

SENTINEL-2 MSI APLICADO À ESTIMATIVA DA QUALIDADE DA ÁGUA DA LAGOA RODRIGO DE FREITAS (RIO DE JANEIRO, BRASIL)**SENTINEL-2 MSI APPLIED TO ESTIMATING WATER QUALITY IN RODRIGO DE FREITAS LAGOON (RIO DE JANEIRO, BRAZIL)****SENTINEL-2 MSI APLICADO A LA ESTIMACIÓN DE LA CALIDAD DEL AGUA DE LA LAGUNA RODRIGO DE FREITAS (RÍO DE JANEIRO, BRASIL)****Hullysses Sabino**Departamento de Geografia, Universidade Federal do Rio de Janeiro (UFRJ), E-mail: hsabino@ufrj.br <https://orcid.org/0000-0002-3200-9507>**Sandra Baptista da Cunha**Departamento de Geografia, Universidade Federal Fluminense (UFF), E-mail: sandracunha51@gmail.com <https://orcid.org/0000-0003-2496-6603>**Juliana Menezes**Departamento de Análise Geoambiental, Universidade Federal Fluminense (UFF), E-mail: juliana_menezes@id.uff.br <https://orcid.org/0009-0001-1157-8962>

RESUMO: A qualidade da água de lagoas costeiras urbanas é altamente relacionada com a intensidade dos processos naturais, tais como eventos meteorológicos e oceanográficos, e antrópicos, como despejo de esgoto sem tratamento e escoamento urbano. Diante desse cenário, as análises hidroquímicas feitas pontualmente são insuficientes para ampla compreensão das características gerais da massa d'água. O objetivo do estudo foi desenvolver uma metodologia para estimar com acurácia os teores de parâmetros qualitativos de toda massa d'água da lagoa Rodrigo de Freitas (RJ, Brasil). Os parâmetros clorofila-*a*, turbidez e transparência foram estimados empregando imagens do sensor Sentinel 2 Multispectral Imager (MSI). A variação sazonal desses parâmetros foi analisada de 2018 a 2022. Ao todo, foram empregados 101 modelos para identificar a melhor associação entre os dados *in situ* e a reflectância espectral. As correlações foram averiguadas por abordagens estatísticas (e.g., r^2 , PBIAS, valor de p entre outros). O teor da clorofila-*a* não foi recuperável, possivelmente devido a sua reduzida concentração. A turbidez foi melhor estimada pelo modelo $(3.0221 \wedge (2.0488 * (\text{aerossol/verde})))$, com $R^2 = 0,66$, PBIAS = 8,1 % e valor de $p < 0,001$. Ao passo que a transparência obteve melhores valores extraídos da banda do aerossol, com $R^2 = 0,68$, PBIAS = 31% e $p\text{-value} = < 0,001$. Esses resultados tiveram uma precisão moderada, uma tendência à superestimativa e as correlações foram estatisticamente significativas. Essas estimativas lograram indicar padrões espaciais e temporais dos parâmetros. Embora foram encontradas estimativas moderadas do teor de parâmetros qualitativos da lagoa, este foi um dos primeiros esforços de monitoramento ambiental desse ecossistema urbano complexo, fornecendo uma base complementar para análises, tomada de decisão e planejamento ambiental.

Palavras-chave: Turbidez, Transparência, Monitoramento ambiental.

ABSTRACT: Water quality of urban coastal lagoons is closely linked to the intensity of natural processes, such as meteorological and oceanographic events, and anthropogenic processes, including raw sewage discharge and urban runoff. Within this context, occasional hydrochemical analyses are insufficient for a comprehensive understanding of the general characteristics of the water body. The objective of this study was to develop a methodology to accurately estimate the levels of qualitative parameters across the entire water body of Rodrigo de Freitas Lagoon (RJ, Brazil). Chlorophyll-a, turbidity, and transparency were estimated using images from the Sentinel-2 Multispectral Imager (MSI) sensor. The seasonal variation of these parameters was analyzed between 2018 and 2022. In total, 101 models were employed to identify the best fit between in situ data and spectral reflectance. Correlations were assessed using statistical approaches (e.g., r^2 , PBIAS, p-value, among others). Chlorophyll-a content was not recoverable, possibly due to its low concentration. Turbidity was best estimated by model $(3.0221 \wedge (2.0488 * (\text{aerosol}/\text{green})))$ with $R^2 = 0.66$, PBIAS = 8.1%, and p-value < 0.001. Transparency, on the other hand, yielded better values extracted from the aerosol band, with $R^2 = 0.68$, PBIAS = 31%, and p-value < 0.001. These results showed moderate accuracy, a tendency to overestimation, and statistically significant correlations. These estimates were able to reveal spatial and temporal patterns of the parameters. Although moderate estimates of the lagoon's qualitative parameters were found, this was one of the first environmental monitoring efforts of this complex urban ecosystem, providing a complementary basis for analysis, decision-making, and environmental planning.

Keywords: Turbidity, Transparency, Environmental monitoring.

RESUMEN: La calidad del agua de las lagunas costeras urbanas está estrechamente relacionada con la intensidad de los procesos naturales, como los fenómenos meteorológicos y oceanográficos, y antropogénicos, como el vertido de aguas residuales sin tratar y la escorrentía urbana. Ante este panorama, los análisis hidroquímicos realizados de forma puntual resultan insuficientes para comprender en profundidad las características generales de la masa de agua. El objetivo del estudio fue desarrollar una metodología para estimar con precisión los valores de los parámetros cualitativos de toda la masa de agua de la laguna Rodrigo de Freitas (RJ, Brasil). Los parámetros clorofila-a, turbidez y transparencia se estimaron utilizando imágenes del sensor Sentinel 2 MSI. Se analizó la variación estacional de estos parámetros entre 2018 y 2022. En total, se emplearon 101 modelos para identificar la mejor asociación entre los datos in situ y la reflectancia espectral. Las correlaciones se evaluaron mediante enfoques estadísticos (por ejemplo, r^2 , PBIAS, valor de p , entre otros). El contenido de clorofila-a no fue recuperable, posiblemente debido a su baja concentración. La turbidez se estimó mejor mediante el modelo $(3,0221 \wedge (2,0488 * (\text{aerosol}/\text{verde})))$, con $R^2 = 0,66$, PBIAS = 8,1 % y valor de $p < 0,001$. Por su parte, la transparencia obtuvo mejores valores a partir de la banda de aerosoles, con $R^2 = 0,68$, PBIAS = 31% y valor $p = < 0,001$. Estos resultados mostraron una precisión moderada, una tendencia a la subestimación y correlaciones estadísticamente significativas. Estas estimaciones permitieron identificar patrones espaciales y temporales de los parámetros. Aunque se obtuvieron estimaciones moderadas del contenido de los parámetros cualitativos de la laguna, este fue uno de los primeros esfuerzos de monitoreo ambiental de este complejo ecosistema urbano, lo que proporcionó una base complementaria para el análisis, la toma de decisiones y la planificación ambiental.

Palabras clave: Turbidez, Transparencia, Monitoreo ambiental.

1. INTRODUÇÃO

Corpos d'água urbanos, como rios e lagos, exigem evolução no método de avaliação diante das intervenções diretas, como assoreamento e escoamento, e indiretas, como as mudanças climáticas. A análise pontual é acurada para precisar o teor de parâmetros qualitativos, contudo requer consideráveis recursos laboratoriais, de tempo e financeiros para sua execução (HAJIGHOLIZADEH *et al.*, 2021; SABINO, 2025). O uso da tecnologia de sensoriamento remoto tem sido empregado para análise qualitativa hídrica em grande escala geográfica e temporal (LOBO *et al.*, 2021; MAPELLI, 2025; PAHLEVAN *et al.*, 2022). Os parâmetros físico-químicos que logram modificar a resposta espectral da coluna d'água são referidos como “ópticamente ativos” (FACCO *et al.*, 2021; SIEGEL *et al.*, 2005). Entre eles, há aqueles que retratam a qualidade d'água, como a clorofila-a, turbidez e transparência d'água.

A clorofila é o pigmento verde que participa no processo de fotossíntese. Todos os organismos fotossintéticos, incluindo algas, cianobactérias, eucariotas e plantas, utilizam principalmente a forma de clorofila-a para libertar oxigênio. O teor de clorofila-a oscila de forma dinâmica no espaço-tempo e é fortemente influenciado por atividades antrópicas (e.g., descarga excessiva de fertilizante ou esgoto) e por fatores climáticos (e.g., vento de baixa altitude, precipitação, intensidade solar e temperatura da água) (CABALLERO *et al.*, 2022; IVANDA *et al.*, 2021; MASOUD, 2022). Dessa forma, a clorofila-a necessita ser continuamente monitorada em alta resolução temporal para tê-la como um eficiente indicador da qualidade da água (MASOUD, 2022). As propriedades ópticas e a dominância fotossintética das algas resultam na clorofila-a como biomassa representativa dos organismos fitoplancônicos, que, por sua vez, estão associados ao processo de eutrofização e são utilizados como indicador de estado trófico da água (DALLOSCH e CREED, 2021; LI *et al.*, 2022; MUSHTAQ *et al.*, 2022; PALTSEV e CREED, 2022; KIM *et al.*, 2022; LOBO *et al.*, 2021; MASOUD, 2022; PERRONE *et al.*, 2021). Por conseguinte, clorofila-a é um indicador importante da qualidade da água.

A resposta espectral da clorofila-a aos sensores orbitais é amplamente analisada na literatura, tendo em conta a sua influência na qualidade ambiental das massas de água. A clorofila-a possui coeficiente de absorção substancial na região do aerossol (~443 nm) e do azul (~496 nm) e maior no vermelho (~665 nm), e coeficiente de reflectância significativo na região do verde (~559 nm) e maior na borda vermelha 1 (~700 nm) em águas continentais (LOBO *et al.*, 2021; SHI *et al.*, 2022; TANG e HUANG, 2021; ZABALETA *et al.*, 2021). Considerando esses comportamentos espectrais, muitos índices e algoritmos recuperação remota do teor de clorofila-a são baseados na relação entre os canais de azul, verde, vermelho e borda do vermelho 1. Alguns dos índices mais conhecidos para extração remota de clorofila-a são Índice de Clorofila por Diferença Normalizada (NDCI, na sigla inglesa) (LOBO *et al.*, 2021; MISHRA e MISHRA, 2012; ZABALETA *et al.*, 2021), o Índice Máximo de Clorofila (MCI) (GOWER *et al.*, 2007), e outros algoritmos como aqueles apresentados por Fernández-Tejedor *et al.* (2022).

A turbidez e a transparência são parâmetros ópticos que mensuram, de modo distinto, a opacidade da coluna d'água e possuem natureza inversamente proporcional. A dificuldade da água para transmitir a luz pode ser causada por sólidos em suspensão, como partículas inorgânicas, areia, silte, argila, micro-organismos, matéria orgânica, metais, bactérias, entre outros elementos químicos e biológicos suspensos (SANTOS, 2008; UNITED STATES GEOLOGICAL SURVEY, 2018; ORGANIZAÇÃO MUNDIAL DA SAÚDE, 2017). A turbidez torna a água opaca ou turva, sendo medida em Unidade de Turbidez Nefelometria (NTU, sua sigla inglesa), ao passo que a transparência é mensurada pela distância da lâmina d'água até onde o disco de Secchi continua visível ao mensurador.

