



**UNIVERSIDADE FEDERAL DE LAVRAS
PROGRAMA DE PÓS-GRADUAÇÃO EM RECURSOS HÍDRICOS**

WILLIAN GERALDO DA SILVA

**MODELOS PARA PREDIÇÃO DE SÓLIDOS DISSOLVIDOS TOTAIS,
SÓLIDOS TOTAIS E TURBIDEZ NO RESERVATÓRIO DE JAGUARA
A PARTIR DOS DADOS ESPECTRAIS DOS SATÉLITES SENTINEL-2**

LAVRAS

2025

WILLIAN GERALDO DA SILVA

**MODELOS PARA PREDIÇÃO DE SÓLIDOS DISSOLVIDOS TOTAIS,
SÓLIDOS TOTAIS E TURBIDEZ NO RESERVATÓRIO DE JAGUARA
A PARTIR DOS DADOS ESPECTRAIS DOS SATÉLITES SENTINEL-2**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Recursos Hídricos, área de concentração em Hidrologia, para a obtenção do título de Doutor.

Prof. Dr. Ronaldo Fia
Orientador

**LAVRAS
2025**

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da
Biblioteca Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a)**

Silva, Willian Geraldo.

Modelos para predição de sólidos dissolvidos totais, sólidos totais e turbidez no reservatório de Jaguara a partir dos dados espectrais dos satélites Sentinel-2. – Lavras: UFLA, 2025.

117p. : il.

Tese (doutorado) – Universidade Federal de Lavras, 2025.

Orientador: Ronaldo Fia.

1. Sensoriamento remoto. 2. MSI/Sentinel-2. 3. Qualidade da água. I. Silva, Willian Geraldo. II. Fia, Ronaldo o. III. Título.

WILLIAN GERALDO DA SILVA

**MODELOS PARA PREDIÇÃO DE SÓLIDOS DISSOLVIDOS TOTAIS,
SÓLIDOS TOTAIS E TURBIDEZ NO RESERVATÓRIO DE JAGUARA
A PARTIR DOS DADOS ESPECTRAIS DOS SATÉLITES SENTINEL-2**

**MODELS FOR PREDICTION OF TOTAL DISSOLVED SOLIDS,
TOTAL SOLIDS, AND TURBIDITY IN THE JAGUARA RESERVOIR
USING SPECTRAL DATA FROM SENTINEL-2 SATELLITES**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Recursos Hídricos, área de concentração em Hidrologia, para a obtenção do título de Doutor.

APROVADA em 18 de junho de 2025.

Prof. Dr. Ronaldo Fia - UFLA

Prof. Dr. Mateus Pimentel de Matos - UFLA

Prof. Dr. Gilberto Coelho - UFLA

Prof. Dr. Alisson Carraro Borges - UFV

Prof. Dr. Samuel Beskow - UFPEL

Prof. Dr. Ronaldo Fia
Orientador

LAVRAS

2025

AGRADECIMENTOS

A jornada acadêmica não começou em 2021, quando ingressei no doutorado. Ela começou em 2013, quando iniciei o curso de Engenharia Ambiental. Naquele momento, ainda estava em busca de compreensão sobre meu futuro, mas foi nesse curso que descobri minha paixão pelos recursos hídricos e suas idiossincrasias. Ali, comecei a sonhar com o doutorado, a imaginar que um dia poderia chegar até aqui.

Hoje, ao olhar para trás, é difícil acreditar que aquele aluno, que terminou o ensino médio com tantas dificuldades, jamais imaginaria que chegaria a concluir um doutorado. O caminho até aqui foi marcado por muitos desafios, os quais foram sendo superados a cada momento com muita dedicação e resiliência. Em muitos momentos, o que faltava em inteligência, sobrou em dedicação e "raça". Assim, para chegar até aqui, foram muitos desafios os quais não superei sozinho.

Nesse sentido, agradeço a Deus pela oportunidade de realizar este doutorado, por me proporcionar o conhecimento e a força necessária para chegar até aqui.

Agradeço imensamente à minha esposa, Helen, pela paciência, compreensão e apoio durante minha ausência. Sua compreensão e apoio incondicional foram essenciais para a realização desta etapa.

Agradeço ao professor Ronaldo Fia, meu orientador, por compreender todas as minhas dificuldades. Sua calma e sabedoria foram fundamentais para tranquilizar minha ansiedade, ajudando-me a seguir em frente e alcançar a conclusão dessa fase do meu percurso acadêmico.

Finalmente, sou grato à Universidade Federal de Lavras (UFLA), em especial ao Departamento de Recursos Hídricos e Saneamento, pela oportunidade e pelo suporte que me foram oferecidos ao longo dessa jornada.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

A chave da conservação ambiental não é o assistencialismo preservacionista. A natureza nunca poderia ser tratada como uma parceira inerte e passiva, como uma peça de museu, protegida, intocável e imune à ação do tempo e dos seres humanos. A natureza é, ao contrário, dinâmica e reativa, que merece ser tratada como uma força viva, dadivosa e renovável, mas com limites bem definidos. O ser humano precisa perceber que ela é um dos seus componentes e que dela depende para sua própria sobrevivência (SILVA, 2016).

RESUMO

O objetivo deste estudo é desenvolver modelos para estimar parâmetros da qualidade da água, como os Sólidos Dissolvidos Totais (SDT), Sólidos Totais (ST) e a Turbidez, no reservatório da UHE Jaguará. Para isso, foram utilizados dados de reflectância do sensor MSI/Sentinel-2, em conjunto com medições *in situ*, com o intuito de oferecer um monitoramento mais eficiente e preciso da qualidade da água nesse importante reservatório. Os dados de entrada foram obtidos a partir de 21 campanhas de amostragem realizadas entre 2018 e 2023, avaliadas em cenários com e sem remoção de valores atípicos. Os resultados indicaram que os modelos de aprendizado de máquina apresentaram melhor desempenho na previsão dos três parâmetros. O modelo *Random Forest* utilizando a banda 2186 foi o mais eficaz para TDS ($r = 0,84$), enquanto a razão de bandas 559/864 combinada com o modelo *Decision Tree* se destacou para TS ($r = 0,51$). Para turbidez, o modelo *Random Forest* utilizando todas as bandas obteve $r = 0,70$. A análise dos mapas preditivos confirmou os dados de campo, mostrando que as maiores concentrações de SDT, ST e turbidez ocorreram na estação chuvosa, especialmente nas áreas de entrada de água do reservatório. Além das chuvas, fatores como lançamentos de efluentes e mudanças no uso do solo também influenciaram a qualidade da água. A combinação de dados de sensoriamento remoto e técnicas de aprendizado de máquina mostrou-se eficaz na previsão de parâmetros da qualidade da água. Isso possibilitou estimativas mais precisas e a visualização contínua das concentrações de TS, TDS e turbidez, o que é um avanço em relação às metodologias tradicionais de amostragem. A aplicação dessa abordagem no reservatório da UHE Jaguará mostra o potencial para ser expandida para outros reservatórios, principalmente em áreas com diferentes condições hídricas.

PALAVRAS-CHAVE: Sensoriamento remoto; MSI/Sentinel-2; Qualidade da água; Aprendizado de máquina; Modelagem preditiva.

ABSTRACT

The objective of this study is to develop models to estimate water quality parameters such as Total Dissolved Solids (TDS), Total Solids (TS), and Turbidity in the UHE Jaguara reservoir. To achieve this, reflectance data from the MSI/Sentinel-2 sensor were used in conjunction with in situ measurements, aiming to provide more efficient and accurate water quality monitoring in this important reservoir. The input data were obtained from 21 sampling campaigns conducted between 2018 and 2023, evaluated in scenarios with and without outlier removal. The results indicated that machine learning models performed better in predicting the three parameters. The Random Forest model using band 2186 was the most effective for TDS ($r = 0.84$), while the 559/864 band ratio combined with the Decision Tree model stood out for TS ($r = 0.51$). For turbidity, the Random Forest model using all bands achieved $r = 0.70$. The analysis of the predictive maps confirmed the field data, showing that the highest concentrations of TDS, TS, and turbidity occurred during the rainy season, particularly in the water inflow areas of the reservoir. In addition to rainfall, factors such as effluent discharges and land use changes also influenced water quality. The combination of remote sensing data and machine learning techniques proved effective in predicting water quality parameters. This enabled more accurate estimates and continuous visualization of TS, TDS, and turbidity concentrations, representing an advancement over traditional sampling methodologies. The application of this approach in the UHE Jaguara reservoir shows potential for expansion to other reservoirs, particularly in areas with varying hydrological conditions.

KEYWORDS: Remote sensing; MSI/Sentinel-2; Water quality; Machine learning; Predictive modeling.

INDICADORES DE IMPACTO

O objetivo deste estudo é desenvolver modelos para estimar parâmetros da qualidade da água, como os Sólidos Dissolvidos Totais (SDT), Sólidos Totais (ST) e a Turbidez, no reservatório da UHE Jaguará. Utilizando dados de reflectância do sensor MSI/Sentinel-2 em conjunto com medições in situ, o trabalho visa aprimorar o monitoramento da qualidade da água nesse reservatório, essencial para o abastecimento de água, a geração de energia e a preservação ambiental. A aplicação de modelos de aprendizado de máquina demonstrou ser eficaz para prever os parâmetros da qualidade da água, com destaque para o modelo Random Forest, que obteve bons ajustes nos dados. A combinação de dados de sensoriamento remoto e técnicas de aprendizado de máquina proporciona um avanço significativo em relação às metodologias tradicionais de amostragem, permitindo estimativas mais precisas e contínuas, com menores custos e maior abrangência temporal e espacial. O impacto direto desse trabalho se reflete no desenvolvimento de ferramentas mais eficazes para a gestão de recursos hídricos, além de possibilitar um monitoramento mais eficiente da qualidade da água em grandes reservatórios, contribuindo para a conservação dos ecossistemas aquáticos. No contexto social, pode ser aplicada a diversas regiões do Brasil, promovendo um monitoramento mais acessível e de maior alcance. Economicamente, o trabalho reduz custos operacionais associados ao monitoramento tradicional, beneficiando tanto as empresas do setor energético quanto os gestores de recursos hídricos. Esse trabalho se alinha aos Objetivos de Desenvolvimento Sustentável (ODS), especialmente ao ODS 6 (Água Potável e Saneamento), ao ODS 13 (Ação Contra a Mudança Global do Clima) e ao ODS 15 (Vida Terrestre), e contribui para a criação de soluções mais sustentáveis para o uso da água e a preservação ambiental.

IMPACT INDICATORS

The objective of this study is to develop models to estimate water quality parameters, such as Total Dissolved Solids (TDS), Total Solids (TS), and Turbidity, in the UHE Jaguara reservoir. Using MSI/Sentinel-2 reflectance data combined with in situ measurements, the study aims to enhance water quality monitoring in this important reservoir, which is essential for water supply, energy generation, and environmental preservation. The application of machine learning models proved to be effective in predicting water quality parameters, with the Random Forest model showing good data fit. The combination of remote sensing data and machine learning techniques represents a significant advancement over traditional sampling methodologies, allowing for more accurate and continuous estimates with lower costs and greater temporal and spatial coverage. The direct impact of this work is reflected in the development of more effective tools for water resource management, as well as enabling more efficient monitoring of water quality in large reservoirs, contributing to the conservation of aquatic ecosystems. In the social context, this approach can be applied to various regions in Brazil, promoting more accessible and broader monitoring. Economically, the work reduces operational costs associated with traditional monitoring, benefiting both energy sector companies and water resource managers. This work aligns with the United Nations Sustainable Development Goals (SDGs), particularly SDG 6 (Clean Water and Sanitation), SDG 13 (Climate Action), and SDG 15 (Life on Land), contributing to the creation of more sustainable solutions for water use and environmental preservation.

