAN, N. *et al.* Sentinel-2 MultiSpectral Instrument (MSI) data processing for aquatic science applications: Demonstrations and validations. **Remote Sensing of Environment**, v. 201, p. 47–56, 1 nov. 2017.

PAHLEVAN, N. *et al.* Sentinel-2/Landsat-8 product consistency and implications for monitoring aquatic systems. **Remote Sensing of Environment**, v. 220, p. 19–29, 1 jan. 2019.

PERILLA, G. A.; MAS, J.-F. Google Earth Engine (GEE): una poderosa herramienta que vincula el potencial de los datos masivos y la eficacia del procesamiento en la nube. **Investigaciones Geográficas**, n. 101, 31 mar. 2020.

PIEDRAS, S. R. N. *et al.* Macroinvertebrados bentônicos como indicadores de qualidade de água na Barragem Santa Bárbara, Pelotas, RS, Brasil. **Ciência Rural**, v. 36, n. 2, p. 494–500, 2006.

POMPÊO, M. *et al.* Water quality assessment using Sentinel-2 imagery with estimates of chlorophyll a, Secchi disk depth, and Cyanobacteria cell number: the Cantareira System reservoirs (São Paulo, Brazil). **Environmental Science and Pollution Research**, v. 28, n. 26, p. 34990–35011, 4 jul. 2021.

RAMADAS, M.; SAMANTARAY, A. K. Applications of remote sensing and GIS in water quality monitoring and remediation: a state-of-the-art review. Em: **Water remediation**. [s.l.] Springer, 2018. p. 225–246.

RITCHIE, J. C.; SCHIEBE, F. R.; MCHENRY, J. R. Remote sensing of suspended sediments in surface waters. **Photogramm. Eng. Remote Sens**, v. 42, p. 1539–1545, 1976.

RITCHIE, J. C.; ZIMBA, P. V.; EVERITT, J. H. Remote Sensing Techniques to Assess Water Quality. **Photogrammetric Engineering & Remote Sensing**, v. 69, n. 6, p. 695–704, 1 jun. 2003.

ROUSE JR, J. W. *et al.* **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. [s.l.: s.n.].

SABERIOON, M. *et al.* Chlorophyll-a and total suspended solids retrieval and mapping using Sentinel-2A and machine learning for inland waters. **Ecological Indicators**, v. 113, 1 jun. 2020.

SAGAN, V. *et al.* 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, jun. 2020.

SALISBURY, J. *et al.* Spatial and temporal coherence between Amazon River discharge, salinity, and light absorption by colored organic carbon in western tropical Atlantic surface waters. **Journal of Geophysical Research: Oceans**, v. 116, n. C7, p. 2011JC006989, 23 jul. 2011.

SANEP. **Sistemas de Captação**. Disponível em: <<https://portal.sanep.com.br/agua/sistema-captacao>>. Acesso em: 16 set. 2021.

SANT'ANNA, C. L. **Manual ilustrado para identificação e contagem de cianobactérias plântonicas de águas continentais brasileiras**. São Paulo: Sociedade Brasileira de Ficologia, 2006.

SAUNITTI, R. M.; FERNANDES, L. A.; BITTENCOURT, A. V. L. Estudo do assoreamento do reservatório da barragem do rio Passaúna-Curitiba-PR. **Boletim Paranaense de Geociências**, v. 54, 2004.

SHI, K. *et al.* Remote estimation of cyanobacteria-dominance in inland waters. **Water Research**, v. 68, p. 217–226, 1 jan. 2015.

SHI, K. *et al.* Remote sensing of cyanobacterial blooms in inland waters: present knowledge and future challenges. **Science Bulletin**, v. 64, n. 20, p. 1540–1556, out. 2019.

SHOURIAN, M.; MORIDI, A.; KAVEH, M. Modeling of eutrophication and strategies for improvement of water quality in reservoirs. **Water Science and Technology**, v. 74, n. 6, p. 1376–1385, 2016.