Alta turbidez causada por matéria orgânica pode preencher rapidamente lagoas, acelerar os processos de assoreamento e sedimentação, e causar morte da ictiofauna por asfixia devido obstrução branquial (BRANCO, 1983; UNITED STATES GEOLOGICAL SURVEY, 2018). Além disso, a elevação do nível de turbidez pode modificar a cor d'água, cessar a entrada de luz solar, limitando a fotossíntese e minorando o teor de oxigênio dissolvido na massa d'água após precipitações pluviométricas (BRANCO, 1983; TUNDISI e M. TUNDISI, 2008). Nesse cenário, o oxigênio dissolvido é consumido e, simultaneamente, tem sua produção fotossintética inibida ou interrompida, agravando as condições ambientais e propiciando episódios de mortandade da ictiofauna. A turbidez não afeta diretamente a saúde humana, porém serve como um indicativo da entrada de contaminantes e da presença de micro-organismos patogênicos (ORGANIZAÇÃO MUNDIAL DA SAÚDE, 2017). A turbidez possui maior absorção na faixa do aerossol (~443 nm) e do azul (~496 nm) e boa reflectância na região do vermelho (~665 nm), borda vermelha 2 (~750 nm), borda vermelha 3 (~782 nm) e NIR (~835 nm) (BHARGAVA e MARIAM, 1990; DOGLIOTTI *et al.*, 2015; FACCO *et al.*, 2021). A forte correlação entre a turbidez e o canal vermelho tem sido destacada na literatura (ABDELAL *et al.*, 2022; FACCO *et al.*, 2021). São utilizados vários algoritmos para a extração remota da turbidez, com destaque para o Índice de Turbidez por Diferença Normalizada (NDTI, em sua sigla inglesa) (FACCO *et al.*, 2021; LACAUX *et al.*, 2007; SABINO e MENEZES, 2022).

Os parâmetros físico-químicos e biológicos são indicadores importantes do comportamento e do equilíbrio ambiental das massas de água. Dentre os vários parâmetros, a clorofila-*a* e a turbidez assumem particular importância. O seu aumento está associado a processos de eutrofização, à proliferação de algas, à deterioração da qualidade da água, ao desequilíbrio das taxas de sedimentação (assoreamento e erosão) e ao stress ou degradação das relações dos ecossistemas aquáticos (CABALLERO *et al.*, 2022; ESTEVES, 2011).

A transparência da água é a quantidade de luz que penetra na coluna d'água, por conseguinte, é um importante indicativo da qualidade hídrica. Maior valor da transparência indica água mais cristalina e assinala a melhor qualidade d'água, enquanto que menor valor aponta a água com diversos elementos (PREISENDORFER, 1986). Esses elementos podem ser, concomitantemente ou não, de origem inorgânica (materiais em suspensão oriundos de processos erosivos, revolvimento do solo ou escoamento urbano) e de origem orgânica (algas e organismos fitoplanctônicos). O esgoto *in natura* apresenta elevado nível de turbidez e cores que variam de acinzentado a preto, que, quando em elevada concentração, reduzem a transparência da coluna d'água. A transparência tem maior absorção na região do vermelho (~665 nm) e do infravermelho, como na borda do vermelho 4 (~864 nm) (MUSHTAQ *et al.*, 2022), e maior reflectância no canal azul (~496 nm). Em geral, a transparência tem a resposta espectral oposta à turbidez (DEUTSCH *et al.*, 2021). A transparência d'água também é remotamente recuperada por múltiplos algoritmos expostos na literatura (ARIAS-RODRIGUEZ *et al.*, 2021; DEUTSCH *et al.*, 2021; MANSARAY *et al.*, 2021; MUSHTAQ *et al.*, 2022; POMPEO *et al.*, 2021; SORIANO-GONZÁLEZ *et al.*, 2022).

O monitoramento por sensoriamento remoto de parâmetros qualitativos possibilita compreender o comportamento hidroquímico e a degradação em larga escala geográfica e temporal de corpos hídricos (ASSUNÇÃO *et al.*, 2025; GERMÁN *et al.*, 2021; IVANDA *et al.*, 2021; KIM *et al.*, 2022; MAIA *et al.*, 2026; MANSARAY *et al.*, 2021; POMPEO *et al.*, 2021; VALERIO *et al.*, 2026). A lagoa urbana eutrófica Rodrigo de Freitas (Rio de Janeiro, Brasil) é secularmente alvo de esgoto *in natura* (BARÃO DE TEFFÉ, 1830, *apud* FEEMA, 1982), embora tenha grande potencial ambiental e turístico ainda subaproveitado. Dessa forma, o presente estudo teve como objetivo desenvolver uma metodologia para calibrar e validar modelos de estimação dos teores de parâmetros qualitativos empregando dados *in situ* de órgão

municipal e remotos do Sentinel-2 MultiSpectral Instrument Nível 2A para classificar suas características ao longo do espaço-tempo e para auxiliar na gestão ambiental.

2. ÁREA DE ESTUDO

A lagoa Rodrigo de Freitas (LRF) é uma célebre massa d'água da cidade do Rio de Janeiro, sendo a terceira maior em área. Ela possui cerca de 2,2 km², volume aproximado de 6,2 milhões m³ e profundidade média de 3 m, sendo mais rasa nas margens oeste e sudoeste, embora contenha algumas cavas com cerca de 9 metros de profundidade (FEEMA, 1982; ROSMAN, 2012). Ela está inserida em meio a mancha urbana da cidade do Rio de Janeiro, especificamente, na zona econômica mais rica do estado fluminense (**Figura 1**). Ela é rodeada por bairros de perfil socioeconômico elevado, como Ipanema, Leblon, Copacabana, Gávea, entre outros. Diante disso, a lagoa é amplamente visada pela população para fins de lazer, esportivo e turístico, além de ser fonte sustento para pescadores locais.




Figura 1 - Localização da bacia hidrográfica e rede hidrográfica da lagoa Rodrigo de Freitas, cidade do Rio de Janeiro (Brasil). Os pontos amarelos na lagoa referem-se aos pontos de monitoramento (LRF1 ao LRF6). Fonte dos dados: Data.Rio (2022) e IBGE (2022). Mapa: H. Sabino.

A bacia hidrográfica da LRF possui cerca de 23,5 km², dos quais 9 km² (38% da área total) estão urbanizados (Data.Rio, 2022). A área não-urbanizada encontra-se com características naturais preservadas e estende-se pela Serra da Carioca, onde nascem os principais rios da bacia. A bacia da LRF engloba três sub-bacias hidrográficas: a do rio Rainha (descarga de 4,1 m³/s), Macacos (3,4 m³/s) e Cabeças (0,68 m³/s) (SERLA, 1990). Esses três rios são tributários da LRF. Contudo, um reduzido volume de água fluvial contribui para a LRF devido ao sistema de

comportas controladas pela Prefeitura, que encaminha o fluxo fluvial e de parte do escoamento urbano para os canais da rua General Garzon, do Jóquei e da rua Visconde de Albuquerque para lançamento na praia do Leblon ou no emissário submarino. Em contrapartida à reduzida vazão dos rios tributários, na LRF há 35 pontos de deságue, oficialmente classificados como “ponto de drenagem de águas pluviais” (SMAC/Rio-Águas, 2026).

A lagoa está inserida em meio a planícies fluviais e fluvio-marinhas e rodeada por morros, com destaque para a Serra da Carioca, que limita a bacia a oeste e norte. Embora seja denominada como “lagoa” de forma oficial e popular, ela é uma laguna, diante da sua morfogênese relacionada ao barramento por depósitos litorâneos holocênicos (onde estão os bairros de Leblon e Ipanema) e a manutenção de uma ligação direta com o mar.

A região apresenta clima Af (equatorial, sempre úmido) conforme a classificação de Köppen (MAIOR, 1954 *apud* SANTANA *et al.*, 2005). A bacia hidrográfica da LRF abriga uma estação pluviométrica do Sistema Alerta Rio (2026) da Prefeitura do Rio de Janeiro no bairro do Jardim Botânico. Durante o período de estudo (2018 a 2022), a bacia hidrográfica registrou volume médio de precipitação de 1688 mm por ano¹. Os maiores volumes ocorram nos meses de verão e os menores volumes, nos meses inverniais (**Figura 2**). Provavelmente, a precipitação individual com maior volume registrado foi aquela ocorrida em abril de 2019 com 334,4 mm em 24 horas (ALERTA RIO, 2024).




Figura 2 - Acumulado mensal de precipitação na estação Jardim Botânico, dentro da bacia hidrográfica da lagoa Rodrigo de Freitas entre 2018 e 2022. Dados de dezembro de 2021 e 2022 indisponíveis. Dados: Sistema Alerta Rio (2026).

LRF sempre foi alvo da atenção midiática e de múltiplos registros da sua situação ambiental. O histórico de poluição da LRF remonta ao séc. XIX com relatos da sua contaminação e descontentamento da população local (BARÃO de TEFFÉ, 1830 *apud* FEEMA,

¹ Os dados do Sistema Alerta Rio (2026) não registraram o volume precipitado mensalmente no mês de dezembro de 2021 e 2022, logo, esses anos apresentaram acumulados inferiores aos demais.

1982). A sua bacia hidrográfica abrigou cerca de 4% de todas as fábricas do estado do Rio de Janeiro, em especial as de tecidos, e, posteriormente, registrou a existência de diversas favelas e comunidades urbanas (Parques Proletariados, favelas da Praia do Pinto, do Capinzal, do Largo da Memória, da Ilha das Dragas e da Catacumba) com baixo ou nenhum nível saneamento básico e com esgoto *in natura* lançado em valões que escorria para a lagoa (CORREIO da MANHÃ, 1961; INSTITUTO RIO PATRIMÔNIO da HUMANIDADE, 2012; JORNAL do BRASIL, 1970). A lagoa apresenta distintos estados avançados de eutrofização (eutrófica, supereutrófica, hipereutrófica) em sua história, além de ter registrado dezenas de mortandades de peixes durante os séculos XX e XXI, conforme Sabino (2025).

3. MATERIAL E MÉTODOS

O presente item foi desenvolvido para detalhar os procedimentos metodológicos adotados para a estimativa remota dos parâmetros qualitativos de clorofila-*a*, turbidez e transparência na laguna Rodrigo de Freitas de 2018 a 2022. Foi apresentado a estruturação e integração de um robusto banco de dados *in situ*, proveniente da SMAC/RioÁguas, com dados de reflectância de superfície do satélite Sentinel-2 processados via Google Earth Engine. Para viabilizar a análise do grande volume de informações, foram desenvolvidos códigos em *Visual Basic for Applications* para automação do tratamento de dados e “pareamento temporal” (*match-up*), além da implementação de rotinas em linguagem R para a análise estatística. O rigor metodológico fundamentou-se em etapas de calibração e validação independentes, submetendo os dados a 101 modelos matemáticos para identificar as correlações de maior acurácia e significância estatística.

3.1. Dados de clorofila-*a*, turbidez e transparência

Os parâmetros qualitativos opticamente ativos e indicadores da qualidade de água selecionados para análise foram clorofila-*a*, turbidez e transparência. O banco de dados desses parâmetros mensurados foram disponibilizados pela Secretaria Municipal do Ambiente e Clima e a Fundação Rio-Águas da cidade do Rio de Janeiro (SMAC/RioÁguas, 2022). O período analisado de 2018 a 2022.