SUMÁRIO

1	INTRODUÇÃO.....	13
2	OBJETIVOS.....	16
2.1	OBJETIVO GERAL.....	16
2.2	OBJETIVO ESPECÍFICOS	16
3	REVISÃO DE LITERATURA	17
3.1	POLUIÇÃO DAS ÁGUAS	17
3.2	MONITORAMENTO E VARIÁVEIS DE QUALIDADE DA ÁGUA	18
3.3	SENSORIAMENTO REMOTO.....	20
3.3.1	Processamento digital de imagens.....	21
3.3.2	Radiação Eletromagnética (REM).....	21
3.4	SENSORIAMENTO REMOTO DA ÁGUA	22
3.4.1	Instrumentos usados no sensoriamento remoto aquático	24
3.4.2	Propriedades ópticas da água.....	25
3.5	MODELAGEM DE COMPONENTES OPTICAMENTE ATIVOS NA ÁGUA ...	26
3.5.1	Fitoplânctons (pigmentos fotossintetizantes)	26
3.5.2	Concentração do Total de Material em Suspensão.....	28
3.5.3	Efeitos da Presença da Turbidez na Reflectância da Água	30
3.5.4	Matéria orgânica dissolvida colorida.....	31
3.6	CORREÇÃO ATMOSFÉRICA	33
3.7	MODELAGEM MATEMÁTICA DA QUALIDADE DE ÁGUAS SUPERFICIAIS 35	
3.8	APRENDIZADO DE MÁQUINA	36
3.8.1	Regressão Linear	36
3.8.2	Random Forest.....	37
3.8.3	Árvore de Decisão <i>Decision Tree</i>	38
3.8.4	Máquinas de Vetores de Suporte Support Vector Machine (SVM)	39
4	MATERIAL E MÉTODOS	41
4.1	ÁREA DO ESTUDO.....	41
4.2	Etapas Metodológicas.....	42
4.3	AQUISIÇÃO DE DADOS LIMNOLÓGICOS.....	44
4.4	CÁLCULO DO IQA – ÍNDICE DE QUALIDADE DAS ÁGUAS	45
4.5	AQUISIÇÃO DOS DADOS DE SENSORIAMENTO REMOTO	47
4.6	CORREÇÃO ATMOSFÉRICA	48

4.7	EXTRAÇÃO DOS VALORES DE REFLECTÂNCIA.....	49
4.8	GERAÇÃO DE MODELOS DE PREDIÇÃO	49
4.8.1	Análise de Regressão.....	50
4.8.2	Aprendizado de máquina.....	51
4.9	AVALIAÇÃO DOS MODELOS DE PREDIÇÃO.....	51
4.10	MAPA DE ESTIMATIVAS.....	52
5	RESULTADOS E DISCUSSÃO	53
5.1	DADOS DE QUALIDADE E CÁLCULO DO IQA	53
5.2	COMPORTAMENTO ESPECTRAL DA ÁGUA DO RESERVATÓRIO.....	56
5.3	MODELAGEM DOS SÓLIDOS DISSOLVIDOS TOTAIS.....	59
5.3.1	Resultados das amostragens de sólidos dissolvidos totais	59
5.3.2	Modelos de predição sólidos dissolvidos totais.....	61
5.4	SÓLIDOS TOTAIS	68
5.4.1	Resultados das análises de sólidos totais.....	68
5.4.2	Modelos de predição sólidos totais.....	71
5.5	TURBIDEZ	77
5.5.1	Resultados das análises de turbidez.....	77
5.5.2	Modelos de predição de turbidez.....	81
6	CONCLUSÃO	88
7	REFERÊNCIAS.....	89

1 INTRODUÇÃO

Os reservatórios de água doce são importantes para o abastecimento de água, agricultura irrigada, geração de energia hidrelétrica e navegação, além de serem essenciais para manter a biodiversidade e o ciclo hidrológico do planeta (Barbosa; Novo; Martins, 2019; Saberioon *et al.*, 2020; Saad *et al.*, 2021). No entanto, eles enfrentam desafios ambientais naturais e causados pelo homem, tornando o monitoramento da qualidade da água fundamental para preservar esses recursos hídricos (Karaoui *et al.*, 2019; Arango; Nairn, 2020; Papa *et al.*, 2023).

O monitoramento da qualidade da água em ambientes lênticos é uma necessidade fundamental para uma gestão eficaz dos recursos hídricos. Isso permite assegurar sua sustentabilidade e compreender a dinâmica do ambiente, levando em conta as atividades humanas circundantes (Gholizadeh *et al.*, 2016; Chen *et al.*, 2021).

Os grandes reservatórios brasileiros demandam o monitoramento extensivo de diferentes variáveis ambientais. No entanto, as medições atuais, realizadas de maneira tradicional e *in situ*, apresentam desafios significativos, incluindo custos elevados, demanda intensiva de trabalho e períodos prolongados (Karaoui *et al.*, 2019). Essas limitações tornam o processo inadequado para análises em grande escala, afetando a coleta de amostras em termos de alcance geográfico e frequência temporal (Mccarthy *et al.*, 2017; adjovu *et al.*, 2022).

Neste contexto, é essencial elaborar metodologias que proporcionem confiabilidade, eficiência, custos reduzidos e uma ampla abrangência espacial e temporal (Zhou *et al.*, 2017). Para preencher a lacuna entre a precisão e as análises em larga escala, a tecnologia de sensoriamento remoto demonstrou ser uma ferramenta adequada (Song *et al.*, 2011; Crasto *et al.*, 2015; Avdan *et al.*, 2019).

O monitoramento remoto é uma alternativa que possibilita a estimativa de variáveis de qualidade da água com alta frequência temporal. Vários satélites adquirem imagens e dados georreferenciados com resoluções que variam de centímetros a quilômetros, alguns deles realizando observações diariamente (Ritchie *et al.*, 2003; Shi *et al.*, 2018). Dados de sensoriamento remoto em formato digital são adquiridos e processados com facilidade e têm sido empregados desde a década de 1970 em avaliações da qualidade da água (Konratyev *et al.*, 1998; Hellweger *et al.*, 2004; Abbas *et al.*, 2019).

A metodologia empregada no sensoriamento remoto de ambientes aquáticos é baseada na interação entre a radiação eletromagnética (REM) e os componentes ópticos ativos, como matéria orgânica dissolvida e minerais em suspensão (Barbosa; Novo; Martins, 2019). Sensores a bordo de satélites medem a radiação refletida em várias faixas de comprimento de onda da

superfície da água, permitindo correlacioná-la com variáveis de qualidade da água. Essas reflexões podem ser utilizadas, tanto de forma direta quanto indireta, para detectar diversos indicadores de qualidade da água (McCullough *et al.*, 2012; Guneroglu *et al.*, 2013).

Para estabelecer uma conexão eficaz entre os dados de sensoriamento remoto e as informações locais sobre a qualidade da água, recorre-se a técnicas matemáticas e estatísticas na modelagem espacial (Adjovu *et al.*, 2023). Essa integração do sensoriamento remoto com um Sistema de Informação Geográfica (SIG) não apenas gera indicadores para o monitoramento da qualidade da água e das mudanças ambientais, mas também possibilita a automação do processamento de imagens, economizando tempo, reduzindo erros e padronizando o tratamento das imagens (Pinto *et al.*, 2014; Adjovu *et al.*, 2023).

Diversos autores têm utilizado o sensoriamento remoto para estimativa de variáveis ambientais de qualidade de água, como clorofila-a (Chl-a) (Pahlevan *et al.*, 2020), turbidez (Hossain *et al.*, 2021), sólidos suspensos totais (SST) (Saberioon *et al.*, 2020), fósforo total (Du *et al.*, 2018) e profundidade do disco de Secchi (SSD) (Chen *et al.*, 2019).

Dentre os diversos parâmetros de qualidade da água, os Sólidos Dissolvidos Totais (SDT), os Sólidos Totais (ST) e a Turbidez se destacam por sua relevância ambiental e por apresentarem características ópticas que permitem sua estimativa por meio de sensoriamento remoto (Barbosa; Novo; Martins, 2019). Esses parâmetros afetam diretamente a forma como a radiação eletromagnética interage com a superfície da água, alterando a refletância registrada pelos sensores (Adjovu *et al.*, 2023).

A turbidez, relacionada à presença de partículas em suspensão, influencia fortemente a dispersão e a absorção da luz, especialmente nas bandas do espectro visível e do infravermelho próximo. Os Sólidos Totais, que englobam tanto a fração dissolvida quanto a particulada, e os Sólidos Dissolvidos Totais, associados principalmente à presença de sais e matéria orgânica solúvel, também alteram a assinatura espectral da água, embora de forma mais sutil (Sagan *et al.*, 2020; Liu *et al.*, 2017; Fraga *et al.*, 2020). Assim, compreender o comportamento espectral desses parâmetros possibilita o desenvolvimento de modelos empíricos e estatísticos para sua estimativa remota, permitindo análises em grande escala espacial e com alta frequência temporal, especialmente úteis em reservatórios extensos e com logística complexa de monitoramento *in situ*.

Existe uma variedade de sensores orbitais ópticos que oferecem oportunidades científicas para a pesquisa em águas interiores, sendo o Sentinel-2 um exemplo daqueles mais utilizados. Este sensor proporciona imagens com resolução radiométrica de 12 bits, resolução espacial variando entre 10, 20 e 60 metros, e resolução espectral composta por 13 bandas

(Pahlevan *et al.*, 2017; Zhou *et al.*, 2017; ESA, 2021). Essas configurações proporcionam a capacidade de mapear sistemas hídricos, desde extensões amplas até sistemas pequenos e irregulares. Elas demonstram maior sensibilidade radiométrica para distinguir variáveis bio-óticas e oferecem uma frequência temporal adequada, permitindo o monitoramento de mudanças na composição da água ao longo do tempo (Martins *et al.*, 2017).

Esses elementos representam vantagens da ferramenta, amplamente utilizada em estudos de monitoramento de lagos e reservatórios (Odermatt *et al.*, 2018). No entanto, a maioria dos estudos atuais lida com dados provenientes de ambientes aquáticos frequentemente eutrofizados, o que torna evidente o desafio de qualificar águas claras por meio de sensoriamento remoto, como é evidenciado nas águas do Reservatório Jaguará Localizada bacia hidrográfica do Rio Grande, entre os estados de São Paulo e Minas Gerais, as quais apresentam características que podem variar de águas claras a moderadamente claras.

Diante da importância de monitorar a qualidade da água, este trabalho busca aprimorar a técnica de sensoriamento remoto, especialmente para corpos hídricos com menos poluição. O reservatório da UHE Jaguará, localizado na divisa entre os estados de Minas Gerais e São Paulo, é um ponto estratégico para o monitoramento, já que ele fica na região do Triângulo Mineiro e abriga a Usina Hidrelétrica Jaguará, operada pela ENGIE Brasil Energia. Esse reservatório não só é essencial para a geração de energia e abastecimento de água, mas também para atividades de lazer, transporte e outros usos que dependem de sua qualidade hídrica, que, infelizmente, tem sido afetada pela degradação.