SILVA, A. C.; SOUZA, A. M.; DUTRA, I. S. Ocorrência de algas cianofíticas em água de dessedentação de bovinos criados extensivamente. **Pesquisa Veterinária Brasileira**, v. 34, n. 5, p. 415–420, 2014.

SILVA, L. C. DA *et al.* Invasion of the dinoflagellate *Ceratium furcoides* (Levander) Langhans 1925 at tropical reservoir and its relation to environmental variables. **Biota Neotropica**, v. 12, n. 2, p. 93–100, 2012.

SIMON, A. L. H.; TRENTIN, G.; CUNHA, C. M. L. DA. Avaliação da dinâmica do uso da terra na Bacia do Arroio Santa Aárbara – Pelotas (Brasil). **Scripta Nova: revista electrónica de geografía y ciencias sociales**, v. 14, 2010.

SLONECKER, T. *et al.* Hyperspectral Reflectance Characteristics of Cyanobacteria. **Advances in Remote Sensing**, v. 10, n. 03, p. 66–77, 2021.

SOBRAL, M. DO C. *et al.* Geotecnologias na gestão de reservatórios: uma revisão e uma proposta de integração. **Engenharia Sanitaria e Ambiental**, v. 22, n. 5, p. 841–852, 1 set. 2017.

SOVDAT, B. *et al.* Natural color representation of Sentinel-2 data. **Remote Sensing of Environment**, v. 225, p. 392–402, 1 maio 2019.

STUMPF, R. P. *et al.* Challenges for mapping cyanotoxin patterns from remote sensing of cyanobacteria. **Harmful Algae**, v. 54, p. 160–173, abr. 2016.

TELUGUNTLA, P. *et al.* A 30-m landsat-derived cropland extent product of Australia and China using random forest machine learning algorithm on Google Earth Engine cloud computing platform. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 144, p. 325–340, 1 out. 2018.

TOMING, K. *et al.* First Experiences in Mapping Lake Water Quality Parameters with Sentinel-2 MSI Imagery. **Remote Sensing**, v. 8, n. 8, p. 640, 5 ago. 2016.

USALI, N.; ISMAIL, M. H. Use of remote sensing and GIS in monitoring water quality. **Journal of sustainable development**, v. 3, n. 3, p. 228, 2010.

VIRDIS, S. G. P. *et al.* Remote sensing of tropical riverine water quality using sentinel-2 MSI and field observations. **Ecological Indicators**, v. 144, p. 109472, 1 nov. 2022.

VISO-VÁZQUEZ, M. *et al.* Remote Detection of Cyanobacterial Blooms and Chlorophyll-a Analysis in a Eutrophic Reservoir Using Sentinel-2. **Sustainability**, v. 13, n. 15, p. 8570, 31 jul. 2021.

WANG, L. *et al.* Mapping Freshwater Chlorophyll-a Concentrations at a Regional Scale Integrating Multi-Sensor Satellite Observations with Google Earth Engine. **Remote Sensing**, v. 12, n. 20, p. 3278, 9 out. 2020.

WATANABE, F. S. Y. *et al.* Estimation of chlorophyll-a concentration and the trophic state of the barra bonita hydroelectric reservoir using OLI/landsat-8 images. **International Journal of Environmental Research and Public Health**, v. 12, n. 9, p. 10391–10417, 2015.

WEBER, S. J. *et al.* Risks for cyanobacterial harmful algal blooms due to land management and climate interactions. **Science of the Total Environment**, v. 703, p. 134608, 2020.

XAVIER, S. C. **Mapeamento geotécnico aplicado ao planejamento do uso e ocupação do solo da cidade de Pelotas/RS: estudo voltado à expansão urbana.** Tese (Doutorado em Engenharia Civil)—Porto Alegre - RS: Universidade Federal do Rio Grande do Sul, 2017.

ZHAO, J. *et al.* Remote Sensing Evaluation of Total Suspended Solids Dynamic with Markov Model: A Case Study of Inland Reservoir across Administrative Boundary in South China. **Sensors**, v. 20, n. 23, p. 6911, 3 dez. 2020.