As mensurações na lagoa foram feitas a partir de 6 pontos de monitoramento (LRF1, LRF2, LRF3, LRF4, LRF5 e LRF6) (**Tabela 1, Figura 1**). Esses 6 pontos são posições geográficas conhecidas visitadas duas vezes por semana pelos técnicos da SMAC/RioÁguas. Os teores trabalhados nesse estudo correspondem às mensurações feitas no epilânio (superfície) da lagoa (0,3 m de profundidade). A transparência foi mensurada por meio do disco de Secchi (PREISENDORFER, 1986).

A SMAC/Rio-Águas também disponibilizou a concentração de clorofila-*a* e os níveis de turbidez mensurados automaticamente em intervalos de 30 minutos por sua estação de monitoramento contínuo localizada próxima da LRF3. Essa estação comporta a sonda multiparamétrica Hydrolab DS5X. A sonda mensura clorofila-*a* na faixa de 0 a 500 µg/L com precisão de ± 3% para equivalentes de nível de sinal de 1 ppb de corante rodamina WT e turbidez no intervalo de detecção de 0 a 1000 NTU e precisão de ± 5% de leitura. À vista que a turbidez foi mensurada por uma equipe técnica *in situ* e também pela sonda, criou-se dois bancos de dados distintos: ‘turbidez/manual’ e ‘turbidez/sonda’. Os teores de turbidez/manual foram amostrados em todos os seis pontos de monitoramento, enquanto que os teores de turbidez/sonda ficaram restritos à estação de monitoramento automático. A turbidez/manual foi mensurada pelo método 2130 (B) da APHA (2017) com limite mínimo de quantificação de 1,5 NTU.

Tabela 1 - Localização aproximada dos pontos analisados *in situ* na lagoa Rodrigo de Freitas.

ID	Latitude	Longitude
LFR1	22°57'59.0"S	43°12'45.3"W
LFR2	22°57'58.0"S	43°12'23.5"W
LFR3	22°58'17.0"S	43°12'46.4"W
LFR4	22°58'35.0"S	43°12'15.7"W
LFR5	22°58'37.9"S	43°12'54.1"W
LFR6	22°58'45.8"S	43°12'23.3"W

3.2. Dados de Sensoriamento Remoto

As imagens de satélite do sensor Sentinel-2 MSI Nível 2A foram corrigidas atmosféricamente pelo processador Sen2Cor (*Sentinel 2 (Atmospheric) Correction*) desenvolvido e distribuído pela Agência Espacial Europeia (ESA, 2023). Elas foram empregadas neste estudo diante acurácia comprovada na literatura e perante a facilidade do acesso às imagens corrigidas no Google Earth Engine (GEE). As imagens do Sentinel-2 Nível 2A foram lançadas globalmente no dia 13 de dezembro de 2018 e o primeiro imageamento do Rio de Janeiro ocorreu 2 dias depois. Logo, a amostragem temporal deste estudo abrangeu inicialmente todas as imagens obtidas do dia 15 de dezembro de 2018 até 31 de dezembro de 2022.

Filtros foram aplicados para excluir imagens com interferências de nuvens e da reflexão especular da água (*sun glint*). Esses filtros foram descritos no item 3.3 e envolvem os procedimentos realizados no GEE, de onde as imagens foram inicialmente filtradas e seus dados de reflectância baixados, e em macros de *Excel*, onde o banco de dados foi editado e formatado.

3.3. Desenvolvimento dos códigos para extração, tratamento e análises estatísticas

Os dados das mensurações *in situ* dos parâmetros físicos e biológicos estavam distribuídos em centenas de abas em variadas planilhas de *Excel*, e os dados de reflectância estavam em múltiplas bandas espectrais distribuídas em dezenas de imagens de sensores remotos. Diante desse cenário, códigos de programação para automatizar extração, armazenamento e tratamento dos dados foram construídos, conforme métodos descritos a seguir.

3.3.1. Macros para Excel para extrair e tratar dados

O conjunto de dados enviado inicialmente pela SMAC/RioÁguas compreendeu ao período entre 2015 e 2022, que foi enviado 5 planilhas em formato Microsoft Excel, referentes aos anos de 2015, 2016, 2017-19, 2020-21 e 2022. Havia uma aba para cada dia analisado nas planilhas. Em cada aba, havia o mesmo conjunto de 15 a 16 parâmetros analisados para cada um dos seis pontos de monitoramento (LRF1 ao LRF6) mensurados em três ou cinco níveis de profundidade. Dessa forma, cada aba continha cerca de 270 dados das concentrações dos parâmetros. Cada uma das 5 planilhas recebidas continha diferentes quantidades de abas, variando entre 93 e 387 abas. O significativo volume de dados a ser selecionado, unido e organizado gerou a necessidade de implementação de códigos de programação de *Visual Basic for Applications* (VBA). O fluxo metodológico do tratamento dos dados é visto na **Figura 3**.




Figura 3 - Fluxograma das edições do banco de dados deste trabalho. LRF: Lagoa Rodrigo de Freitas. Os dados dos canais fluviais e dos sedimentos não foram empregados.

O VBA é um ambiente no pacote *Office* da Microsoft que permite o desenvolvimento de comandos a partir da escrita de linguagem de programação. Dentro de um módulo do VBA, é possível escrever uma sequência de códigos para a execução de inúmeros comandos e funções dos programas do *Office*. A sequência de códigos é chamada de macro. Criar e aplicar macros possibilita desenvolver diversos encadeamentos de comandos, automatizar funções repetitivas que são rapidamente exercidas e viabilizar análises de grande volume de dados.

Uma macro foi desenvolvida no Excel para juntar todos os dados de um mesmo ponto de monitoramento. Essa macro foi adaptada e aplicada 6 vezes (uma por ponto de monitoramento). Cada aplicação gerou uma nova aba que continha todos os dados de um ponto específico que foram exportados pela macro. Os dados de todos os anos de um mesmo ponto de monitoramento foram unidos em uma aba, aglutinando todos os dados do período trabalho (2015 a 2022). Ao concluir esse processo, todos os dados da lagoa ficaram dispostos em apenas 6 abas em suas respectivas planilhas.

Na planilha resultante, os dados de todas as profundidades analisadas estavam presentes no banco de dados de cada ponto de monitoramento. Para separá-los de acordo com os dados de profundidade (epilímnio, meio (eufótico e afótico) e hipolímnio) em quatro colunas distintas, quatro macros foram desenvolvidas. As macros foram modificadas para a coleta dos dados de cada uma das profundidades em cada ponto de monitoramento. Somente os dados do epilímnio foram empregados.

Apesar da clorofila-*a* e turbidez (sonda) serem mensurados a cada 30 minutos por sonda automática, somente as mensurações realizadas às 10 horas (UTC -3; 13 horas UTC) foram consideradas porque é o momento em que os satélites do Sentinel-2 (~10h02min) passam sobre o Rio de Janeiro. Quanto maior a proximidade temporal entre o dado *in situ* e o remoto, maior a acurácia da metodologia de recuperação remota da concentração de parâmetros ópticos. As mensurações *in situ* na lagoa realizadas pelas SMAC/RioÁguas ocorreram próximo às 10 h.

3.3.2. Extração dos valores da reflectância dos *pixels* no Google Earth Engine

Considerando a periodicidade de 5 dias da constelação Sentinel-2 MSI Nível 2A, o período de análise (dez/2018 a dez/2022) disponibilizou 296 séries temporais. O geoprocessamento de todo esse conjunto de dados por metodologias tradicionais² demandaria demasiado tempo de *download*, grande capacidade de armazenamento (~296 GB de memória para 296 datas³), um potente processador para trabalhar com os dados no *desktop* e grande tempo operacional. Por conta dessas múltiplas limitações ao geoprocessamento de grandes volumes de dados na máquina física, o ambiente virtual do Google Earth Engine (GEE, 2026) foi empregado para realizar a extração dos valores espectrais dos *pixels* de cada ponto de análise específico (LRF1 a LRF6).

Previamente, diversos códigos foram desenvolvidos e testados para extrair os valores das respostas espectrais de nuvens do banco de dados. Os melhores resultados foram oriundos do filtro '*Cloudy_Pixel_Percentage*', presente no código do GEE, que reduziu a quantidade de imagens de satélite para somente aquelas com menos de 5% de presença de nuvem. Um código foi desenvolvido para o GEE extrair o valor de *pixel* das cenas de uma determinada banda espectral de cada um dos 6 pontos de monitoramento da SMAC/RioÁguas. Esse código gerou no GEE uma tabela com as datas de aquisição (datas das cenas) e os valores espectrais de cada *pixel* de cada ponto de monitoramento. Os dados dessa tabela foram exportados para uma nova planilha com as macros de tratamento e análise dos dados espectrais que serão apresentados a seguir.

3.3.3. Macros para Excel para tratamento dos dados de reflectância

Os seis pontos de monitoramento (LRF1-LRF6) da SMAC/RioÁguas foram empregados como base para a extração de dados espectrais. Para cada ponto, foram extraídos valores de reflectância da superfície de doze bandas do sensor Sentinel-2 MSI Nível 2A (B1 a B12, incluindo B8A). Dessa forma, cada ponto gerou 12 valores de reflexão por cena e como foram 6 pontos analisados, totalizaram 72 valores gerados por cena. Considerando que foram 57 cenas disponíveis após filtragem, o código desenvolvido no GEE gerou ao todo 4104 valores de reflectância ($72 * 57$).

O processamento dos dados espectrais exportados do GEE foi estruturado em macros e organizadas em etapas sequenciais de tratamento. Inicialmente, os dados espectrais foram padronizados, que incluiu a conversão de separadores decimais e a conversão de datas do padrão GEE (ex.: Dec 15, 2018) para padrão brasileiro e legível pelo *Excel* (ex.: 15/12/2018). Subsequentemente, aplicou-se um filtro de qualidade espectral para a remoção de ruídos atmosféricos, descartando-se registros com valores de reflectância superiores a 350, que indicam nuvens. Após essa etapa, os dados foram agrupados por estação de monitoramento e em um banco de dados unificado. A etapa final consistiu na integração dos dados de sensoriamento remoto aos parâmetros mensurados *in situ* (clorofila-*a*, turbidez e transparência). Essa integração ocorreu por meio de pareamento temporal (*match-up*), unindo os conjuntos de dados com base na coincidência das datas de aquisição. Somente os dados que coincidiam no mesmo dia de análise (*in situ* e remota) foram pareados com o objetivo de elevar a precisão da estimativa dos parâmetros.

² Entende-se como metodologias tradicionais aquelas que envolvem a necessidade de *download* e tratamento dos dados na máquina física do usuário.

³ Cada conjunto de imagem é referente a uma data específica e é composto por dados de cerca de 1 GB, incluindo as 12 cenas (uma por banda) e outras informações.

O procedimento acima resultou em séries temporais distintas para cada parâmetro: 17 datas analisáveis para clorofila-*a* e 22 datas para turbidez (sonda). Ao passo que a turbidez (manual) e transparência totalizaram 41 e 42 datas, na devida ordem (ver item 3.6). A distinção no volume de dados ocorreu porque os dois primeiros parâmetros foram provenientes de uma única estação de monitoramento pontual, ao passo que as demais integravam dados vindos dos seis pontos de monitoramento (LRF1-LRF6).