Assim, o objetivo deste estudo é desenvolver modelos para estimar parâmetros da qualidade da água, como os Sólidos Dissolvidos Totais (SDT), Sólidos Totais (ST) e a Turbidez, no reservatório da UHE Jaguará. Para isso, foram utilizados dados de reflectância do sensor MSI/Sentinel-2, em conjunto com medições *in situ*, com o intuito de oferecer um monitoramento mais eficiente e preciso da qualidade da água nesse importante reservatório.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Este trabalho teve como objetivo desenvolver modelos para estimar os parâmetros de qualidade da água, especificamente Sólidos Dissolvidos Totais (SDT), Sólidos Totais (ST) e Turbidez, no Reservatório de Jaguara, localizado na divisa entre os estados de Minas Gerais e São Paulo, utilizando dados de reflectância obtidos por imagens do sensor MSI/Sentinel-2 em conjunto com dados *in situ*.

2.2 OBJETIVO ESPECÍFICOS

- Avaliar a qualidade da água e discutir a variação espacial das variáveis sólidos dissolvidos totais, sólidos totais e turbidez no Reservatório de Jaguara;
- Avaliar o comportamento espectral da água na área de estudo;
- Comparar as imagens geradas dos índices espectrais com a variação espacial de sólidos dissolvidos totais, sólidos totais e turbidez na represa;
- Avaliar a influência das condições do ambiente na estimativa da concentração de sólidos dissolvidos totais, sólidos totais e turbidez;
- Verificar o desempenho de análises de modelos de aprendizagem de máquinas e modelos de regressão para modelagem de variáveis ambientais por meio de dados espectrais;
- Calibrar e validar um modelo para predição de Sólidos Dissolvidos Totais (SDT), Sólidos Totais (ST) e Turbidez utilizando imagens do satélite Sentinel-2;
- Gerar mapa com a espacialização das estimativas de sólidos dissolvidos totais, sólidos totais e turbidez no Reservatório de Jaguara.

3 REVISÃO DE LITERATURA

3.1 POLUIÇÃO DAS ÁGUAS

A lei nº 9.433, promulgada em 8 de janeiro de 1997, estabelece a Política Nacional de Recursos Hídricos (PNRH) e o Sistema Nacional de Gerenciamento de Recursos Hídricos (SINGREH), além de outras regulamentações. Essa lei cita que a “água é um recurso natural limitado, dotado de valor econômico”. Ressalta-se que antes disso a água é um fator essencial para a vida e, por isso, é considerada um bem de domínio público e deve ser preservada (Brasil, 1997).

No Brasil, apesar da abundância de recursos hídricos, muitos brasileiros ainda enfrentam dificuldades de acesso à água em quantidade e qualidade adequadas, devido aos fatores locais e financeiros (Pasqualetto *et al.*, 2022). Essa situação é agravada pela degradação contínua das fontes de água causada por diversas atividades humanas, como poluição doméstica e industrial, uso inadequado do solo, insumos agrícolas impróprios, desmatamento, mineração e outras ações, comprometendo a quantidade e a qualidade da água disponível (Mello *et al.*, 2020), levando às situações de conflito (Peixoto *et al.*, 2022).

Nesse contexto, a poluição das águas emerge como um dos problemas mais urgentes. A poluição pode ser definida como a introdução de substâncias ou formas de energia que alteram a natureza dos corpos d'água, prejudicando os usos legítimos desses recursos (Von Sperling, 2014). No entanto, essa poluição representa apenas um sintoma visível de uma relação mais complexa entre as atividades humanas e os recursos hídricos, destacando a intrincada interdependência entre ambos (Mello *et al.*, 2020).

Dessa forma, torna-se evidente a necessidade de aumentar a conscientização sobre a importância da gestão sustentável da água. A preservação das fontes de água doce exige a colaboração de diversos setores da sociedade. Desde a adoção de práticas individuais de conservação até a implementação de políticas públicas fundamentadas, todos desempenham um papel crucial para garantir um futuro no qual a água seja um recurso acessível e de qualidade para todos os cidadãos brasileiros (Mamedes *et al.*, 2023).

A poluição de corpos d'água resulta na degradação da qualidade da água e no comprometimento do ecossistema aquático como um todo. A alteração na qualidade do recurso pode agravar problemas relacionados à disponibilidade de água, como a possibilidade de escassez devido à contaminação de fontes de água. Uma abordagem eficaz para controlar a qualidade da água requer monitoramento constante de parâmetros específicos definidos por

normas ambientais (Chapman; Sullivan, 2022). Assim, é necessário que ações de monitoramento e controle sejam estabelecidas visando garantir o acesso das atuais e futuras gerações à água em quantidade e qualidade suficientes para satisfazer suas necessidades básicas.

3.2 MONITORAMENTO E VARIÁVEIS DE QUALIDADE DA ÁGUA

O Brasil, com suas dimensões continentais, abriga um vasto potencial hídrico distribuído pelas diversas bacias hidrográficas que se estendem por todo o país. Esse potencial é amplamente explorado em regiões onde a topografia propicia a construção de reservatórios para aproveitar cursos d'água com grande volume de água, com o propósito de atender aos variados objetivos, incluindo o abastecimento de água à população e/ou a produção de energia hidrelétrica (Pellegrini *et al.*, 2016).

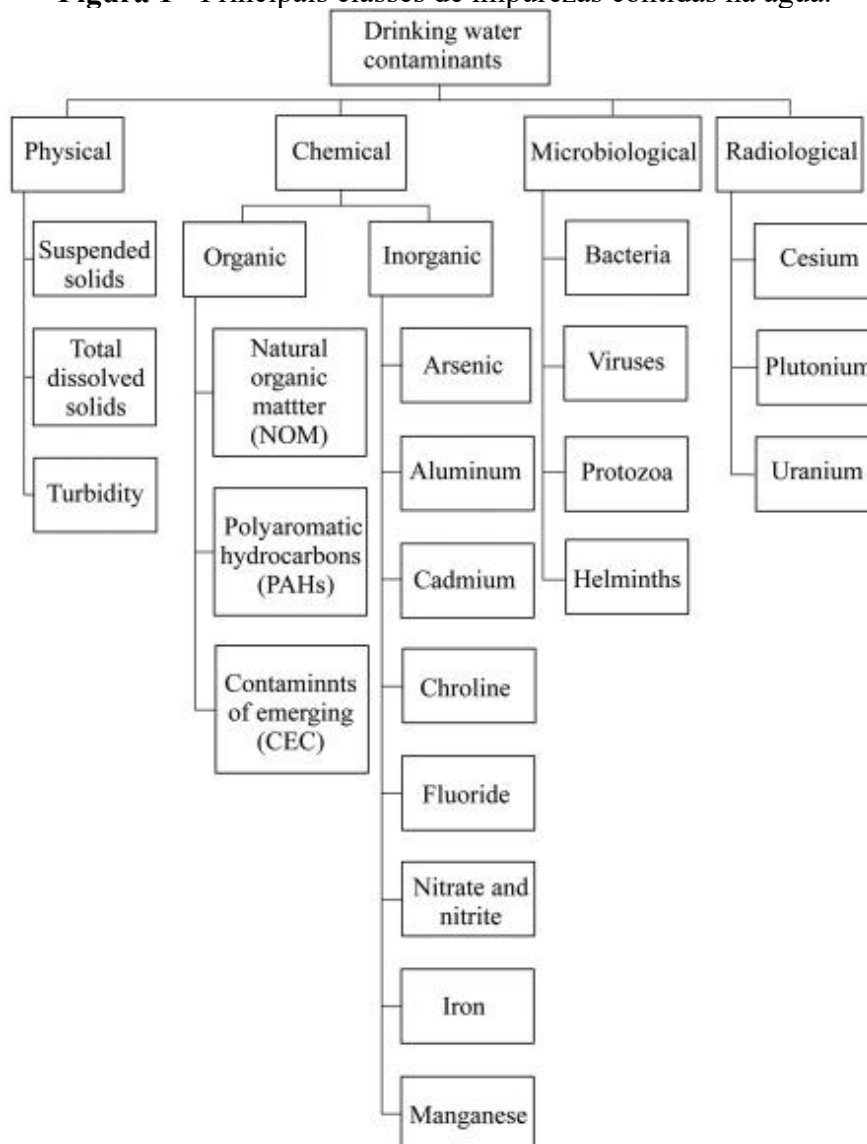
Entretanto, a criação de reservatórios, ao provocar a mudança repentina de um ecossistema lótico (rio) para um ambiente lêntico (lago), desencadeia transformações nos padrões fluviais e desequilíbrios substanciais na composição físico-química e hidrobiológica do ambiente aquático. Isso pode resultar em efeitos ambientais consideráveis, frequentemente com impactos adversos, tanto a montante quanto a jusante da estrutura de barramento (Von Sperling, 2012; Tundisi, 2018).

Devido às suas características solventes e à sua habilidade de transportar partículas, a água não é encontrada no ambiente em sua forma puramente molecular (H₂O). Nela estão presentes compostos de origem natural e antropogênica, tais como sais, metais, microrganismos, matéria orgânica, entre outros (Shah *et al.*, 2023). Esses elementos, desempenham o papel de descrever as características da sua qualidade, assumindo, portanto, a responsabilidade pela categorização dela com base na importância do seu uso (Von Sperling, 2014).

Dessa forma, torna-se necessário o monitoramento da qualidade da água para a determinação dos possíveis impactos ambientais tanto em ambientes hídricos naturais quanto em ambientes artificiais como reservatórios (Chou; Ho; Hoang, 2018; Vasistha; Ganguly, 2020). O monitoramento regular da qualidade das águas é uma ferramenta essencial de planejamento e gestão, porém, não se trata de uma prática fácil (Goher *et al.*, 2014) devido à gama de parâmetros que podem qualificar a água, além da escassez de recursos financeiros e humanos e a indisponibilidade de infraestruturas. Por isso as técnicas de acompanhamento da qualidade da água devem ser aprimoradas (Jiang *et al.*, 2020; Barcellos; Souza, 2022).

Para avaliar a qualidade de um reservatório específico, é necessário conduzir um processo de amostragem que envolve coletas pontuais ao longo da massa d'água. Essas medidas possibilitam a identificação dos elementos presentes, suas concentrações e as condições ambientais em que a água se encontra. A avaliação dessas variáveis de qualidade pode ser realizada em laboratório por meio de análises físicas, químicas e biológicas ou diretamente no local com o auxílio de sondas e/ou sensores (Barbosa; Novo; Martins, 2019). A Figura 1 destaca as categorias predominantes de impurezas na composição da água.

Figura 1 - Principais classes de impurezas contidas na água.



Fonte: Shah *et al.* (2023).

A qualidade da água em ambientes lênticos pode ser avaliada a partir de suas características físicas, químicas e/ou biológicas. Esses componentes, que influenciam a pureza da água, podem ter características físicas relacionadas ao estado sólido (série de sólidos,

resíduos) ou gasoso (dissolvidos), propriedades químicas que podem ser inorgânicas (como sais e metais) ou orgânicas (matéria em decomposição), e atributos biológicos representados por organismos vivos de origem animal, vegetal ou protista (Von Sperling, 2014). Além dos compostos emergentes, que podem alterar a qualidade da água (Shah *et al.*, 2023).