ZHAO, Q. *et al.* Progress and trends in the application of google earth and google earth engine. **Remote Sensing**, v. 13, n. 18, p. 3778, 2 set. 2021.

## **Apêndices**

## **Apêndice A – Código para processamento de imagem no *Google Earth Engine***

```
// PONTOS DE AMOSTRAGEM //////////////////////////////////////
/*AMOSTRAGEM 17/02/2022
var ST2 = ee.Geometry.Point([-52.36909, -31.72041]);
var SB2 = ee.Geometry.Point([-52.37029, -31.71408]);
var PC2 = ee.Geometry.Point([-52.38109, -31.70729]);
var AMB2 = ee.Geometry.Point([-52.37948, -31.71306]);
var HOTEL2 = ee.Geometry.Point([-52.37498, -31.72026]);
var MEIO2 = ee.Geometry.Point([-52.37604, -31.72366]);
var TAIPA2 = ee.Geometry.Point([-52.36977, -31.72893]);

///AMOSTRAGEM 28/03/2022
var ST3 = ee.Geometry.Point([-52.36900, -31.72386]);
var SB3 = ee.Geometry.Point([-52.37039, -31.71405]);
var PC3 = ee.Geometry.Point([-52.38050, -31.70716]);
var AMB3 = ee.Geometry.Point([-52.37927, -31.71263]);
var HOTEL3 = ee.Geometry.Point([-52.37519, -31.72035]);
var MEIO3 = ee.Geometry.Point([-52.37633, -31.72402]);
var TAIPA3 = ee.Geometry.Point([-52.36938, -31.72866]);
var CAPT3 = ee.Geometry.Point([-52.36674, -31.72630]);

// AMOSTRAGEM 04/11/2022
var ST4 = ee.Geometry.Point([-52.36799, -31.72296]);
var SB4 = ee.Geometry.Point([-52.37001, -31.71454]);
var PC4 = ee.Geometry.Point([-52.38006, -31.70549]);
var AMB4 = ee.Geometry.Point([-52.38015, -31.71176]);
var HOTEL4 = ee.Geometry.Point([-52.37599, -31.71874]);
var MEIO4 = ee.Geometry.Point([-52.37597, -31.72303]);
var TAIPA4 = ee.Geometry.Point([-52.37147, -31.72809]);
var CAPT4 = ee.Geometry.Point([-52.36682, -31.72593]);

// Poligono da BSB
var roi= ee.FeatureCollection('users/dmartinsampaio/SantaBarbara');

////////////////////////////////////*/
```

```

// Função para mascarar nuvens usando QA60 (Sentinel-2)
function maskS2clouds(image) {
  var qa = image.select('QA60');

  // Bits 10 e 11 - clouds/cirrus.
  var cloudBitMask = 1 << 10;
  var cirrusBitMask = 1 << 11;

  // Ambos os sinalizadores devem ser definidos como zero, indicando condições
  claras.
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0)
    .and(qa.bitwiseAnd(cirrusBitMask).eq(0));

  return image.updateMask(mask).divide(10000);
}

////////////////////////////////////

//Carregando a imagem Sentinel-2 Level 2A (harmonizada)
var s2_geral = ee.ImageCollection('COPERNICUS/S2_SR_HARMONIZED')
  .filter(ee.Filter.eq("MGRS_TILE",'22HCK'))// usar somente a cena HCK, que
  abrange toda a Barragem Santa Bárbara
  // ativo/inativo a linha da imagem da data escolhida
  // .filterDate('2022-02-15', '2022-02-18') // (17/02)
  // .filterDate('2022-03-27', '2022-03-30') // (28/03)
  .filterDate('2022-10-28', '2022-10-31') // (29/10)
  .map(maskS2clouds)
  .filterBounds(roi) // para a região escolhida

// Função 'clip collection'
var function_clip = function(image) {
  return image.clip(roi);
};

// Aplicando a função