3.4. Etapas de calibração e validação

Os dados de todos os parâmetros (clorofila-*a*, turbidez sonda e manual e transparência) foram distribuídos aleatoriamente (*data splitting*) em dois subconjuntos distintos: 80% destinados para a calibração e 20% para a validação, proporção usualmente empregada na literatura de estimação de parâmetros por sensoriamento remoto (IVANDA *et al.*, 2021; KIM *et al.*, 2022; MUSHTAQ *et al.*, 2022).

A metodologia de estimação remota de concentrações de parâmetros opticamente activos baseia-se em duas etapas: calibração (treinamento) e validação independente (teste) (ABDELAL *et al.*, 2022; CAO *et al.*, 2022; GERMÁN *et al.*, 2021; HORN, 2021; IVANDA *et al.*, 2021; KIM *et al.*, 2022; LEHMANN *et al.*, 2021; MANSARAY *et al.*, 2021; MENG *et al.*, 2022; MOHSEN *et al.*, 2021; MUSHTAQ *et al.*, 2022; POMPÊO *et al.*, 2021; SHI *et al.*, 2022). Essas etapas foram sintetizadas em um fluxograma observado na **Figura 4**.

O processo de calibração consiste em uma base de dados formada pelo conteúdo obtido em campo de um determinado parâmetro e os valores de reflectância espectral extraídos dos pixels onde foram realizadas as amostragens *in situ*. A relação entre os parâmetros e a resposta espectral foi avaliada por meio de análises de correlações estatísticas (ver item 3.5 a seguir). Essas correlações produzem equações que descrevem a linha de tendência entre os conjuntos de dados. Foram testados o modelo exponencial, linear, logarítmico e polinomial de acordo com a natureza da relação dos dados. A equação com a melhor correlação foi selecionada e aplicada apenas às imagens orbitais que constituem a base de dados inicial. As concentrações adquiridas remotamente tiveram novamente sua precisão definida por correlações estatísticas.

A capacidade de estimação da equação encontrada na etapa de calibração é averiguada na etapa de validação. A equação é validada com um novo conjunto de dados amostrados *in situ* e de reflectância espectral não empregada anteriormente. A precisão da estimação é verificada também por análises de correlações estatísticas que expressam a força de correlação entre os dados, validando o processo de estimativa remota. O processo de validação autentica a equação de modelamento para determinar a concentração de determinado parâmetro (MOHSEN *et al.*, 2021).

A equação validada é aplicável à antiga e nova imagem de satélite para medir o parâmetro, permitindo monitoramento espacial e temporalmente detalhada. No entanto, as avaliações devem ser cautelosas, uma vez que estão presentes imprecisões inerentes a qualquer modelação de dados.




Figura 4 - Etapas de calibração e validação da relação entre os dados de concentração dos parâmetros opticamente ativos obtidos *in situ* e remotamente.

3.5. Métodos de correlação estatística

As associações estatísticas foram realizadas a partir dos coeficientes determinação (R^2) e de correlação (R), que são operações estatísticas usualmente empregadas para medir a correlação entre os valores obtidos *in situ* e os encontrados remotamente (Equações 1 e 2). A linha de tendência do R^2 pode ser do tipo linear, logarítmica, exponencial, de potência, polinomial e de média móvel. O modelo de linha de tendência mais acurado deve ser escolhido de acordo com a natureza dos dados correlacionados.

$$R^2 = 1 - \frac{\sum_{i=1}^n (X_i^{\text{Mensurado}} - X_i^{\text{Estimado}})^2}{\sum_{i=1}^n (X_i^{\text{Mensurado}} - X_i^{\text{Valor médio mensurado}})^2} \quad (\text{Eq. 1})$$

$$R = \sqrt{R^2} \quad (\text{Eq. 2})$$

Outras operações estatísticas foram aplicadas complementarmente para garantir a compreensão da exatidão da correlação entre os dados, para além do coeficiente de determinação (R^2). Entre elas, o Erro Absoluto Médio (*Mean Absolute Error* - MAE), o Erro Quadrático Médio (*Mean Squared Error* - MSE), a Raiz do Erro Quadrático Médio (*Root Mean Square Error* - RMSE), e a Tendência Percentual (PBIAS) (Equações 3 a 6). Quanto mais próximo de zero é o valor encontrado pelas operações de MAE, MSE, RMSE e PBIAS, melhor o desempenho do modelo. Quando o valor de PBIAS for entre ± 25 , esse modelo segue considerado como satisfatório. Ademais, o valor de p também foi analisado para avaliar a significância estatística encontrada.

$$MAE = \frac{1}{n} \sum_{i=1}^n |X_i^{Estimado} - X_i^{Mensurado}| \quad (\text{Eq. 3})$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i^{Estimado} - X_i^{Mensurado})^2 \quad (\text{Eq. 4})$$

$$RMSE = \sqrt{MSE} \quad (\text{Eq. 5})$$

$$PBIAS = \frac{\sum_{i=1}^n (X_i^{Mensurado} - X_i^{Estimado}) * 100}{\sum_{i=1}^n X_i^{Mensurado}} \quad (\text{Eq. 6})$$

As correlações estatísticas supracitadas foram realizadas por intermédio da programação na linguagem R no *StudioR* versão 4.2.3 com os pacotes *readxl* versão 1.4.2, *zoo* e *hydroGOF* versão 0.5-0 (R CORE TEAM, 2023; WICKHAM e BRYAN, 2023; ZAMBRANO-BIGIARINI, 2020; ZEILEIS e GROTHENDIECK, 2005).

Com o objetivo de capturar a melhor associação frente à variabilidade dos constituintes dos parâmetros opticamente ativos, ao todo, 101 modelos matemáticos foram implementados (**Tabela 2**). Esse conjunto de modelos permite uma análise estatística mais ampla ao empregar diferentes abordagens, como com razões de bandas simples (e.g., modelos 6 a 16, B/G, G/NIR), índices de diferença normalizada (e.g., modelos 23 e 70, ((NIR-R)/(NIR+R))), algoritmos semi-analíticos (e.g., modelos 29, 30, 31 e 32, {(1/B)-(1/G)}*NIR) e modelos de regressão polinômias e logarítmicos (e.g., 22, 73, 79 e 101, 1,67-3,94*log(B)+3,78*log(G)). Esse modelos foram derivados dos trabalhos de Abdelal *et al.* (2022), Dallosch e Creed (2021), Hajigholizadeh *et al.* (2021) e Meng, Zhang e Zheng (2022).

Tabela 2 - Modelos aplicados para analisar a regressão entre os dados *in situ* de clorofila e turbidez com resposta espectral. Modelos de 97 a 101 foram exclusivos para estimação da turbidez

Modelo	Expressão	Modelo	Expressão	Modelo	Expressão
1	B*G	34	(B/R)*NIR	68	(NIR/B)*(NIR/R)
2	B*R	35	(G/R)*NIR	69	(NIR/G)*(NIR/R)
3	G*R	36	(R/B)*NIR	70	(RE-R)/(RE+R)
4	G*NIR	37	(R/G)*NIR	71	(RE-R)/(RE+R) + RE4
5	R*NIR	38	(R*NIR)/B	72	RE-(R+RE2)/2
6	B/G	39	(B/G)*(B/R)	73	315,50*((1/R-1/RE*RE2)^2)+215,95*(1/R-1/RE*RE2)-25,66
7	B/R	40	(B/G)*(B/NIR)	74	23,44*(RE-R)/(RE+R)+1)^7,95
8	G/B	41	(B/G)*(R/G)	75	5,6949^14,543*G
9	G/R	42	(B/G)*(R/NIR)	76	5,6949^14,543*R
10	G/NIR	43	(B/G)*(NIR/B)	77	5,6949^14,543*RE
11	R/B	44	(B/G)*(NIR/G)	78	1/(R*RE2)
12	R/G	45	(B/G)*(NIR/R)	79	2986+6,936*d3-0,861*d4-91,4*d8
13	R/NIR	46	(B/R)*(B/NIR)	80	61,32*(RE/R)-37,94
14	NIR/B	47	(B/R)*(G/R)	81	-2231*(RE-(R+RE2)/2)+12,7
15	NIR/G	48	(B/R)*(G/NIR)	82	R/RE*-105,3+140,6
16	NIR/R	49	(B/R)*(NIR/R)	83	61,32*(RE/R)-37,94
17	B*G*R	50	(B/NIR)*(G/NIR)	84	RE-(R+RE2)/2
18	B*G*NIR	51	(B/NIR)*(R/NIR)	85	RE/R
19	B*R*NIR	52	(G/B)*(G/R)	86	(RE/R)/(705-665)
20	G*R*NIR	53	(G/B)*(G/NIR)	87	R/RE
21	NIR-R	54	(G/B)*(R/B)	88	(RE2/RE)-(RE2/R)
22	1,67-3,94*log(B)+3,78*log(G)	55	(G/B)*(R/NIR)	89	(RE-R)/(RE+R)
23	(NIR-R)/(NIR+R)	56	(G/B)*(NIR/B)	90	RE-R
24	((R/NIR)-1)/((R/NIR)+1)	57	(G/B)*(NIR/R)	91	-5,57 + 80,13*NIR/R
25	(NIR-R)/(B+G)	58	(G/R)*(G/NIR)	92	(R*665)-(R*560)
26	(B-R)/G	59	(G/R)*(NIR/R)	93	NIR- B/G
27	(NIR/G)+(NIR/B)	60	(G/NIR)*(R/NIR)	94	(B+G)/2
28	G*(B+G+R)	61	(R/B)*(R/G)	95	(B+R)/2
29	{(1/B)-(1/G))*NIR	62	(R/B)*(R/NIR)	96	(B+NIR)/2
30	{(1/R)-(1/G))*NIR	63	(R/B)*(NIR/B)	97	-10,42*b1+2,76
31	{(1/R)-(1/B))*NIR	64	(R/B)*(NIR/G)	98	-2,78*((B-R)/G)+2,30
32	{(1/R)-(0,2363*(1/G))}*NIR	65	(R/G)*(R/NIR)	99	106,62*R-0,7179
33	{(1/R)-(1/B)}/NIR	66	(R/G)*(NIR/G)	100	3,0221^2,0488*(B1/G)
		67	(NIR/B)*(NIR/G)	101	517,91 * (R/NIR) - 8,86 * (G/NIR) - 799,23 * (NIR/B) + 127,76 * (NIR/G) + 1100,92 * (NIR/R) - 74,63 * (B/NIR) - 1037,79

B1: aerossol ($R_{rs}(443)$); B: azul ($R_{rs}(490)$); G: verde ($R_{rs}(560)$); R: vermelho ($R_{rs}(665)$); RE: red edge ($R_{rs}(705)$); RE2: red edge 2 ($R_{rs}(740)$); NIR: infravermelho próximo ($R_{rs}(842)$); d3: (RE-R)/(705-665); d4: (RE2-RE)/(740-705); d8: (SWIR2-SWIR1)/(2190-1610). Eq. 22: Kab1; Eq. 23: NDVI; Eq. 24: NRVI; Eq. 70: NDCI.

3.6. Descrição dos dados *in situ*

O detalhamento estatístico dos teores e valores dos parâmetros estudados *in situ* é visto na **Tabela 3** e **Figura 5**. O banco de dados dos parâmetros estudados clorofila-*a*, turbidez (sonda e manual) e transparência foram separados aleatoriamente em dois montantes: o primeiro para validação, com 80% das amostras, e o segundo, para calibração, com os 20% restantes.