Diversos parâmetros podem ser utilizados para avaliar a qualidade da água. No entanto, a medição dessas variáveis nem sempre é simples. Além dos custos envolvidos, fatores como o clima, a geografia do local e a presença de obstáculos naturais, como rios com grande volume e correnteza, podem dificultar o acesso aos pontos de coleta. Isso pode comprometer a representatividade das amostras, que nem sempre refletem com precisão as condições da água em toda a área estudada (Gholizadeh *et al.*, 2016; Schuwirth, 2020), além das variações dos processos analíticos laboratoriais que podem conduzir a valores não representativos do ambiente (Farouk; Jamil; Latip, 2023).

Diante da importância da preservação dos recursos hídricos e da crescente magnitude dos desafios globais relacionados à qualidade da água, é imperativo adotar tecnologias de custo acessível para viabilizar um monitoramento mais eficaz. Essa abordagem visa aprimorar a gestão desses recursos e responder às suas exigências (Adjovu *et al.*, 2023; Yang *et al.*, 2022).

Nesse sentido, o sensoriamento remoto surge como recurso adicional para monitorar recursos hídricos, possibilitando inferir parâmetros de qualidade da água a partir da análise dos padrões espectrais da radiação solar refletida pela superfície aquática (Arango e Nairn, 2020). Componentes na água, como clorofila-a, matéria orgânica dissolvida colorida, material em suspensão, atenuação da luz, transparência da água, turbidez, afetam os padrões espectrais da radiação, tornando o sensoriamento remoto viável para avaliação da qualidade da água (Barbosa; Novo; Martins, 2019; Rosa, 2007).

3.3 SENSORIAMENTO REMOTO

Em linhas gerais, sensoriamento remoto é definido como a aquisição de dados em diversas faixas do espectro eletromagnético obtidas a partir de sensores acoplados em aeronaves espaçonaves ou outras plataformas, com o objetivo de estudar eventos, fenômenos e processos que ocorrem na superfície na Terra, a partir do registro e da análise das interações entre a radiação eletromagnética (Jensen, 2011; Novo, 2008).

Nesse contexto, o sensoriamento remoto investiga a interação entre as propriedades do objeto em foco e a energia eletromagnética que é refletida, emitida ou dispersada por ele. Ao analisar os padrões espectrais de diferentes superfícies, como solo, água e vegetação, torna-se

viável estabelecer conexões entre informações tanto qualitativas quanto quantitativas desses alvos (Jensen, 2011).

Imagens obtidas por sensoriamento remoto têm sido amplamente utilizadas em várias áreas de pesquisa e trabalho, como agricultura, ecologia e meio ambiente, por sua capacidade de capturar informações detalhadas da superfície terrestre (Xiao *et al.*, 2023).

3.3.1 Processamento digital de imagens

A evolução do sensoriamento remoto ocorreu a partir do desenvolvimento da tecnologia espacial e da óptica. Atualmente, o sensoriamento remoto por imageamento orbital é favorecido pela quantidade de satélites que estão disponíveis na órbita terrestre, obtendo imagens com maior ou menor resolução diariamente (Gomes *et al.*, 2020; Wang *et al.*, 2023).

Para compreender informações das imagens do sensoriamento remoto, é crucial conhecer o comportamento espectral dos objetos na superfície terrestre e os fatores que o afetam. Grande parte das pesquisas nesse campo visa relacionar a quantidade de energia eletromagnética refletida, emitida ou retroespalhada em faixas específicas com características dos sistemas biológicos e ambientais da terra que incluem o estudo da geologia, da atmosfera, da hidrosfera e da biosfera (Ferrández-Pastor; García-Chamizo; Nieto-Hidalgo, 2017; Porwal; González-Álvarez, 2019).

Os sistemas de sensoriamento remoto têm várias aplicações, permitindo medições diretas de variáveis biofísicas com sensores adequados. Para estudos de vegetação, por exemplo, é possível determinar pigmentos, estrutura, altura do dossel, biomassa via índices de vegetação e evapotranspiração. Ao focar na caracterização da água, esses sistemas fornecem informações sobre minerais em suspensão, clorofila, matéria orgânica suspensa/dissolvida e hidrologia superficial (Barbosa; Novo; Martins, 2019; Zhang *et al.*, 2021; Lioumbas *et al.*, 2023).

3.3.2 Radiação Eletromagnética (REM)

A fonte de energia para todos os processos físico-químicos e biológicos que ocorrem na superfície terrestre é o sol. Portanto, a compreensão de conceitos fundamentais como a radiação solar é essencial para o entendimento dos processos subjacentes às estimativas das variáveis de qualidade da água por meio do sensoriamento remoto. Interpretação dos dados adquiridos a partir de imagens aéreas é fundamentada na compreensão da interação da radiação

eletromagnética (REM) com os corpos d'água (Barbosa; Novo; Martins, 2019; Sagan *et al.*, 2020).

Os sensores remotos são instrumentos que têm a capacidade de identificar a energia eletromagnética proveniente de um objeto em certas faixas do espectro eletromagnético (Jafarbiglu; Pourreza, 2022). Eles convertem essa energia em um sinal elétrico, o qual é então registrado. Esses dados podem ser armazenados ou transmitidos em tempo real, a fim de serem posteriormente transformados em informações que descrevem as características dos elementos presentes na superfície terrestre (Javaid *et al.*, 2021).


A radiação eletromagnética (REM) desempenha um papel vital na interligação de todos os elementos fundamentais no sensoriamento remoto: a fonte (o sol), o alvo (a superfície terrestre) e o sensor (o instrumento capaz de coletar dados). O sol é a fonte essencial da REM necessária para aplicar técnicas de sensoriamento remoto no estudo dos recursos naturais. O sensor, por sua vez, é o dispositivo capaz de coletar e registrar a REM refletida ou emitida pelo alvo, que representa o elemento do qual se pretende extrair informações (Blaschke; Hermann, 2007; Jafarbiglu; Pourreza, 2022).

Para uma compreensão dos princípios do sensoriamento remoto, é fundamental levar em conta duas características da REM: o comprimento de onda e a frequência. O comprimento de onda é definido como a distância entre duas cristas consecutivas de uma onda e é expresso em unidades como metros (m) ou seus submúltiplos. A frequência de onda, por sua vez, representa a quantidade de oscilações que passam por um ponto fixo em um intervalo de tempo e é medida em Hertz (Hz), o que equivale a um ciclo por segundo (Liu; Bao, 2021).

3.4 SENSORIAMENTO REMOTO DA ÁGUA

Da mesma maneira que as imagens provenientes de sensoriamento remoto conseguem detectar as distintas características espectrais dos elementos presentes na superfície terrestre, elas também têm a capacidade de registrar essas modificações no comportamento da água. Essas mudanças podem ser capturadas por meio de sensores instalados em plataformas terrestres, aéreas ou orbitais (Jafarbiglu; Pourreza, 2022). Para aplicar o sensoriamento remoto em corpos d'água, é fundamental compreender inicialmente como a água pura absorve e espalha a radiação incidente ou a luz solar na coluna d'água (Curtarelli *et al.*, 2020). A Figura 2 ilustra a jornada da luz solar desde a emissão até atingir alvos aquáticos e retornar ao sensor orbital.

Figura 2 - Interações entre a radiação solar com atmosfera (1), corpo d'água (2, 3 e 4) e os componentes opticamente ativos - COAs de um ecossistema aquático (5, 6 e 7) durante o processo de sensoriamento remoto.



Fonte: Barbosa; Novo; Martins, (2019).

Conforme observado na Figura 2 os processos de espalhamento e absorção da luz na água são influenciados pelas substâncias presentes nela. Isso possibilita estimar a concentração dos elementos transportados pela água, como partículas inorgânicas e orgânicas, substâncias orgânicas dissolvidas e organismos vivos. Esses componentes, conhecidos como componentes opticamente ativos (COAs), afetam a coloração da água e sua qualidade (Barbosa; Novo; Martins, 2019; Karimi *et al.*, 2023).

O sensoriamento remoto em ambientes aquáticos busca medir e mapear parâmetros como clorofila, sólidos em suspensão, turbidez e matéria orgânica na água. Esses dados são cruciais para entender as condições biológicas e tróficas dos ecossistemas aquáticos. Utilizando sensores passivos alimentados pela radiação solar, conhecido como sensoriamento da cor da água, a faixa do espectro eletromagnético entre 400 e 900 nanômetros é a mais adequada para essas medições (Albert; Gege, 2006; Sagan *et al.*, 2020).

Nos últimos anos, tem havido um crescimento do uso de sensoriamento remoto abrangendo diversos campos científicos (Guo *et al.*, 2023a). No monitoramento aquático não é diferente, pois vários pesquisadores têm se dedicado a explorar as possibilidades do sensoriamento remoto para prever e estimar variáveis ambientais. Hossain *et al.* (2021) e Magri *et al.* (2023) desenvolveram modelos numéricos de estimativa de turbidez a partir de imagens de satélite. Shang *et al.* (2017) utilizaram um veículo aéreo não tripulado (VANT) e Lai *et al.* (2023a), imagens de satélite, na avaliação do florescimento de fitoplâncton. Kim *et al.* (2017), Lai *et al.* (2023b) e CAO *et al.* (2023a) determinaram a eficiência do sensor MODIS na determinação de clorofila a e sólidos em águas superficiais. Todos os autores verificaram a possibilidade da utilização das imagens aéreas para o monitoramento da qualidade da água.

3.4.1 Instrumentos usados no sensoriamento remoto aquático

A tecnologia de sensoriamento remoto tem sido utilizada para representar a distribuição espacial e as mudanças dinâmicas nos componentes da qualidade da água, devido às vantagens oferecidas em termos de cobertura espacial e temporal (Odermatt *et al.*, 2018; Chawla; Karthikeyan; Mishra, 2020). Sensores ópticos, que são dispositivos que avaliam a quantidade de radiação eletromagnética em diversos comprimentos de onda refletida pela superfície de corpos d'água (Adjovu *et al.*, 2023), desempenham um papel crucial nesse processo. Em particular, essas medições são fundamentais para a geração de modelos de sensoriamento aquático (LI *et al.*, 2020a).

A predição de parâmetros físico-químicos, para avaliar a qualidade da água em ambientes lênticos por sensoriamento remoto pode ser realizada em diferentes escalas, sejam locais, regionais, continentais ou globais (Chawla; Karthikeyan; Mishra, 2020; Sagan *et al.*, 2020). Quando se trata de modelos que combinam dados *in situ* com informações de satélite, é fundamental sincronizar as datas das campanhas de coleta de dados e as passagens dos satélites para obter resultados mais precisos (CHEN *et al.*, 2016; Lee *et al.*, 2022).

A maioria das imagens de satélite com resolução espacial moderada a alta está disponível gratuitamente por meio de agências espaciais (Li *et al.*, 2019), como o *Earth Explorer* do Serviço Geológico dos Estados Unidos (*United States Geological Survey* - USGS), ou o *Copernicus Open Access Hub* da Agência Espacial Europeia (*European Space Agency* - ESA) (Gascon *et al.*, 2017; Guo *et al.*, 2023b). No Brasil, o Instituto Nacional de Pesquisas Espaciais - INPE e a Empresa Brasileira de Pesquisa Agropecuária - EMBRAPA realizam o processamento das imagens de diversos sensores e disponibilizam gratuitamente em suas bases

de dados na internet. Também é possível adquirir dados de sensores comerciais de alta resolução espacial ou espectral, porém, essas opções podem ser dispendiosas (Assis *et al.*, 2019).

Sensores multiespectrais e hiperespectrais recentes foram projetados para uso em plataformas aéreas como aviões, helicópteros e veículos aéreos não tripulados. Drones têm se popularizado para o sensoriamento remoto devido à disponibilidade de sensores leves (Van Der Merwe; Price 2015; Graham *et al.*, 2022).