```

```

var s2 = s2_geral.map(function_clip);

var s2_image = s2.first()

// Para visualizar a imagem na coloração 'natural' RGB
var paletalmagenes = {bands:['B4', 'B3', 'B2'], min: 0.01, max: 0.2};

//Map.addLayer(s2, paletalmagenes, 'RGB');
Map.centerObject(roi, 13);

// Procedimento de reamostragem
var b8 = s2.select('B8'); // 10-m resolution
var b2 = s2.select('B2'); // 10-m resolution
var b3 = s2.select('B3'); // 10-m resolution
var b4 = s2.select('B4'); // 10-m resolution
var b5 = s2.select('B5'); // 20-m resolution
var b6 = s2.select('B6'); // 20-m resolution
var b7 = s2.select('B7'); // 20-m resolution
var b8a = s2.select('B8A'); // 20-m resolution
var b11 = s2.select('B11'); // 20-m resolution
var b12 = s2.select('B12'); // 20-m resolution

var proj_10m = b8.first();//Acessar a primeira imagem da coleção
    .projection();//projeção para uma resolução de 10m

// B5 =====
function resample(image) {
    var b5 = image.select('B5');
    var b5_res = b5.resample('bilinear').reproject(proj_10m);
    return b5_res;
}
var b5_res =b5.map(resample)

// B6 =====
function resample6(image) {
    var b6 = image.select('B6');

```

```

    var b6_res = b6.resample('bilinear').reproject(proj_10m);
    return b6_res;
}
var b6_res =b6.map(resample6)

// B7 =====
function resample7(image) {
    var b7 = image.select('B7');
    var b7_res = b7.resample('bilinear').reproject(proj_10m);
    return b7_res;
}
var b7_res =b7.map(resample7)

// B8A =====
function resample8a(image) {
    var b8a = image.select('B8A');
    var b8a_res = b8a.resample('bilinear').reproject(proj_10m);
    return b8a_res;
}
var b8A_res =b8a.map(resample8a)

// B11 =====
function resample11(image) {
    var b11 = image.select('B11');
    var b11_res = b11.resample('bilinear').reproject(proj_10m);
    return b11_res;
}
var b11_res =b11.map(resample11)

// B12 =====
function resample12(image) {
    var b12 = image.select('B12');
    var b12_res = b12.resample('bilinear').reproject(proj_10m);
    return b12_res;
}
var b12_res =b12.map(resample12)

```

```

// Paleta de cores ///
Var paletalmagenes2 = {"bands":"B2","min":0.06,"max":0.2,"gamma":[1.44]}
var paletalmagenes3 = {"bands":"B3","min":0.06,"max":0.2,"gamma":[1.44]}
var paletalmagenes4 = {"bands":"B4","min":0.06,"max":0.2,"gamma":[1.44]}
var paletalmagenes8 = {"bands":"B8","min":0.06,"max":0.2,"gamma":[1.44]}
var paletalmagenes5 = {"bands":"B5","min":0.06,"max":0.2,"gamma":[1.44]}
var paletalmagenes6 = {"bands":"B6","min":0.06,"max":0.2,"gamma":[1.44]}
var paletalmagenes7 = {"bands":"B7","min":0.06,"max":0.2,"gamma":[1.44]}
var paletalmagenes8A = {"bands":"B8A","min":0.06,"max":0.2,"gamma":[1.44]}
var paletalmagenes11 = {"bands":"B11","min":0.06,"max":0.2,"gamma":[1.44]}
var paletalmagenes12 = {"bands":"B12","min":0.06,"max":0.2,"gamma":[1.44]}

//Map.addLayer(s2,paletalmagenes,'original');

/*/ Bandas 10m
Map.addLayer(b2,paletalmagenes2,'b2_10m');
Map.addLayer(b3,paletalmagenes3,'b3_10m');
Map.addLayer(b4,paletalmagenes4,'b4_10m');
Map.addLayer(b5_res,paletalmagenes5,'b5_10m');
Map.addLayer(b6_res,paletalmagenes6,'b6_10m');
Map.addLayer(b7_res,paletalmagenes7,'b7_10m');
Map.addLayer(b8,paletalmagenes8,'b8_10m');
Map.addLayer(b8A_res,paletalmagenes8A,'b8A_10m');
Map.addLayer(b11_res,paletalmagenes11,'b11_10m');
Map.addLayer(b12_res,paletalmagenes12,'b12_10m');
/*/

// Transformando em imagem
var s2_image = s2.first()
var b5_res_image = b5_res.first()
var b6_res_image = b6_res.first()
var b7_res_image = b7_res.first()
var b8a_res_image = b8A_res.first()

// Nomeando pelas bandas Sentinel-2