Tabela 3 - Resumo descritivo dos dados de clorofila-a, turbidez e transparência na análise ambiental da lagoa. Teor médio (X), desvio padrão (DP), número de amostras (N), mínimo (Min), máximo (Max).

Parâmetro	Calibração		Validação	
	X ± DP (N)	Min - Max	X ± DP (N)	Min - Max
Clorofila-a (µg/L)	32,30 ± 34,40 (13)	0,42 – 101,28	16,30 ± 26,16 (4)	0,02 – 55,22
Turbidez/Sonda (NTU)	6,78 ± 2,31 (17)	3,90 - 11,70	5,56 ± 2,53 (5)	2,22 – 8,90
Turbidez/Manual (NTU)	3,63 ± 1,57 (41)	1,52 – 9,41	3,89 ± 1,45 (12)	1,84 - 6
Transparência (cm)	95,71 ± 7,61 (42)	30 - 200	95,00 ± 14,95 (12)	30 - 170




Figura 5 - Distribuição da frequência de amostras e porcentagem cumulativa dos parâmetros qualitativos opticamente ativos amostrados entre 2018 e 2022 na lagoa Rodrigo de Freitas (RJ): A. Clorofila-a (µg/L, n = 17); B. Transparência (disco de Secchi em cm, n = 54); C. Turbidez/sonda (NTU, n = 22); D. Turbidez/manual (NTU, n = 53).

4. RESULTADOS E DISCUSSÃO

4.1. Calibração e validação dos modelos de estimação remota

O modelo número 66 foi aquele que apresentou o melhor desempenho para associar os dados *in situ* com os dados de reflectância para clorofila-a. Ao todo, 13 amostras foram analisadas na etapa de calibração e 4 na etapa de validação. O modelo 66 ((R/G)*(NIR/G)) gerou o coeficiente observado na Equação 7 ao trabalhar com a faixa de 0,42 a 101,28 µg/L de clorofila-a.

$$y = 0,002 * X + 0,0459 \quad (\text{Eq. 7})$$

Onde y = teor da clorofila-a (µg/L); x = (R/G)*(NIR/G).

No que se refere a turbidez (sonda), o modelo 12 obteve o mais acurado desempenho na associação entre os dados *in situ* com os de reflectância. Ao todo 22 amostras foram empregadas: 17 na etapa de calibração e 5 na validação. O modelo 12 (R/G) produziu o coeficiente visto na Equação 8 com o conjunto de dados analisados variando entre 3,90 a 11,70 NTU de turbidez.

$$y = 0,0248 * X + 0,3264 \quad (\text{Eq. 8})$$

Onde y = teor de turbidez (NTU); x = (R/G).

O modelo 100 demonstrou maior acurácia para os dados de turbidez (manual) e os dados remotamente obtidos. Entre as amostras, 41 foram aplicadas na etapa de avaliação e 12 na de calibração. Esse modelo 100 ($3.0221 \wedge (2.0488 * (\text{Aerossol/Verde}))$) obteve o coeficiente demonstrado na Equação 9 a partir dos teores que variaram entre 30 a 200 NTU de turbidez.

$$y = -0,9305 * X + 8,602 \quad (\text{Eq. 9})$$

Onde y = teor de turbidez (NTU); x = $3.0221 \wedge (2.0488 * (\text{Aerossol/Verde}))$.

Por fim, a respeito da transparência, a banda do aerossol foi aquela com maior precisão, onde 54 amostras foram contabilizadas, das quais 42 foram destinadas para etapa de calibração e 12 para validação. Os valores da banda do aerossol produziram o coeficiente descrito na Equação 10 para valores entre 30 a 200 cm de transparência. As principais correlações encontradas na etapa de calibração foram sintetizadas na **Tabela 4**.

$$y = 0,6099 * X + 19,837 \quad (\text{Eq. 10})$$

Onde: y = transparência da coluna d'água (cm); X = respectivo valor da banda do aerossol.

Tabela 4 - Resumo estatístico das correlações entre os parâmetros opticamente ativos clorofila, turbidez (sonda e manual) e transparência e as respostas espectrais na etapa de calibração. Análise do *p-value* foi reservada apenas para os modelos de melhor ajuste estatístico.

Clorofila-a							
Modelo/ Banda	MAE	MSE	RMSE	PBIAS	r	R ²	p-value
66	3,2E+01	2,1E+03	4,6E+01	2,9E+04	0,60	0,36	0,03
Turbidez (sonda automática)							
Modelo/ Banda	MAE	MSE	RMSE	PBIAS	r	R ²	p-value
12	6,3E+00	4,4E+01	6,7E+00	1,3E+03	0,41	0,17	0,10
Turbidez (mensuração manual)							
Modelo/ Banda	MAE	MSE	RMSE	PBIAS	r	R ²	p-value
100	3,1E+00	1,5E+01	3,8E+00	-3,1E+01	-0,63	0,39	< 0,0001
Aerossol	1,2E+02	1,7E+04	1,3E+02	-9,7E+01	-0,57	0,32	-
Transparência							
Modelo/ Banda	MAE	MSE	RMSE	PBIAS	r	R ²	p-value
Aerossol	4,0E+01	2,6E+03	5,1E+01	-2,3E+01	0,64	0,41	< 0,0001
6	9,5E+01	1,1E+04	1,1E+02	1,5E+04	0,53	0,28	-

Todas as equações acima descritas foram validadas por um conjunto de dados novos, isto é, que não pertenceram a etapa de calibração. As descrições dos dados empregados na etapa de validação foram dispostas na **Tabela 3**. Os resultados das equações 15 a 18 aplicadas a novos conjuntos de dados foram analisados estatisticamente e resumidos na **Tabela 5**. Dentre os quatro parâmetros, as equações das clorofila-*a* e turbidez mensurada pela sonda obtiveram resultados insatisfatórios, com R^2 em 0,14 e 0,22, respectivamente. Ao passo que a turbidez (manual) e a transparência lograram bons resultados na validação, com R^2 em 0,66 e 0,68, na devida ordem.

Tabela 5 - Resumo das equações de validação encontradas na etapa de validação. A validação ocorreu a partir da correlação estatística entre o valor mensurado *in situ* por aquele estimado.

Parâmetro	Equação	MAE	MSE	RMSE	PBIAS (%)	r	R ²	p-value
Clorofila-a	$y = 0,002 * X + 0,0459$	16	7,8E+02	28	-1,0E+02	-0,37	0,14	0,62
Turbidez/Sonda	$y = 0,0248 * X + 0,3264$	5,2	32	5,7	-94	-0,47	0,22	0,43
Turbidez/Manual	$y = -0,9305 * X + 8,602$	1,6	3,1	1,8	8,1	0,81	0,66	< 0,001
Transparência	$y = 0,6099 * X + 19,837$	34	1,8E+03	43	31	0,83	0,68	< 0,001

Y é o teor do parâmetro e X, o respectivo valor espectral.

Notou-se que os valores dos *pixels* nas margens da lagoa causavam efeito de borda, isto é, outras feições (como vegetação, píeres e estruturas urbanas) interferiam nos valores de reflectância da água. Para solucionar esse problema, a área da lagoa foi reduzida no arquivo vetorial da lagoa para então recortar a área dos arquivos matriciais das imagens de satélite com os modelos aplicados. O *shapefile* foi reduzido com o emprego da ferramenta de geoprocessamento *Buffer* e os cálculos matemáticos dos modelos ocorreu pela *Calculadora Raster* do sistema de informação geográfica QGIS v. 3.22.5 (QGIS.org, 2026). Testes iniciais com *buffer* de 10 a 50 metros revelaram que os modelos produziram estimativas incongruentes com a natureza dos parâmetros, resultando em valores espúrios (ex.: -7,0E+07 NTU) ou subestimados (ex.: 0,0459 µg/L). A dificuldade de encontrar boa correlação entre os dados *in situ* e a resposta espectral também foi observada no estudo na lagoa de Conceição (Santa Catarina) por Horn (2021).

Diante desses cenários, aplicou-se o *buffer* de 100 metros de recorte das margens da lagoa. Essa medida possibilitou reservar a área mais central da lagoa de influências espectrais de sua margem. Esses resultados permitiram concluir que a clorofila-*a* e os valores obtidos da turbidez/sonda foram irrecuperáveis a partir da metodologia empregada nesse estudo. Por conta disso, novas tentativas de recuperação desses parâmetros não foram realizadas. Contrariamente, a recuperação dos dados de turbidez/manual, pelo Modelo 100 ($3.0221^{1/2.0488} * (b1/G)$), e transparência, pela relação com a banda do aerossol, foram mais consistentes e esses seguiram na análise.

4.2. Estimativa remota dos níveis de turbidez

O teor de turbidez foi recuperado para toda lagoa em nove datas distintas ao decorrer dos anos de 2019 a 2021, sendo elas: 12/08/2019, 16/09/2019, 13/04/2020, 27/07/2020, 03/05/2021 e 16/08/2021. As concentrações de turbidez recuperadas nessas datas constaram entre o intervalo de 0,1 a 23,5 NTU (**Figura 6**), respeitando o limite de 40 NTU previsto na Resolução Conama nº 357/2005 (BRASIL, 2005). Essa Resolução refere-se à água doce, porém foi empregada como padrão por ausência de uma norma específica para água salobra, como a Rodrigo de Freitas.




Figura 6 - Mapas com distintas escalas do nível de turbidez na lagoa Rodrigo de Freitas (RJ). Estimativa dos níveis de turbidez realizada pelo modelo $100 (3.0221^{+2.0488} * (\text{aerossol}/\text{verde}))$. Devido à distinção nativa da resolução espacial entre as bandas do Sentinel 2 MSI (aerossol com 60 m e verde com 10 m), os produtos resultantes apresentaram variações nas feições visuais. Todos os *rasters* possuem resolução espacial de 10 metros. Arquivo *shapefile* original de Data.Rio (2024). Imagem de satélite do primeiro mapa: ESA (2023). Mapa: H. Sabino.

A distribuição espaço-temporal dos níveis de turbidez estimados apresentou amplitude que pode ser dita como normal para a área de estudo. Os valores encontrados indicaram que houve influência sazonal na disposição da turbidez. Os menores teores foram estimados nos meses de outono e inverno (ex.: 22/07/2020 com pico de 4 NTU e 03/05/2021 com pico de 2,6 NTU), o que sugere que durante esse período houve maior estabilidade na coluna d'água ou menor aporte de material particulado, possivelmente associado aos minorados níveis de

precipitação pluviométrica e de ventos fortes. Por outro lado, os níveis de turbidez mais elevados foram estimados predominantemente no período de transição do final do inverno para a primavera. Como exemplo, citam-se as imagens de setembro de 2020, com o maior nível estimado (23,5 NTU), seguida da imagem de agosto de 2021 (17,2 NTU). Interessante evidenciar que o maior e menor teor estimados encontraram-se no mesmo ano (2020).