Sensores transportados por aeronaves, como APEX, MIVIS e HySpex, são usados para monitorar a qualidade da água. Apesar de serem grandes e pesados, podem ser usados em aeronaves tripuladas ou drones avançados. Esses sensores fornecem imagens de alta resolução espacial e espectral, permitindo o monitoramento de corpos d'água em várias condições (Sabat-Tomala *et al.*, 2018; Kutser *et al.*, 2020).

3.4.2 Propriedades ópticas da água

As águas naturais são compostas por materiais dissolvidos e partículas que influenciam a maneira como a luz é absorvida e espalhada. Esses elementos são conhecidos como componentes opticamente ativos (COAs) (Barbosa; Novo; Martins, 2019; Karimi; Hashemi; Aghighi, 2023). Entre os COAs, destacam-se a água pura, a matéria orgânica dissolvida colorida (CDOM) e o material particulado total, como fitoplâncton e sedimentos, cada um apresentando propriedades ópticas únicas de absorção e espalhamento da radiação solar (Kirk, 2011; Cai *et al.*, 2023).

A coexistência variável desses COAs na água gera interações complexas com a luz solar, influenciando tanto a absorção quanto o espalhamento da radiação. Isso, por sua vez, determina as características espectrais da água, enquanto as concentrações dos COAs regulam a intensidade da radiação refletida na coluna d'água (Barbosa; Novo; Martins, 2019).

Consequentemente, na hidrologia, as propriedades ópticas estão intrinsecamente ligadas à interação com a luz solar, resultando na modificação do espectro de energia da radiação solar refletida nas massas de água (Adjovu *et al.*, 2023). Essas propriedades podem ser categorizadas em duas classes: Propriedades Ópticas Inerentes (POI), que se alteram apenas com a composição da água, não sendo afetadas pela luz incidente; e Propriedades Ópticas Aparentes (POA), que dependem tanto do meio quanto da geometria da luz incidente (Ogashawara; Li; Druschel, 2022).

Embora as propriedades ópticas inerentes (POIs) sejam mais diretamente ligadas à composição do meio, sua medição direta por satélites é inviável. Por isso, recorre-se às propriedades ópticas aparentes (POAs), que podem ser obtidas a partir de observações remotas e são influenciadas tanto pelas POIs quanto pela geometria da luz incidente (Mobley, 2015).

Entre as POAs, destaca-se a refletância de sensoriamento remoto (R_{rs}), definida como a razão entre a radiância da água e a irradiância descendente (Mobley; Boss; Roesler, 2010). Essa medida, no entanto, requer correções ópticas devido à interferência de reflexos do céu e do sol na superfície da água (Lee *et al.*, 2022). Fatores como o ângulo de visada do sensor, o estado da superfície da água e a variação espectral da luz ambiente afetam diretamente a precisão da estimativa da reflectância remota (Mobley, 2015).

3.5 MODELAGEM DE COMPONENTES OPTICAMENTE ATIVOS NA ÁGUA

As técnicas de modelagem desempenharam um papel altamente relevante nos estudos relacionados à hidrologia. O uso do sensoriamento remoto para avaliar a qualidade da água, com enfoque em pesquisas científicas, tem sido abordado em diversas áreas do conhecimento. No entanto, para utilizar eficazmente o sensoriamento remoto em pesquisas aquáticas, é fundamental possuir um conhecimento prévio sobre como os diferentes componentes da água se manifestam em termos espectrais (Liu; Wang, 2019; Ouma *et al.*, 2020).

3.5.1 Fitoplânctons (pigmentos fotossintetizantes)

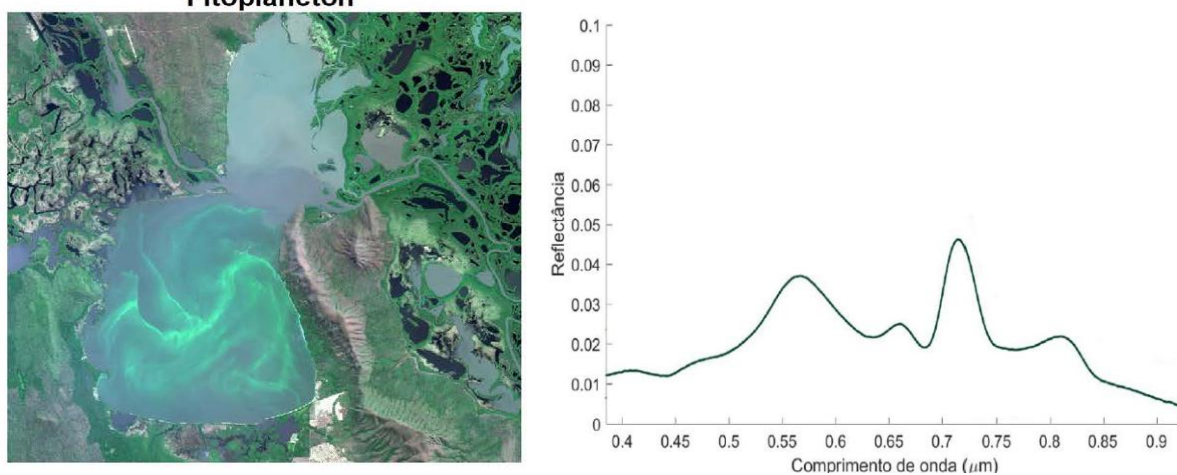
Os principais pigmentos que contribuem para a absorção da radiação solar são os fotossintetizantes, como clorofila e carotenoides. A concentração de clorofila a (Chl-a), em específico, é usada como um indicador para detectar a presença de fitoplâncton e avaliar o nível trófico de um ecossistema aquático. Esses pigmentos têm um papel fundamental na avaliação da saúde e das características dos sistemas aquáticos (Barbosa; Novo; Martins, 2019).

Existe uma preocupação em relação à proliferação de cianobactérias, pois elas podem produzir metabólitos conhecidos como cianotoxinas em corpos d' água. Essas toxinas representam uma ameaça à saúde pública. A detecção do fitoplâncton em águas continentais, que pode conter espécies de cianobactérias produtoras de substâncias prejudiciais à saúde humana, pode ser realizada por meio de sensoriamento remoto, usando estimativas remotas de chl-a e pigmentos fotossinteticamente ativos (PC) (Ogashawara, 2019; Rolim *et al.*, 2023).

A variação nos níveis de Chl-a é indicativa da proliferação de diferentes tipos de algas e cianobactérias, uma consequência da eutrofização em corpos d' água doce, e que está diretamente relacionada à concentração de Chl-a, uma vez que esse pigmento é essencial para a fotossíntese (Mishra *et al.*, 2019). Essas concentrações podem variar conforme o metabolismo, luz, temperatura, disponibilidade de nutrientes e outros fatores. Portanto, ao registrar a cor de uma superfície aquática, é possível estimar a quantidade e o tipo de fitoplâncton presente (Jensen, 2009; Al-thani *et al.*, 2023).

Nesse contexto, a Chl-a destaca-se como uma variante opticamente ativa da clorofila, desempenhando um papel essencial na fotossíntese. Ela representa uma das variáveis de qualidade da água que tem sido extensivamente estudada por meio do sensoriamento remoto, conforme ilustrado na Figura 3.

**Figura 3 - Espectros da água sob dominância de clorofila-a.
Fitoplâncton**



Fonte: Barbosa, Novo; Martins (2019).

As pesquisas têm revelado correlações consistentes entre a detecção de chl-a e a utilização de imagens de satélites, em lagos, reservatórios e zonas costeiras (Feng *et al.*, 2014; Ansper *et al.*, 2019; Mishra *et al.*, 2019; Rolim *et al.*, 2023).

Ha *et al.* (2017) Utilizaram a correlação entre a razão de reflectância da banda verde MSI Sentinel 2A (banda 3) versus banda vermelha (banda 4) para desenvolver um método para estimar a concentração de chl-a. Os resultados indicaram que a razão da banda verde-vermelha foi a opção mais apropriada para monitorar a concentração de chl-a no lago.

No estudo realizado por Ogashawara (2019), foi investigado o potencial do *Ocean and Land Color Instrument* (OLCI) a bordo do satélite Sentinel-3 para a identificação de chl-a. O

autor observou que ao utilizar razões simples de bandas para estimar esses pigmentos, obteve uma relação mais forte, evidenciada por um valor de R^2 mais elevado.

3.5.2 Concentração do Total de Material em Suspensão

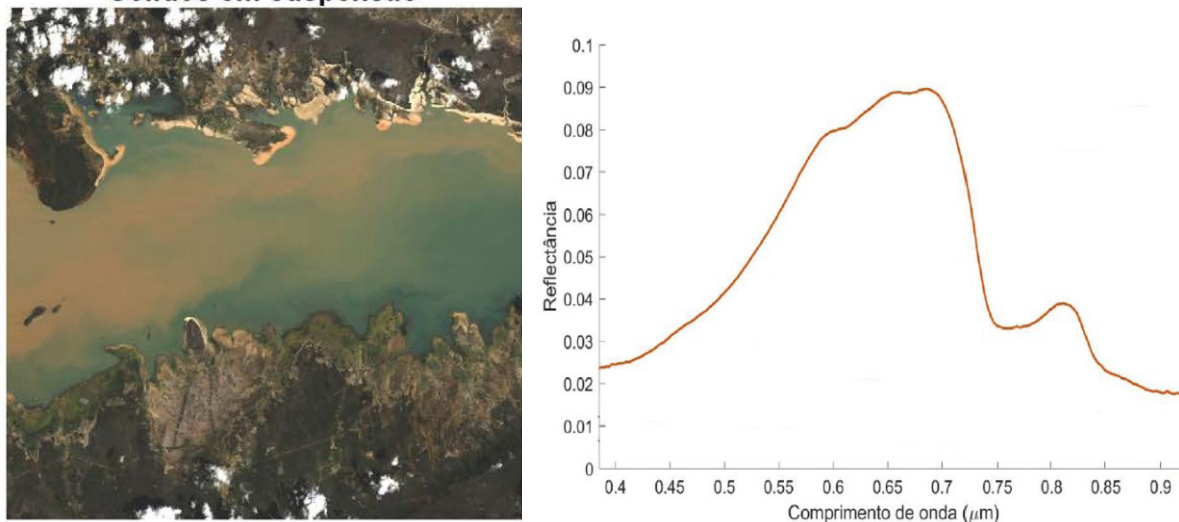
A concentração de sedimentos em suspensão afeta as características ópticas da água. Esses sedimentos consistem em partículas orgânicas (como detritos e microrganismos vivos) e inorgânicas (como minerais), presentes na água. A variação das partículas inorgânicas, desde argila fina até areia grosseira, influencia diretamente a refletância da água. A combinação de matéria orgânica não viva e matéria inorgânica em suspensão é chamada de tripton ou fração não algal (Barbosa; Novo; Martins, 2019).

Os sedimentos em suspensão têm várias fontes, como erosão agrícola e costeira. É importante estudar e monitorar seus tipos e quantidades. A erosão do solo em bacias hidrográficas, por exemplo, carrega sedimentos para corpos d'água, causando assoreamento e afetando a qualidade da água para uso humano (Jensen, 2009; Sagan *et al.*, 2020).