```

```

var B3 = s2_image.select('B3');
var B4 = s2_image.select('B4');
var B5 = b5_res_image.select('B5');
var B6 = b6_res_image.select('B6');
var B7 = b7_res_image.select('B7');
var B8 = s2_image.select('B8');
var B8A = b8a_res_image.select('B8A');

// NDVI
var ndvi = B8.subtract(B4).divide(B8.add(B4)).rename('NDVI');
Map.centerObject(roi, 13);
var ndviParams = {min: -0.5, max: 0.5, palette: ['red', 'white', 'green']};
Map.addLayer(ndvi, ndviParams, 'NDVI image');

// NDCI
var ndci = B5.subtract(B4).divide(B5.add(B4)).rename('NDCI');
Map.centerObject(roi, 13);
var ndciParams = {min: -0.15, max: 0.62, palette: ['red', 'white', 'green']};
Map.addLayer(ndci, ndciParams, 'NDCI image');

// Índice de Toming
var IT = B5.subtract((B4).divide(B6).divide(2.0)).rename('IT');
Map.centerObject(roi, 13);
var ITParams = {min: -1, max: 0.1, palette: ['red', 'white', 'green']};
Map.addLayer(IT, ITParams, 'Toming image');

/// MODELAGENS //////////////////////////////////////

// MODELO DE CLOROFILA
var Chla = (B3.divide(B4).multiply(669.0))
    .add(B5.divide(B4).multiply(386.0))
    .subtract(B6.divide(B4).multiply(4438.0))
    .add(B7.divide(B4).multiply(3324.0))
    .add(B8.divide(B4).multiply(982.0))
    .subtract(682.0)
    .rename('Chla');

```

```
Map.centerObject(roi, 13);
var ChlaParams = {min: 0, max: 700, palette: ['red', 'white', 'green']};
Map.addLayer(Chla, ChlaParams, 'Chl-a model');
```

```
// MODELO DE SÓLIDOS SUSPENSOS TOTAIS
var SST = (B5.multiply(243.2)).add(B6.divide(B4).multiply(154.1))
    .subtract(B8.divide(B4).multiply(153.3))
    .subtract(21.1)
    .rename('SST');
```

```
Map.centerObject(roi, 13);
var SSTParams = {min: 0, max: 40, palette: ['red', 'white', 'green']};
Map.addLayer(SST, SSTParams, 'SST model');
```

```
// MODELO DE CERATIUM
var ctm = (B3.divide(B4).multiply(4460.0))
    .add(B5.divide(B4).multiply(2573.0))
    .subtract(B6.divide(B4).multiply(29586.0))
    .add(B7.divide(B4).multiply(22160.0))
    .add(B8.divide(B4).multiply(6546.0))
    .subtract(4898.0)
    .rename('Ceratum');
```

```
Map.centerObject(roi, 13);
var ctmParams = {min: 0, max: 4000, palette: ['red', 'white', 'green']};
Map.addLayer(ctm, ctmParams, 'Ceratum model');
```

```
// DOWNLOAD DAS IMAGENS //////////////////////////////////////
Export.image.toDrive({image:ndci, description: 'ndci_28030', folder:
'Dissertação_2803',fileNamePrefix:'ndci_2803',scale:10, crs: 'EPSG:4326',
maxPixels: 1e13, region: roi,
fileFormat:'GeoTIFF'});
```