A LRF apresentou comportamento heterogêneo na distribuição espacial de turbidez, o que era esperado devido a sua área (2,2 km²) e profundidade (média de 3 m), o que propicia o revolvimento de elementos na coluna d'água. Os mapas da **Figura 6** possibilitaram identificar que as datas com maior turbidez (16/09/2019, 30/09/2020 e 16/08/2021) mostraram maior tendência de concentração desse parâmetro nas áreas marginais, como paralela ao morro do Sacopã, e, principalmente, na parte norte da lagoa, próximas aos pontos LRF1 e LRF2. A gênese desse perfil pode estar relacionada a uma dinâmica de circulação d'água mais restrita nessa parte, ressuspensão de sedimentos por vento e maior aporte da drenagem urbana. Por outro lado, a porção central e, especialmente ao sul próximo do LRF6, tenderam a apresentar valores reduzidos de turbidez.

Como é notável, as estimativas evidenciaram o “pixelado” da mescla de bandas com distintas resoluções nativas do Sentinel 2. Nas datas com menor nível de turbidez (como em 27/07/2020 e 03/05/2021), o “pixelado” ficou mais evidente nos mapas. Isso ocorreu porque a banda aerossol de 60 metros de resolução espacial precisou ser mesclada com a de 10 metros da banda verde durante o cálculo matricial.

4.3. Estimativa remota da transparência

A lagoa Rodrigo de Freitas foi descrita como “extraordinariamente transparente” no começo do século XIX (LUCCOCK, 1820). Contudo, com o avanço da urbanização e descaso com a questão do saneamento, a contaminação mudou as características translúcidas da lagoa, que por vez passou a ser documentada com a cor avermelhada e “entre azul e verde” (CORREIO DA MANHÃ, 1954), esverdeada (JORNAL DO BRASIL, 1959), vermelha (JORNAL DO BRASIL, 1992) e com um “colorido verde azeitonado, se qualquer pintor fosse fazer um quadro da paisagem local, naquele momento, teria de usar na tela a cor olivácea denegrada” (OLIVEIRA *et al.*, 1957). Atualmente, a lagoa apresenta melhor transparência em suas margens, logrando a observação visual do ecossistema lacustre (MOSCATELLI, 2023), ainda que derramamento de óleo, esgoto e outros elementos colorantes sejam lançados na lagoa ou em seus tributários, como registrado no estudo de Sabino *et al.* (2026) e outras fontes, como Moscatelli (2024a, 2024b, 2024c).

A amplitude dos valores da transparência variou de forma considerável no período analisado, mais do que a turbidez (**Figura 7**). O momento em que a coluna d'água observou maior translucidez foi em 16/09/2019, quando atingiu a 293 cm. Em contraste, a menor amplitude ocorreu em 03/05/2021, com transparência máxima de apenas 74 cm, indicando que houve algum evento generalizado, como revolvimento de material suspenso ou alguma floração de algas que reduziu a penetração da luz em todo espalho d'água.

A análise da transparência deve ser feita de forma “invertida” em relação aos demais parâmetros, visto que sua lógica dita que quanto maior o seu valor, maior a translucidez, logo, melhor a qualidade d'água. A transparência foi analisada nas mesmas datas que a turbidez. Notou-se a presença de padrões “compartimentados” da distribuição espacial da transparência. As partes marginais da lagoa, especialmente ao norte (cerca de LRF1 e LRF2) e na parte mais ao sul (LRF4 e LRF5), apresentam variações da transparência distintas da parte central. Como exemplo, citam-se as datas de 13/04/2020 e 22/07/2020, quando a maior transparência estava na parte central da lagoa, o contrário era constatado às margens, possivelmente por influência de

fatores locais, como contribuição do escoamento urbano e ressuspensão de sedimentos. A margem leste é mais profunda que a oeste, ainda assim, a região oriental registrou os melhores resultados de transparência.




Figura 7 - Estimativa da transparência por disco de Secchi durante 3 anos da lagoa Rodrigo de Freitas pela estimativa remota da banda do aerossol do Sentinel 2 MSI. Os mapas possuem escala de transparências distintas. Resolução espacial de 10 metros. Arquivo *shapefile* original de Data.Rio (2024). Imagem de satélite original: ESA (2023). Mapa: H. Sabino.

Assim como observado nos mapeamentos de turbidez, os mapas de transparência evidenciaram a pixelização. Este é um efeito metodológico inerente ao uso da banda de aerossol do Sentinel 2, que possui resolução nativa de 60 metros e, mesmo reamostrada para compor o *raster* final de 10 metros, domina o visual do produto final.

Diversas atividades de lazer, como pedalinho, remo e *stand-up*, ocorrem na região entorno do LRF4, e próximo ao parque Cantagalo. A partir de uma visão geral, pode-se afirmar que a região foi marcada pela reduzida concentração de turbidez e intermediária transparência da

água lagunar. Logo, indicam reduzidos elementos turvos e aprazível translucidez, usuais parâmetros visuais da boa qualidade d'água. A análise específica dessa região é relevante diante do elevado número de esportistas e cidadãos que nela frequentam.

4.4. Classificação da acurácia por estimativa remota

Múltiplos estudos disponíveis na literatura estimaram a concentração dos parâmetros opticamente ativos somente aplicando índices de diferenças normalizadas, como o Índice de Turbidez (NDTI) e o de Clorofila (NDCI), ou apenas aplicando algoritmos de estimação predefinidos, como aqueles no processador de imagem *Sentinel Application Platform (SNAP)* da ESA (2022b). Houve também os estudos que empregaram os índices, como os da diferença normalizada, ou algoritmos globais e efetuaram a associação calibrada com os dados *in situ* (LOBO *et al.*, 2021; POMPEO *et al.*, 2021; TÓTH *et al.*, 2021; ZABALETA *et al.*, 2021). Os estudos que calibram e validam os parâmetros obtidos remotamente e *in situ* ainda representam uma pequena parcela das análises de qualidade de água por satélite, que, por sua vez, também ocupa uma reduzida porção das pesquisas do campo de sensoriamento remoto.

A associação entre o conteúdo obtido remotamente e aquele em campo é necessário para realizar o processo de calibração e, especialmente, o de validação do algoritmo de estimação para verificar sua acurácia para determinado parâmetro em certa área considerada.

Finalmente, considerando toda discussão supracitada, padrões metodológicos para estimação remota de dados foram encontrados. Esses padrões de estudo foram classificados em três níveis considerando o seu grau de acurácia, como detalhado a seguir:

- Nível 1 (menos acurado): aplica índices globais ou algoritmos, porém não calibra ou valida estatisticamente o dado remoto com o dado *in situ*;
- Nível 2: calibra o dado remotamente obtido com dado mensurado *in situ*, porém, não valida o algoritmo de estimação; e
- Nível 3 (mais acurado): calibra e valida o algoritmo de estimação do dado remoto com o dado *in situ*. Estes permitem obter a maior exatidão da concentração estimada. Estudos nesse nível são menos frequentes na literatura quando comparados com outros níveis.

A metodologia desenvolvida no presente estudo é classificada como Nível 3. Dessa forma, a metodologia mais acurada na recuperação da concentração de parâmetros opticamente ativos na coluna d'água.

5. CONCLUSÕES E LIMITAÇÕES

O presente estudo apresentou uma abordagem pioneira para estimar o teor dos parâmetros qualitativos clorofila-*a*, turbidez e transparência por imagem de satélite da lagoa urbana eutrófica Rodrigo de Freitas (Rio de Janeiro, Brasil) de 2018 a 2022. O grande volume de dados mensurados *in situ* e a necessidade de tratar os dados de reflectância espectral levou ao desenvolvimento de rotinas em macros de excel em Visual Basic for Applications e do uso da plataforma baseada na nuvem Google Earth Engine.

A metodologia desenvolvida não logrou estimar clorofila-*a*, porém possibilitou a recuperação acurada do teor da turbidez (manual) ($R^2 = 0,66$; valor de $p = <0,001$) e da transparência ($R^2 = 0,68$; valor de $p = <0,001$). Esses dois últimos parâmetros são, naturalmente, complementares entre si.

Os teores estimados de turbidez variaram entre 0,1 a 23,5 NTU, enquadrando-se abaixo do teor máximo de 40 NTU, logo, foi um parâmetro de reduzida influência na qualidade da água no período analisado. Houve predominância de maiores níveis de turbidez (menor qualidade) na região central da lagoa, especialmente na região sudoeste (LRF5), indicando aporte de sedimentos via drenagem urbana e na área sob influência do canal exutório Jardim do Alá. A maior concentração de turbidez estimada (23,5 NTU) ocorreu em setembro de 2020. No que se refere à transparência, a análise de setembro de 2019 apresentou maior translucidez, atingindo 293 cm de profundidade, indicando ótima qualidade de água. Contudo, a qualidade reduziu ao longo do tempo e atingiu a pior qualidade em maio de 2021, com somente 74 cm de profundidade. Em geral, a região norte e nordeste possuíam maior translucidez, logo, melhor qualidade se comparada com a região ao sul (LRF6), que registrou os menores valores de translucidez e qualidade d'água.

A partir de técnicas de processamento digital de imagens, foram identificadas distintas e esperadas variações dos comportamentos dos parâmetros ao longo de espaço-tempo de forma a concluir que a lagoa esteve, em geral, com qualidade de água estável. Essas técnicas proporcionaram um entendimento do comportamento espaço-temporal da turbidez e transparência e da qualidade d'água, complementando o monitoramento convencional de análise pontual *in situ*. Dessa forma, a metodologia desenvolvida consolida-se como uma ferramenta de auxílio à gestão hídrica lacustre, identificando as características e padrões qualitativos da lagoa Rodrigo de Freitas. Ainda assim, observam-se limitações ao método, como a reduzida quantidade de imagens analisáveis pós-filtragem, a reamostragem espacial para compatibilização de resoluções entre bandas do Sentinel-2 e a imprecisão estatística preditiva dos modelos para quantificar os teores dos parâmetros.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001. O autor H. também agradece a PROEX-POSGEO-UFF pelos suportes financeiros. Agradecimentos à Secretaria Municipal de Ambiente da Cidade e a Fundação Rio-Águas da Prefeitura do Rio de Janeiro, em nome do Daniel, pelo compartilhamento das análises físico-químicas e microbiológicas da lagoa Rodrigo de Freitas.

REFERÊNCIAS

Abdelal, Q.; Assaf, M. N.; Al-Rawabdeh, A.; Arabasi, S.; Rawashdeh, N. A. Assessment of Sentinel-2 and Landsat-8 OLI for Small-Scale Inland Water Quality Modeling and Monitoring Based on Handheld Hyperspectral Ground

Truthing. **Journal of Sensors**, v. 2022, p. 1–19, 2022. Disponível em: <https://doi.org/10.1155/2022/4643924>
Alerta Rio. **Dados Meteorológicos do Sistema Alerta Rio - Estação Jardim Botânico**. 2024. Disponível em: <http://www.sistema-alerta-rio.com.br/dados-meteorologicos/download/dados-meteorologicos/>. Acesso em: 19 mar. 2024.

APHA. **Standard Methods for the Examination of Water and Wastewater**. 23. ed. Washington, D.C.: American Public Health Association, 2017.

Arias-Rodriguez, L. F.; Duan, Z.; Díaz-Torres, J. de J.; Babilio Hazas, M.; Huang, J.; Kumar, B. U.; Tuo, Y.; Disse, M. Integration of remote sensing and Mexican water quality monitoring system using an extreme learning machine. **Sensors**, v. 21, n. 12, 2021. Disponível em: <https://doi.org/10.3390/s21124118>

Assunção, A.; Silva, T. F. G.; De Carvalho, L. A. S.; Vinçon-Leite, B. Assessing water quality restoration measures in Lake Pampulha (Brazil) through remote sensing imagery. **Environmental Science and Pollution Research**, v.