Corpos de água com partículas inorgânicas suspensas apresentam comportamento espectral mais elevado em relação à água pura, tal como apresentado na Figura 4. A concentração crescente de sedimentos suspensos na água amplia sua refletância devido ao aumento do coeficiente de espalhamento do volume de água (Alcântara; Curtarelli; Stech, 2016). No entanto, a radiação dispersa por esses sedimentos é influenciada por fatores como tamanhos de partículas e composição, tornando desafiador criar um algoritmo único para lidar com esses sedimentos (Liu *et al.*, 2017).

Modelos empíricos e semiempíricos têm sido amplamente empregados para quantificar a concentração de sólidos totais. Esses modelos, são simples e de fácil aplicação. Eles estabelecem relações estatísticas entre dados coletados *in situ* e valores de refletância. Para isso, utilizam análises de regressão linear e não linear, análise de componentes principais (ACP) e redes neurais artificiais (Al-Fahdawi *et al.*, 2015; Alcântara; Curtarelli; Stech, 2016; Markert *et al.* 2018). A Figura 4 exibe os espectros da água, destacando a predominância de sólidos totais em suspensão.

**Figura 4 - Espectros da água sob dominância de sólidos totais em suspensão.
Sólidos em suspensão**



Fonte: Barbosa, Novo e Martins (2019).

Markert *et al.* (2018) correlacionaram medições *in situ* de sólidos suspensos totais com observações coincidentes do satélite Landsat, desenvolvendo um modelo empírico para estimar essas concentrações na Bacia do Baixo Mekong. Devido à grande quantidade de dados e à ampla extensão geográfica da área de estudo, a plataforma *Google Earth Engine* foi utilizada para facilitar e acelerar o processamento das imagens. O modelo, fundamentado em razões de bandas espectrais, demonstrou desempenho superior em relação a estudos anteriores, apresentando um erro médio quadrático da raiz (RMSE) de $19 \text{ mg}\cdot\text{L}^{-1}$. Além disso, os autores disponibilizaram uma aplicação online hospedada no *Google App Engine*, permitindo que usuários sem conhecimento técnico em sensoriamento remoto tivessem acesso fácil às estimativas mensais de SST em toda a região, o que ampliou o monitoramento ambiental, especialmente em locais desprovidos de estações de medição convencionais.

Fraga *et al.* (2020), desenvolveram um modelo empírico para estimar a concentração de Sólidos Suspensos na Lagoa Mirim Norte com base em imagens do MSI Sentinel-2. Esse modelo empírico foi construído usando regressão linear múltipla e teve seu desempenho validado por meio do método de simulação de Monte Carlo. De acordo com os autores, o mapeamento dos Sólidos Suspensos se mostrou consistente com as medições *in situ*.

3.5.3 Efeitos da Presença da Turbidez na Reflectância da Água

A turbidez de uma amostra de água é caracterizada como o grau de atenuação que a energia incidente sofre ao atravessar a coluna d'água. Nesse sentido, a turbidez é frequentemente avaliada como um indicador de qualidade da água devido às suas propriedades ópticas ativas. E está relacionada com a produtividade das algas planctônicas e bentônicas nas águas, e é um bom indicador do total de sedimentos suspensos (Wang; Yang, 2019; Maimouni *et al.*, 2022).

O aumento da turbidez ocorre, geralmente, em estações chuvosas devido à movimentação do sedimento. Ações antrópicas como desmatamento, despejo de esgoto sanitário, efluentes industriais, agropecuários e mineração, fazem com que o escoamento superficial aumente a turbidez da água resultando em grandes alterações no ecossistema aquático (Fernandes *et al.*, 2021; Hall *et al.*, 2022).

O crescimento na concentração de turbidez na água está intimamente relacionado ao acréscimo da reflectância. À medida que a turbidez se intensifica, há um maior fluxo de energia sendo captado pelo sensor. Esse efeito ocorre porque as partículas responsáveis pela turbidez possuem a capacidade de retroespalhar ou refletir uma quantidade mais elevada de radiação solar, o que resulta nesse incremento no sinal detectado (Alcântara; Curtarelli; Stech, 2016; Rudorff *et al.*, 2018; Adjovu, 2023).

A partir da análise da radiação eletromagnética (REM) que é refletida pelo corpo de água, é possível deduzir a turbidez. No que diz respeito a essa relação, três abordagens principais podem ser utilizadas para as diversas plataformas disponíveis (órbita, aeroembarcadas, campo ou laboratório): abordagem empírica, semi-analítica e analítica (Novoa *et al.*, 2017).

A turbidez da água é umas das variáveis ópticamente ativas que apresenta maior dificuldade de obtenção. Em virtude desta dificuldade são empregados diferentes métodos e unidades de medida com o propósito de padronização para facilitar suas comparações (Quang *et al.*, 2017; Barbosa; Novo; Martins, 2019).

Porém, predições quantitativas de turbidez e outras variáveis relacionadas à transparência da água têm sido realizadas com sucesso utilizando satélites espaciais, em reservatórios, lagos e oceano e validadas contra medições *in situ* (Kim *et al.*, 2017; Chu *et al.*, 2018; Kupssinskü *et al.*, 2020; Souza *et al.*, 2023).

A análise de regressão com algoritmos de banda única ou multibanda é um método amplamente utilizado para avaliar a correlação entre a reflectância espectral e medições de

turbidez *in situ* (Al-Fahdawi *et al.*, 2015; Hossain *et al.*, 2021). Resultados promissores foram obtidos ao combinar as bandas de verde e vermelho (Avdan *et al.*, 2019) e ao adotar as faixas do red-edge em 705 nm e 714 nm (Sabat-Tomala *et al.*, 2018).

Pizani *et al.* (2022) compararam o desempenho dos sensores Sentinel-2 MSI e Landsat-8 OLI na criação de modelos de regressão múltipla, para criação do modelo foram utilizados parâmetros opticamente ativos (turbidez). Os modelos de regressão múltipla utilizaram as bandas de reflectância espectral de ambos os sensores (separadamente) como preditores.

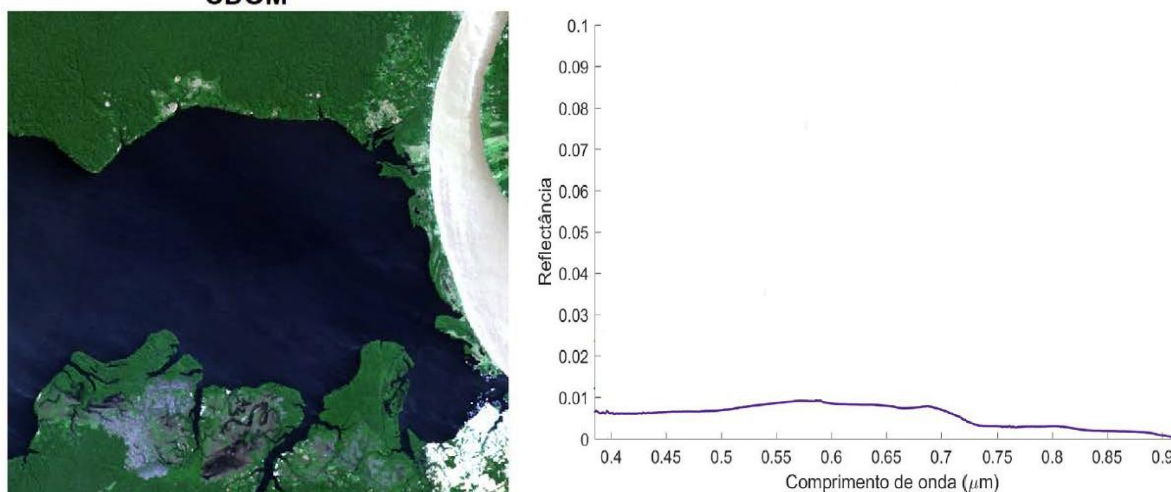
Outros métodos também encontraram potencial para prever turbidez em corpos hídricos: programação da expressão gênica (GEP) (Liu *et al.*, 2019), aprendizados de máquinas (Dias *et al.*, 2021) e regressão linear múltipla (MLR) (CHU *et al.*, 2018). Esses métodos são simples, eficientes e baratos para prever parâmetros de qualidade da água com cobertura espacial quase contínua.

3.5.4 Matéria orgânica dissolvida colorida

A matéria orgânica dissolvida colorida - CDOM é constituída por substâncias orgânicas solúveis, como ácidos húmicos e fúlvicos, que causam alterações na coloração da água. Essas substâncias resultam em tons que variam do amarelo ao marrom escuro. A quantidade e composição da CDOM têm um papel significativo nos processos fotoquímicos da água e na disseminação da luz sob a superfície. Além disso, a CDOM atua como uma fonte de nutrientes para as plantas aquáticas, originados dos compostos gerados pela biodegradação da matéria orgânica (Toming *et al.*, 2016; Barbosa; Novo; Martins, 2019).

Estas substâncias em águas naturais ocasionam forte redução da reflectância e aumento exponencial da absorção da luz em direção aos comprimentos de ondas mais longos. Assim, o aumento na concentração de substâncias orgânicas dissolvidas na água reduz significativamente a reflectância na região azul do espectro eletromagnético, que por sua vez, pode alterar as propriedades térmicas e químicas do sistema aquático (Brezonik *et al.*, 2015; Astuti *et al.*, 2018). Desta forma, o coeficiente de absorção da CDOM pode ser um indicador para estimar o carbono orgânico dissolvido em sistemas aquáticos naturais (Li *et al.*, 2022). Os corpos d'água interiores têm altos valores de correlação ao avaliar o CDOM via sensoriamento remoto, tal como pode ser visualizado na Figura 5.

Figura 5 - Espectros da água sob dominância de CDOM.



Fonte: Barbosa, Novo e Martins (2019).

Estimar a concentração de CDOM em estudos torna-se um desafio, devido às suas propriedades ópticas semelhantes às substâncias orgânicas não vivas e aos organismos fitoplanctônicos presentes no meio (Uudeberg *et al.*, 2020). A cor da água é outra variável óptica ativa que compartilha características espectrais semelhantes às da CDOM, o que resulta em uma forte relação entre elas (Philipson *et al.*, 2016; Toming *et al.*, 2016). Para enfrentar essa complexidade, muitos algoritmos se apoiam em regressões empíricas que usam a reflectância em comprimentos de onda acima de 500 nm (ZHU *et al.*, 2014).

Dörnhöfer *et al.* (2016) comparam o desempenho de diferentes softwares de correções atmosféricas em água rasas e profundas. Como o objetivo de estudar um algoritmo semiempírico de inversão, com a capacidade em recuperar a absorção por matéria orgânica dissolvida colorida (aCDOM). Demonstrando um grande potencial para a quantificação da concentração de CDOM, usando o comprimento de onda de 440 nm. No estudo de Philipson *et al.* (2016), também foram apresentados resultados promissores na faixa de 440 nm ao utilizarem sensores MERIS e Aqua/MODIS para a quantificação e detecção de CDOM.

A baixa resolução espacial impõe restrições ao monitoramento de lagos e reservatórios de pequeno porte. Portanto, uma parte significativa das pesquisas científicas tem recorrido a imagens de alta resolução espacial para estimar a concentração de CDOM, fazendo uso de produtos dos sensores REIS/RapidEye (Coelho *et al.*, 2017), e MSI/Sentinel-2 (Dörnhöfer *et al.*, 2016). OLI/Landsat-8 (Kutser *et al.*, 2016).

Outra técnica que pode ser empregada para a melhoria das imagens é a correção atmosférica, que visa reduzir os efeitos causados por vapor d' água, nuvens e aerossóis. Essa etapa é especialmente importante para o Sentinel-2, que possui baixa razão sinal-ruído em

ambientes aquáticos (Vanhellemont; Ruddick, 2016). A correção busca separar a refletância do topo da atmosfera (TOA) da refletância de fundo da atmosfera (BOA), tornando os dados mais confiáveis para aplicações hidrológicas (Vanhellemont; Ruddick, 2015; Vanhellemont, 2019).

3.6 CORREÇÃO ATMOSFÉRICA

Para a avaliação da qualidade da água por meio de imagens coletadas por diferentes sensores, estas devem passar por pré-processamento para obtenção de dados de maior correção entre a imagem coletada e a qualidade da água *in loco*.

As técnicas convencionais de pré-processamento utilizadas em relação a uma imagem digital bruta, obtida por sensores de satélites, englobam os processos de correções radiométricas, atmosféricas e geométricas (Feng *et al.*, 2022). Nesse sentido, a correção atmosférica é necessária pois, devido à presença de vapor d'água, nuvens e outros constituintes atmosféricos, os valores de reflectância estão sujeitos a interferências atmosféricas como absorção, espalhamento, emissão e reflexão (Barbosa; Novo; Martins, 2019; Nazeer *et al.*, 2021).

A correção atmosférica tem como propósito primordial restaurar as imagens adquiridas, buscando eliminar os efeitos decorrentes de ruídos originados pela interferência atmosférica, bem como superar as restrições impostas pelos sistemas de satélites e pela curvatura do planeta (Liu, 2007; Pahlevan *et al.*, 2021).

Imagens de satélite que abrangem as regiões do visível e infravermelho exibem brilho relacionado à reflectância e aos efeitos atmosféricos, demandando correção para garantir dados quantitativos precisos. Moléculas atmosféricas e aerossóis absorvem e dispersam radiações solar e refletida, impactando cerca de 90% do sinal capturado pelo sensor, processo conhecido como atenuação atmosférica (Abdelmalik, 2018; Ansper; Alikas, 2019).

Essas interferências nos dados podem resultar na perda de nitidez e brilho nas imagens. Para obter valores precisos de reflectância superficial dos alvos, é essencial conduzir a correção atmosférica. A correta realização da correção atmosférica proporcionará a obtenção de valores de refletância de superfície ou de refletância de sensoriamento remoto consistentes, sendo isto um pré-requisito essencial para a quantificação de propriedades biogeoquímicas a partir da refletância de superfície (Pahlevan *et al.*, 2021).

Diversos modelos e softwares são difundidos na literatura para a realização da correção atmosférica. C2RCC (Brockmann; Doerffer, 2016), Polymer (Steinmetz *et al.*, 2011), Sen2Cor (Warren *et al.*, 2019), Acolite (Vanhellemont; Ruddick, 2016), iCOR (Keukelaere *et al.*, 2018)

e L2GEN (Pahlevan *et al.*, 2017). Estes modelos podem ser divididos em image-based, em que a correção é aplicada com dados extraídos da própria imagem (Vanhellemont; Ruddick, 2015). No entanto, existem modelos que empregam a combinação dessas duas classes, sendo chamados de modelos híbridos (Gaida *et al.*, 2020). Dentre os algoritmos de correção atmosférica, o Sen2Cor, classificado como híbrido, está disponível no software SNAP (*Sentinel Application Platform*) (Warren *et al.*, 2019).

O algoritmo Sen2Cor é desenvolvido para processar imagens dos sensores MSI nos satélites Sentinel-2. Utilizando dados de reflectância aparente dos alvos e informações dos metadados, ele converte as reflectâncias da atmosfera em reflectâncias de superfície (Gaida *et al.*, 2020).

O algoritmo ACOLITE, destinado à correção atmosférica, foi desenvolvido para imagens OLI/Landsat 8 e MSI/Sentinel 2, focando em estudos de corpos d'água oceânicos e interiores (Vanhellemont; Ruddick, 2016). Esse algoritmo elimina os efeitos de dispersão de componentes moleculares e aerossóis sobre águas claras e turvas (Vanhellemont, 2019). O ACOLITE permite que o usuário escolha várias entradas para a correção atmosférica, incluindo: (i) cálculo e ajuste em nível de pixel; (ii) fatores de ganho para calibração radiométrica; (iii) pressão atmosférica; (iv) janela aplicada aos valores de refletância do aerossol; e (v) limite de máscara de nuvem (Vanhellemont, 2015; Franz *et al.*, 2014; Vanhellemont, 2019).

Estudos como o de Vanhellemont e Ruddick (2015) corroboram essa abordagem, ao desenvolverem o algoritmo de correção atmosférica “Dark Spectrum Fitting” (DSF), implementado no software ACOLITE. Esse método utiliza bandas SWIR, como 1609 nm e 2202 nm, partindo do princípio de que a contribuição espectral da água nessas bandas é praticamente nula, o que permite estimar com precisão a refletância dos aerossóis e extrapolá-la para o domínio visível. Tal estratégia melhora significativamente a acurácia da correção atmosférica em águas interiores e costeiras turvas, o que demonstra a relevância do uso dessas faixas espectrais em ambientes com elevada carga de sólidos em suspensão ou dissolvidos.

Pan *et al.* (2022) avaliaram dez algoritmos de correção atmosférica, entre eles o ACOLITE-DSF, C2RCC e Sen2Cor, utilizando dados de alta resolução nos lagos no Canadá. Os resultados indicaram que o ACOLITE-DSF se destacou na preservação da forma espectral da refletância, enquanto algoritmos baseados em redes neurais, como o C2RCC, apresentaram os menores erros absolutos e vieses por banda, evidenciando vantagens distintas entre os métodos.

Liu *et al.* (2024) compararam os algoritmos ACOLITE-DSF, ACOLITE-EXP, FLAASH, QUAC, 6S e Sen2Cor utilizando imagens dos satélites Landsat 8 e Sentinel-2 sobre

o Lago Ebinur. O ACOLITE-DSF apresentou os resultados mais consistentes e precisos, com coeficientes de determinação (R^2) acima de 0,73. Além disso, destacou-se pela boa compatibilidade entre sensores diferentes, sendo indicado como a melhor opção para estudos ambientais com séries temporais.

3.7 MODELAGEM MATEMÁTICA DA QUALIDADE DE ÁGUAS SUPERFICIAIS

O planejamento e gerenciamento dos recursos hídricos são cruciais para prevenir potenciais cenários de degradação ambiental. Nesse contexto, o uso de modelos matemáticos é uma abordagem para evitar os impactos que causam poluição e avaliar intervenções e medidas de controle necessárias, esses modelos têm o objetivo de descrever as variações espaciais e temporais das concentrações dos componentes da água (Silva *et al.*, 2017).

Modelos matemáticos simplificam a representação da qualidade da água e, combinados com o sensoriamento remoto, são eficazes, para a gestão ambiental na simulação e prevenção da poluição aquática (Wang *et al.*, 2013; Sagan *et al.*, 2020). O uso de imagens de satélite economiza recursos ao reduzir experimentos laboratoriais. Esses modelos melhoram a detecção em tempo real de mudanças hidrológicas, permitindo alertas e respostas rápidas a eventos prejudiciais (Dube *et al.*, 2015; Chawla; Karthikeyan; Mishra, 2020).

A construção de modelos ambientais enfrenta o desafio de representar com precisão a complexidade das interações nos sistemas ambientais, algumas das quais não podem ser facilmente quantificadas. Não há um único modelo matemático que possa se aplicar a diversos contextos, uma vez que a formulação de um modelo específico requer a consideração das características únicas de cada sistema, incluindo interações, conflitos, metas, dados e recursos disponíveis (Uddin; Nash; Olbert, 2021; Talukda *et al.*, 2023).

Modelos matemáticos para avaliar a qualidade da água via sensoriamento remoto são construídos com base na relação entre variáveis de qualidade da água e respostas ópticas do ambiente aquático. Eles usam imagens de sensores para estimar indicadores, sendo validados pela comparação com concentrações medidas *in loco* ou obtidas em laboratório (Barbosa; Novo; Martins, 2019).

Análises de regressão linear múltipla em sensoriamento remoto correlacionam valores de parâmetros coletados no local (variável dependente) com médias espectrais de bandas em janelas definidas (variável independente). Algoritmos empíricos e técnicas de regressão estatística combinados geram resultados confiáveis, especialmente em áreas específicas de estudo (Cao *et al.*, 2023b).

As abordagens empíricas costumam ser aplicáveis apenas ao conjunto de dados específico (imagem e dados *in situ*) a partir do qual as relações estatísticas foram estabelecidas. Portanto, a abordagem empírica se fundamenta na correlação estatística entre os dados ópticos e as concentrações das variáveis de interesse. É importante notar que, dependendo do modelo estatístico desenvolvido, essa abordagem pode resultar em conclusões incorretas, uma vez que uma correlação estatística não implica necessariamente uma relação causal (Matthews, 2011; Barbosa; Novo; Martins, 2019).

3.8 APRENDIZADO DE MÁQUINA

A Inteligência Artificial (AI) engloba campos como o Aprendizado de Máquina (*Machine Learning - ML*) e o Aprendizado Profundo de Máquinas (*Deep Learning*). O ML, um subcampo da AI, surgiu na segunda metade do século XX, unindo conceitos da neurociência, estatística e matemática para permitir que computadores aprendam e aprimorem algoritmos de autoaprendizagem. Essas técnicas identificam padrões nos dados, preveem eventos futuros e auxiliam na tomada de decisões, sendo cruciais para classificações, regressões e previsões (Borges *et al.*, 2021; Choi *et al.*, 2020).

O Aprendizado de Máquina pode ser dividido em três tipos principais: Aprendizado Supervisionado, Aprendizado Não Supervisionado e Aprendizado por Reforço (Neto *et al.*, 2021). O Aprendizado Supervisionado é comumente utilizado quando há resultados associados aos dados, enquanto o Aprendizado Não Supervisionado é preferido quando os dados não têm rótulos. Além disso, o Aprendizado Profundo de Máquinas é uma subcategoria do Aprendizado de Máquina que frequentemente requer grandes volumes de dados devido à complexidade dos problemas abordados, como visão computacional e reconhecimento de voz (Choi *et al.*, 2020; Meyer *et al.*, 2018).

Alguns modelos de AM, mais especificamente de aprendizado supervisionado, serão utilizados neste estudo e, portanto, descritos nas seções subsequentes. São eles: Regressão Linear e *Random Forest Support Vector Machine (SVM) e Decision Tree*.

3.8.1 Regressão Linear

Uma análise estatística fundamental para a criação de modelos empíricos a fim de estimar dados limnológicos é a regressão linear. Essa técnica avalia a relação e a variação entre

as variáveis por meio de uma função linear representada por $y = a + bx$, em que x é a variável independente e y é a variável dependente (Callegari-Jacques, 2003).

O algoritmo de regressão linear é uma técnica estatística amplamente utilizada no campo do aprendizado de máquina para identificar padrões. Ele aborda o relacionamento entre uma variável de resposta (também conhecida como variável dependente) e várias variáveis independentes (conhecidas como preditores). Essencialmente, o algoritmo modela a variável de resposta como uma função linear das variáveis independentes, capturando como todas essas variáveis independentes contribuem para prever a variável de resposta (Olive, 2017; Engchuan *et al.*, 2019).