32, n. 7, p. 3838–3868, 2025. Disponível em: <https://doi.org/10.1007/s11356-025-35914-6>

Bhargava, D. S.; Mariam, D. W. Spectral Reflectance Relationships to Turbidity Generated by Different Clay Materials. **Photogrammetric Engineering & Remote Sensing**, v. 56, n. 2, p. 225–229, 1990.

Branco, S. M. **Poluição: a morte de nossos rios**. 2. ed. São Paulo: ASCETESB, 1983.

Brasil. Resolução Conama nº 357, de 17 de março de 2005. **Diário Oficial da União**, Brasília, DF, 2005. Disponível em: http://pnqa.ana.gov.br/Publicacao/RESOLUCAO_CONAMA_n_357.pdf

Caballero, I.; Roca, M.; Santos-Echeandía, J.; Bernárdez, P.; Navarro, G. Use of the Sentinel-2 and Landsat-8 Satellites for Water Quality Monitoring: An Early Warning Tool in the Mar Menor Coastal Lagoon. **Remote Sensing**, v. 14, n. 12, p. 2744, 2022. Disponível em: <https://doi.org/10.3390/rs14122744>

Cao, Z.; Ma, R.; Melack, J. M.; Duan, H.; Liu, M.; Kutser, T.; Xue, K.; Shen, M.; Qi, T.; Yuan, H. Landsat observations of chlorophyll-a variations in Lake Taihu from 1984 to 2019. **International Journal of Applied Earth Observation and Geoinformation**, v. 106, p. 102642, 2022. Disponível em: <https://doi.org/10.1016/j.jag.2021.102642>

Correio da Manhã. **Nova mortandade de peixes na lagoa**. 1954. Disponível em: http://memoria.bn.br/DocReader/089842_06/33544. Acesso em: 6 dez. 2023.

Correio da Manhã. **Repitiu-se os espetáculo da Lagoa: peixes mortos**. 1961. Disponível em: http://memoria.bn.br/DocReader/089842_07/23557. Acesso em: 2 dez. 2023.

Dallosch, M. A.; Creed, I. F. Optimization of landsat Chl-a retrieval algorithms in freshwater lakes through classification of optical water types. **Remote Sensing**, v. 13, n. 22, p. 4607, 2021. Disponível em: <https://doi.org/10.3390/rs13224607>

Data.Rio. **Informações sobre a cidade**. 2022. Disponível em: <https://www.data.rio>. Acesso em: 27 nov. 2021.

Data.Rio. **Portal de dados abertos da Prefeitura da Cidade do Rio de Janeiro**. 2024. Disponível em: <https://www.data.rio>. Acesso em: 7 set. 2024.

Deutsch, E. S.; Cardille, J. A.; Koll-Egyed, T.; Fortin, M. J. Landsat 8 lake water clarity empirical algorithms: Large-scale calibration and validation using government and citizen science data from across Canada. **Remote Sensing**, v. 13, n. 7, p. 1257, 2021. Disponível em: <https://doi.org/10.3390/rs13071257>

Dogliotti, A. I.; Ruddick, K. G.; Nechad, B.; Doxaran, D.; Knaeps, E. 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, 2015. Disponível em: <https://doi.org/10.1016/J.RSE.2014.09.020>

ESA. **SNAP Download**. 2022. Disponível em: <https://step.esa.int/main/download/snap-download/>. Acesso em: 9 out. 2022.

ESA. **Copernicus Open Access Hub**. 2023. Disponível em: <https://scihub.copernicus.eu>. Acesso em: 26 fev. 2023.

Esteves, F. D. A. **Fundamentos de Limnologia**. 3. ed. Rio de Janeiro: Interciência, 2011.

Facco, D. S.; Guasselli, L. A.; Ruiz, L. F. C.; Simioni, J. P. D.; Dick, D. G. Spectral Reflectance in the Spatial-temporal Dynamic of Turbidity, Itaipu Reservoir, Brazil. **Anuário do Instituto de Geociências**, v. 44, n. 0, 2021. Disponível em: https://doi.org/10.11137/1982-3908_2021_44_41228. Acesso em: 13 out. 2022.

FEEMA. **Lagoa Rodrigo de Freitas - Diagnóstico 1982**. Rio de Janeiro: Feema, 1982. *E-book*. Disponível em: http://www.inea.rj.gov.br/wp-content/uploads/downloads/MEMORIA_TECNICA/CD_2/MEMORIA_TECNICA_2_A/CAIXA_2/MT_282.pdf

Fernández-Tejedor, M.; Velasco, J. E.; Angelats, E. Accurate Estimation of Chlorophyll-a Concentration in the Coastal Areas of the Ebro Delta (NW Mediterranean) Using Sentinel-2 and Its Application in the Selection of Areas

for Mussel Aquaculture. **Remote Sensing**, v. 14, n. 20, p. 5235, 2022. Disponível em: <https://doi.org/10.3390/RS14205235/S1>

Germán, A.; Shimoni, M.; Beltramone, G.; Rodríguez, M. I.; Muchiut, J.; Bonansea, M.; Scavuzzo, C. M.; Ferral, A. Space-time monitoring of water quality in an eutrophic reservoir using SENTINEL-2 data - A case study of San Roque, Argentina. **Remote Sensing Applications: Society and Environment**, v. 24, p. 100614, 2021. Disponível em: <https://doi.org/10.1016/j.rsase.2021.100614>

Google Earth Engine. **Earth Engine Data Catalog**. 2026. Disponível em: <https://developers.google.com/earth-engine/datasets?hl=pt-br>. Acesso em: 5 jan. 2026.

Gower, J.; King, S.; Borstad, G.; Brown, L. 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, 2007. Disponível em: <https://doi.org/10.1080/01431160500075857>. Acesso em: 24 jan. 2023.

Hajigholizadeh, M.; Moncada, A.; Kent, S.; Melesse, A. M. Land–lake linkage and remote sensing application in water quality monitoring in lake okeechobee, Florida, USA. **Land**, v. 10, n. 2, p. 1–17, 2021. Disponível em: <https://doi.org/10.3390/land10020147>

Horn, L. R. **Caracterização do comportamento da concentração de clorofila-a em uma laguna costeira, com o uso de modelos bio-ópticos de sensoriamento remoto**. 2021. - (Dissertação de Mestrado) Programa de Pós-Graduação em Engenharia Ambiental, Universidade Federal de Santa Catarina, 2021.

IBGE. **BC25_RJ - Curva de Nível**. 2022. Disponível em: <https://metadadosgeo.ibge.gov.br/>. Acesso em: 3 out. 2022.

Instituto Rio Patrimônio da Humanidade. **Guia das APACs: Hipódromo da Gávea, Jardim Botânico e Chácara do Algodão**. Rio de Janeiro: Prefeitura do Rio de Janeiro, 2012. *E-book*. Disponível em: <https://www.rio.rj.gov.br/dlstatic/10112/6433361/4172416/guia14.compressed.pdf>

Ivanda, A.; Šerić, L.; Bugarić, M.; Braović, M. Mapping chlorophyll-a concentrations in the kaštela bay and brač channel using ridge regression and sentinel-2 satellite images. **Electronics**, v. 10, n. 23, p. 3004, 2021. Disponível em: <https://doi.org/10.3390/electronics10233004>

Jornal do Brasil. **Nova mortandade de peixes na Lagoa Rodrigo de Freitas começou ontem sem PDF saber**. 1959. Disponível em: http://memoria.bn.br/DocReader/030015_07/99566. Acesso em: 29 nov. 2023.

Jornal do Brasil. **DLU retirou 30 toneladas de peixe morto da lagoa e quer acabar hoje a limpeza**. 1970. Disponível em: http://memoria.bn.br/DocReader/030015_09/178690. Acesso em: 3 dez. 2023.

Jornal do Brasil. **Estado quer diagnóstico sobre lagoas**. 1992. Disponível em: http://memoria.bn.br/DocReader/030015_11/67830. Acesso em: 5 dez. 2023.

Kim, Y. W.; Kim, T. H.; Shin, J.; Lee, D. S.; Park, Y. S.; Kim, Y.; Cha, Y. K. Validity evaluation of a machine-learning model for chlorophyll a retrieval using Sentinel-2 from inland and coastal waters. **Ecological Indicators**, v. 137, p. 108737, 2022. Disponível em: <https://doi.org/10.1016/j.ecolind.2022.108737>

Lacaux, J. P.; Tourre, Y. M.; Vignolles, C.; Ndione, J. A.; Lafaye, M. Classification of ponds from high-spatial resolution remote sensing: Application to Rift Valley Fever epidemics in Senegal. **Remote Sensing of Environment**, v. 106, n. 1, p. 66–74, 2007. Disponível em: <https://doi.org/10.1016/J.RSE.2006.07.012>

Lehmann, M. K.; Schütt, E. M.; Hieronymi, M.; Dare, J.; Krasemann, H. Analysis of recurring patchiness in satellite-derived chlorophyll a to aid the selection of representative sites for lake water quality monitoring. **International Journal of Applied Earth Observation and Geoinformation**, v. 104, p. 102547, 2021. Disponível em: <https://doi.org/10.1016/j.jag.2021.102547>

Li, H.; Xie, X.; Yang, X.; Cao, B.; Xia, X. An Integrated Model of Summer and Winter for Chlorophyll-a Retrieval in the Pearl River Estuary Based on Hyperspectral Data. **Remote Sensing**, v. 14, n. 9, p. 2270, 2022. Disponível em: <https://doi.org/10.3390/rs14092270>

Lobo, F. de L.; Nagel, G. W.; Maciel, D. A.; De Carvalho, L. A. S.; Martins, V. S.; Barbosa, C. C. F.; Evelyn Márcia Leão de Moraes, N. **AlgaeMap: Algae bloom monitoring application for inland waters in Latin America. Remote Sensing**, v. 13, n. 15, p. 2874, 2021. Disponível em: <https://doi.org/10.3390/rs13152874>

Luccock, J. Journeys from Rio de Janeiro Westwatd - 1813. In: **Notes on Rio de Janeiro, and the southern parts of Brazil; taken during a residence of ten years in that country, from 1808 to 1818**. Londres: Samuel Leigh, 1820. p. 639. *E-book*. Disponível em: <https://doi.org/10.5962/bhl.title.86300> e <https://purl.pt/23656>

Maia, A. C. L. *et al.* Two decades of flood-pulse-driven chlorophyll-a dynamics in an Amazon floodplain lake. **Science of The Total Environment**, v. 1013, p. 181341, 2026. Disponível em: <https://doi.org/https://doi.org/10.1016/j.scitotenv.2025.181341>

Mansaray, A. S.; Dzialowski, A. R.; Martin, M. E.; Wagner, K. L.; Gholizadeh, H.; Stoodley, S. H. Comparing planetscope to Landsat-8 and Sentinel-2 for sensing water quality in reservoirs in agricultural watersheds. **Remote Sensing**, v. 13, n. 9, p. 1847, 2021. Disponível em: <https://doi.org/10.3390/rs13091847>

Mapelli, L. R. **Aplicação de sensoriamento remoto e aprendizado de máquina na estimativa de turbidez de corpos hídricos**. 2025. - Monografia (Bacharelado), Graduação em Engenharia Ambiental, Universidade Federal de Ouro Preto, 2025. Disponível em: https://monografias.ufop.br/bitstream/35400000/7714/3/MONOGRRAFIA_AplicaçãoSensoriamentoRemoto.pdf

Masoud, A. A. On the Retrieval of the Water Quality Parameters from Sentinel-3/2 and Landsat-8 OLI in the Nile

Delta's Coastal and Inland Waters. **Water**, v. 14, n. 4, p. 593, 2022. Disponível em: <https://doi.org/10.3390/w14040593>

Meng, H.; Zhang, J.; Zheng, Z. Retrieving Inland Reservoir Water Quality Parameters Using Landsat 8-9 OLI and Sentinel-2 MSI Sensors with Empirical Multivariate Regression. **International Journal of Environmental Research and Public Health**, v. 19, n. 13, p. 7725, 2022. Disponível em: <https://doi.org/10.3390/ijerph19137725>

Mishra, S.; Mishra, D. R. Normalized difference chlorophyll index: A novel model for remote estimation of chlorophyll-a concentration in turbid productive waters. **Remote Sensing of Environment**, v. 117, p. 394–406, 2012. Disponível em: <https://doi.org/10.1016/J.RSE.2011.10.016>

Mohsen, A.; Elshemy, M.; Zeidan, B. Water quality monitoring of Lake Burullus (Egypt) using Landsat satellite imageries. **Environmental Science and Pollution Research**, v. 28, n. 13, p. 15687–15700, 2021. Disponível em: <https://doi.org/10.1007/s11356-020-11765-1>

Moscatelli, M. **O aquário da Lagoa - Setembro 2023, apesar dos resíduos**. 2023. Disponível em: <https://www.instagram.com/reel/CxWTTEWJcEN>. Acesso em: 21 jul. 2024.

Moscatelli, M. **O país dos inocentes (...)**. 2024a. Disponível em: <https://www.instagram.com/reel/C5YYWI5LgxB>. Acesso em: 21 jul. 2024.

Moscatelli, M. **Tolerância zero (...)**. 2024b. Disponível em: <https://www.instagram.com/p/C54WQqVpQ8W>. Acesso em: 21 jul. 2024.

Moscatelli, M. **Questão cultural (...)**. 2024c. Disponível em: <https://www.instagram.com/p/C9hjKsYpAQN>. Acesso em: 21 jul. 2024.

Mushtaq, F.; Nee Lala, M. G.; Mantoo, A. G. Trophic State Assessment of a Freshwater Himalayan Lake Using Landsat 8 OLI Satellite Imagery: A Case Study of Wular Lake, Jammu and Kashmir (India). **Earth and Space Science**, v. 9, n. 3, 2022. Disponível em: <https://doi.org/10.1029/2021EA001653>

Oliveira, L.; Nascimento, R. do; Krau, L.; Miranda, A. Observações hidrobiológicas e mortandade de peixes na Lagoa Rodrigo de Freitas. **Memórias do Instituto Oswaldo Cruz**, v. 55, n. 2, p. 211–271, 1957. Disponível em: <https://doi.org/10.1590/s0074-02761957000200005>

Pahlevan, N. *et al.* Simultaneous retrieval of selected optical water quality indicators from Landsat-8, Sentinel-2,

and Sentinel-3. **Remote Sensing of Environment**, v. 270, p. 112860, 2022. Disponível em: <https://doi.org/10.1016/j.rse.2021.112860>

Organização Mundial da Saúde. **Water quality and health –review of turbidity: information for regulators and water suppliers**. Geneva: ORGANIZAÇÃO MUNDIAL DA SAÚDE, 2017. *E-book*. Disponível em: <http://apps.who.int/iris/handle/10665/254631/>

Paltsev, A.; Creed, I. F. Are Northern Lakes in Relatively Intact Temperate Forests Showing Signs of Increasing Phytoplankton Biomass? **Ecosystems**, v. 25, n. 3, p. 727–755, 2022. Disponível em: <https://doi.org/10.1007/S10021-021-00684-Y>

Perrone, M.; Scalici, M.; Conti, L.; Moravec, D.; Kropáček, J.; Sighicelli, M.; Lecce, F.; Malavasi, M. Water mixing conditions influence sentinel-2 monitoring of chlorophyll content in monomictic lakes. **Remote Sensing**, v. 13, n. 14, p. 2699, 2021. Disponível em: <https://doi.org/10.3390/rs13142699>

Pompêo, M.; Moschini-Carlos, V.; Bitencourt, M. D.; Sôria-Perpinyà, X.; Vicente, E.; Delegido, J. 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, 2021. Disponível em: <https://doi.org/10.1007/S11356-021-12975-X>

Preisendorfer, R. W. Secchi disk science: Visual optics of natural waters. **Limnology and Oceanography**, v. 31, n. 5, p. 909–926, 1986. Disponível em: <https://doi.org/https://doi.org/10.4319/lo.1986.31.5.0909>
QGIS.org. **QGIS**. 2026. Disponível em: <http://www.qgis.org/>.

R Core Team. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing. Vienna, Austria 2023. Disponível em: <https://www.r-project.org/>

Rosman, P. C. C. Ligação Lagoa-Mar, Uma Necessidade. **Oecologia Australis**, v. 16, n. 3, p. 651–693, 2012. Disponível em: <https://doi.org/10.4257/oeco.2012.1603.17>

Sabino, H. **Qualidade da água da lagoa Rodrigo de Freitas (RJ) (2015-2022): abordagens quali-quantitativa in situ e por sensoriamento remoto**. 2025. - 216 f. Programa de Pós-Graduação em Geografia, Departamento de Geografia, Universidade Federal Fluminense, 2025.

Sabino, H.; Cunha, S. B. da; Menezes, J. M. Evolution of the environmental characteristics of the Cabeças, Macacos, and Rainha urban rivers (RJ) between 2004 and 2023. **Mercator**, v. no prelo, 2026.

Sabino, H.; Menezes, J. Mapeamento da turbidez de lagoas urbanas com imagens do Sentinel 2 MSI. In: 2022, Rio de Janeiro. **VI Jornada de Geotecnologias do Estado do Rio de Janeiro**. Rio de Janeiro 2022. Disponível em: <https://jgeotec.com.br/wp-content/uploads/2023/03/MAPEAMENTO-DA-TURBIDEZ-DE-LAGOAS-URBANAS.pdf>

Santana, J. P. M.; Silva, B. B. G.; Penna, L.; Fialho, E. S. Classificação climática: um estudo comparativo entre os métodos de Köppen e Thornthwaite para o município do Rio de Janeiro. In: 2005, São Paulo. **XI Simpósio Brasileiro de Geografia Física Aplicada**. São Paulo 2005.

Santos, A. C. Qualidade das Águas Subterrâneas. In: FEITOSA, F. A. C.; MANOEL FILHO, J.; FEITOSA, E. C.; DEMETRIO, J. G. A. (org.). **Hidrogeologia - Conceitos e Aplicações**. 2. ed. Rio de Janeiro: CPRM, 2008. p. 323–424.

SERLA. **Projeto de contenção de cheia da bacia da lagoa Rodrigo de Freitas**. Rio de Janeiro, 1990.

Shi, J.; Shen, Q.; Yao, Y.; Li, J.; Chen, F.; Wang, R.; Xu, W.; Gao, Z.; Wang, L.; Zhou, Y. Estimation of Chlorophyll-a Concentrations in Small Water Bodies: Comparison of Fused Gaofen-6 and Sentinel-2 Sensors. **Remote Sensing**, v. 14, n. 1, p. 229, 2022. Disponível em: <https://doi.org/10.3390/rs14010229>

Siegel, D. A.; Maritorena, S.; Nelson, N. B.; Behrenfeld, M. J.; McClain, C. R. Colored dissolved organic matter and its influence on the satellite-based characterization of the ocean biosphere. **Geophysical Research Letters**, v.

32, n. 20, p. 1–4, 2005. Disponível em: <https://doi.org/10.1029/2005GL024310>

Sistema Alerta Rio. **Dados Meteorológicos do Sistema Alerta Rio - Estação Jardim Botânico**. 2026. Disponível em: <http://www.sistema-alerta-rio.com.br/dados-meteorologicos/download/dados-meteorologicos/>. Acesso em: 10 fev. 2026.

SMAC/Rio-Águas. **Gestão da Lagoa Rodrigo de Freitas**. 2026. Disponível em: <https://ambienteclima.prefeitura.rio/monitoramento-diario-da-qualidade-da-agua/>. Acesso em: 5 jan. 2026.

Soriano-González, J.; Urrego, E. P.; Sòria-Perpinyà, X.; Angelats, E.; Alcaraz, C.; Delegido, J.; Ruíz-Verdú, A.; Tenjo, C.; Vicente, E.; Moreno, J. Towards the Combination of C2RCC Processors for Improving Water Quality Retrieval in Inland and Coastal Areas. **Remote Sensing**, v. 14, n. 5, p. 1124, 2022. Disponível em: <https://doi.org/10.3390/rs14051124>

Tang, X.; Huang, M. Inversion of chlorophyll-A concentration in donghu lake based on machine learning algorithm. **Water**, v. 13, n. 9, p. 1179, 2021. Disponível em: <https://doi.org/10.3390/w13091179>

Tóth, V. Z.; Ladányi, M.; Jung, A. Adaptation and Validation of a Sentinel-Based Chlorophyll-a Retrieval Software for the Central European Freshwater Lake, Balaton. **PFG - Journal of Photogrammetry, Remote Sensing and Geoinformation Science**, v. 89, n. 4, p. 335–344, 2021. Disponível em: <https://doi.org/10.1007/S41064-021-00160-1/FULLTEXT.HTML>

Tundisi, J. G.; M. Tundisi, T. **Limnologia**. 1ª ed. São Paulo: Oficina de Textos, 2008.

United States Geological Survey. **Turbidity and Water**. 2018. Disponível em: <https://www.usgs.gov/special-topics/water-science-school/science/turbidity-and-water#overview>. Acesso em: 25 jun. 2024.

Valerio, A. de M.; Montanari, J. L.; Kampel, M.; Ward, N. D.; Richey, J. E.; Cunha, A. C. Chlorophyll-a dynamics in the lower Amazon River: insights from in situ and hyperspectral remote sensing using OCI-PACE. **International Journal of Remote Sensing**, v. 47, n. 1, p. 124–149, 2026. Disponível em: <https://doi.org/10.1080/01431161.2025.2596811>

Wickham, H.; Bryan, J. **readxl: Read Excel Files. R package version 1.4.2**. [S. l.: s. n.] Disponível em: <https://cran.r-project.org/package=readxl>

Zabaleta, B.; Achkar, M.; Aubriot, L. Hotspot analysis of spatial distribution of algae blooms in small and medium water bodies. **Environmental Monitoring and Assessment**, v. 193, n. 4, p. 221, 2021. Disponível em: <https://doi.org/10.1007/S10661-021-08944-Z>

Zambrano-Bigiarini, M. **hydroGOF: Goodness-of-fit functions for comparison of simulated and observed hydrological time series**. 2020. Disponível em: <https://doi.org/10.5281/zenodo.839854>.

Zeileis, A.; Grothendieck, G. zoo: S3 Infrastructure for Regular and Irregular Time Series. **Journal of Statistical Software**, v. 14, n. 6, p. 1–27, 2005. Disponível em: <https://doi.org/10.18637/jss.v014.i06>