Nesse sentido, as análises de regressão linear são classificadas em dois tipos: regressão linear simples e regressão linear multivariada. No modelo de regressão linear simples, examina-se uma única variável preditora em relação à variável de resposta. Por outro lado, no modelo de regressão linear multivariada, lidamos com várias variáveis predictoras simultaneamente para compreender relações mais complexas entre as variáveis. Isso nos permite explorar interações entre múltiplos fatores que podem influenciar a variável de resposta (Murphy, 2013).

Cao *et al.* (2023b) relatam que diferentes pesquisadores obtiveram modelos estatísticos, como regressão linear, regressão polinomial e análise de componentes principais, para estimar diversas variáveis de qualidade da água, como matéria orgânica dissolvida colorida, demanda química de oxigênio (DQO) e pH. Esses modelos foram desenvolvidos com base em múltiplas fontes de dados de sensoriamento remoto, incluindo Landsat, GF-1 e MODIS, utilizando proporções e combinações distintas de bandas espectrais. Os modelos apresentaram bom desempenho, com coeficientes de determinação (R^2) superiores a 0,66. Atualmente, muitos pesquisadores têm adotado abordagens que combinam métodos empíricos e semiempíricos, alcançando resultados promissores em aplicações práticas.

3.8.2 Random Forest

O algoritmo *Random Forest*, foi desenvolvido por Breiman (2001), e se destaca por sua natureza não paramétrica e não linear. Ele combina as características das árvores de classificação e regressão, e adiciona um nível extra de aleatorização no processo de agregação de inicialização (*bootstrap*), denominado *bagging*. Isso confere ao algoritmo maior robustez e poder de generalização ao lidar com uma ampla gama de problemas complexos (Tyralis *et al.*, 2019; Sun *et al.*, 2022).

Cada árvore que faz parte de uma floresta aleatória é construída usando um conjunto de amostras selecionadas aleatoriamente a partir do conjunto original (por meio do método de *bootstrap*). No contexto de problemas de regressão, as previsões produzidas por esse algoritmo são calculadas ao fazer a média das previsões individuais de cada árvore na floresta (etapa de agregação) (Ferreira *et al.*, 2021).

Por meio da aplicação da técnica de *bootstrap* para randomização, o algoritmo reduz a correlação entre as árvores. Como resultado, ao calcular a média das previsões provenientes das várias árvores, o algoritmo *Random Forest* consegue diminuir a variância das previsões. Isso contribui para um aumento na estabilidade e confiabilidade das estimativas geradas pelo modelo (Tyrallis *et al.*, 2019).

Wang *et al.* (2021) aplicaram o algoritmo *Random Forest* para modelar três variáveis de qualidade da água (matéria orgânica, fósforo e nitrogênio) em uma bacia hidrográfica e evidenciaram que o algoritmo pode ser usado para prever a qualidade da água para compensar a falta de estações físicas de monitoramento em algumas áreas.

Sun *et al.* (2022) avaliaram o desempenho de três algoritmos de aprendizado de máquina (incluindo redes neurais de retropropagação, regressão por processo gaussiano e regressão por *Random Forest*), além de algoritmos empíricos, para a estimativa das concentrações de nitrogênio, fósforo e matéria orgânica. O objetivo era identificar o algoritmo mais adequado para recuperar parâmetros de qualidade da água não opticamente ativos. Os resultados indicaram que o algoritmo *Random Forest* se destacou entre os demais, apresentando bons ajustes entre os dados e as imagens coletadas.

3.8.3 Árvore de Decisão *Decision Tree*

O algoritmo de árvore de decisão é uma técnica de aprendizado supervisionado utilizada para tarefas de classificação e regressão. Ele opera particionando o espaço de atributos em regiões homogêneas com relação à variável alvo, organizando essas divisões em uma estrutura hierárquica semelhante a um fluxograma. Cada nó interno representa uma decisão baseada em um atributo, e cada nó terminal (folha) representa um resultado ou classe (GeeksforGeeks, 2024).

A construção da árvore ocorre de forma recursiva, selecionando a cada etapa o atributo que melhor divide os dados, com base em critérios como ganho de informação, impureza de Gini ou índice de entropia. Esse processo, conhecido como particionamento recursivo, continua

até que se atinja um critério de parada, como a pureza dos nós ou a profundidade máxima da árvore (GeeksforGeeks, 2024).

Em aplicações ambientais, particularmente no sensoriamento remoto, os algoritmos de *Decision Tree* têm sido amplamente utilizados pela sua capacidade de lidar com variáveis espectrais altamente correlacionadas e pela facilidade de interpretação dos modelos gerados (Gorgan-Mohammadi *et al.*, 2023; Li *et al.*, 2020b).

Gorgan-Mohammadi *et al.* (2022) utilizaram modelos de *Decision Tree*, incluindo CART, CHAID, QUEST e C5, para prever parâmetros de qualidade da água, como oxigênio dissolvido e fósforo, no Lago Erie. Os resultados demonstraram que o modelo *Decision Tree* apresentou boa precisão, com diferenças mínimas entre os valores observados e previstos, destacando sua eficácia na classificação e previsão de parâmetros hidroquímicos com alta acurácia e em curto tempo.

Além disso, Li *et al.* (2020b) aplicaram árvores de decisão para classificar corpos d'água urbanos com base em características ópticas, identificando diferentes tipos de água, incluindo águas negras e malcheirosas. O modelo alcançou uma acurácia geral de 80%, demonstrando a aplicabilidade das árvores de decisão na classificação de qualidade da água em ambientes urbanos

3.8.4 Máquinas de Vetores de Suporte Support Vector Machine (SVM)

O algoritmo *Support Vector Machine* (SVM) é uma técnica de aprendizado supervisionado utilizada para resolver problemas de classificação e regressão. O funcionamento do SVM se baseia na busca por um hiperplano que separe os dados da melhor forma possível, maximizando a margem entre as classes. Esse princípio está relacionado à Teoria do Aprendizado Estatístico, proposta por Vapnik e Chervonenkis, que introduziu conceitos como a margem máxima e a dimensão (Vapnik, 1995).

Uma das principais vantagens do SVM é sua eficiência em espaços de alta dimensionalidade, mesmo quando o número de amostras é menor que o número de variáveis, o que é comum em dados espectrais. Além disso, o SVM baseia suas decisões apenas em um subconjunto dos dados de treinamento, os chamados vetores de suporte, o que o torna eficiente do ponto de vista computacional e robusto a ruídos (Scikit-learn, 2024).

No contexto prático, Yao *et al.* (2024) demonstraram a aplicação eficaz do SVM, otimizado por algoritmos inteligentes, na previsão de parâmetros de qualidade da água em corpos hídricos de pequeno porte. Utilizando dados multiespectrais captados por veículos

aéreos não tripulados (UAVs), o modelo alcançou alta precisão (R^2 de 0,915), comprovando sua robustez mesmo em cenários com baixa disponibilidade amostral.

Riaz *et al.* (2024) combinaram o algoritmo SVM com a técnica Weight of Evidence (WOE) para mapear o potencial aquífero e avaliar a qualidade da água subterrânea. O modelo obteve desempenho consistente mesmo em cenários com múltiplas variáveis ambientais, demonstrando a capacidade do SVM de lidar com sistemas hidrológicos complexos no contexto do sensoriamento remoto. Os resultados mostraram que apenas 20,3% da área analisada foi classificada como de excelente potencial aquífero, evidenciando a precisão do modelo na identificação de zonas mais favoráveis à exploração de recursos hídricos.

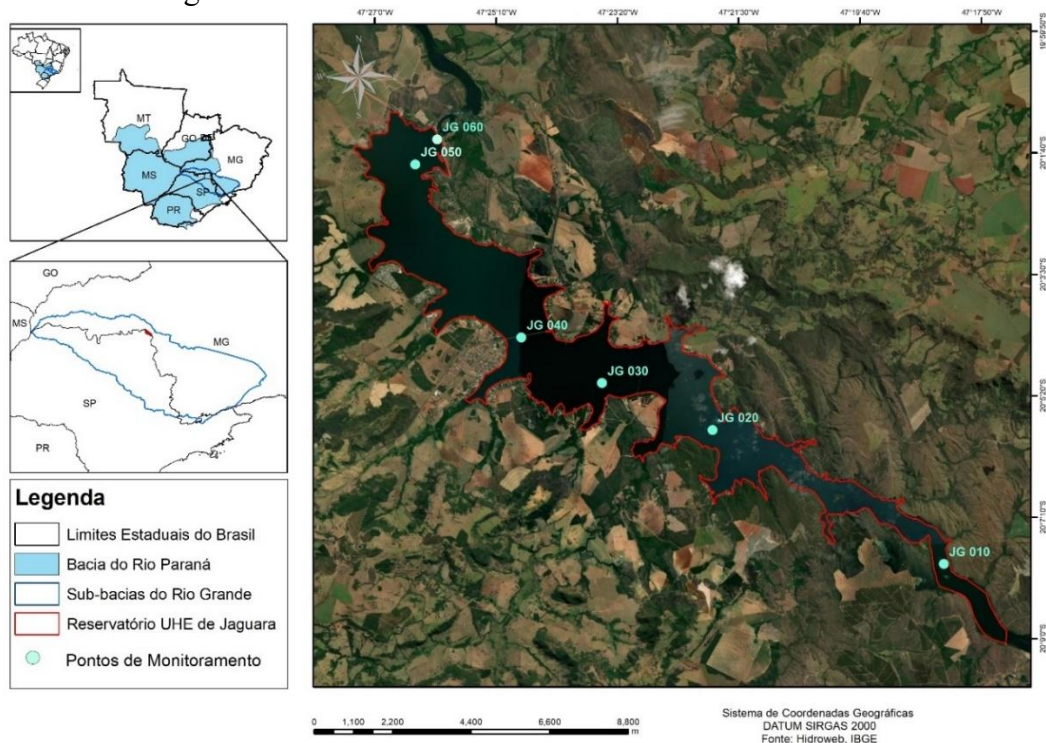
4 MATERIAL E MÉTODOS

4.1 ÁREA DO ESTUDO

A UHE Jaguara é uma usina de energia localizada na bacia hidrográfica do rio Grande, que faz parte da bacia hidrográfica do rio Paraná. Ela entrou em operação em 1971 e tem uma capacidade instalada de 424 megawatts (MW). A usina é composta por quatro unidades geradoras, cada uma equipada com uma turbina vertical do tipo Francis, com capacidade de 106 MW cada (ENGIE Brasil Energia, 2023). A UHE Jaguara está localizada na latitude 20° 01' 05'' sul e longitude 47° 25' 05'' oeste, entre as represas da UHE Estreito (a montante) e da UHE Igarapava (a jusante).

Na área onde está localizado o reservatório da UHE Jaguara, o rio Grande faz a divisa entre os estados de Minas Gerais e São Paulo, marcando a fronteira entre os dois estados na região do Triângulo Mineiro. Sendo o primeiro representado pelo município de Sacramento, que dista cerca de 25 km ao sul do eixo do barramento e o segundo pelos municípios de Rifaina e Pedregulho, que distam respectivamente 7 e 25 km, ao norte do eixo do barramento (Figura 6).

Figura 6 – Área de estudo – lago da usina hidrelétrica Jaguara - e posições dos locais de amostragem.



Fonte: Do Autor (2025).

A Usina Hidrelétrica Jaguara tem um reservatório a fio d'água com área de 34,6 km², perímetro total de 98,4 km, largura média de 1,5 km e extensão aproximada de 23 km, desde o barramento principal até a barragem a montante. A cota máxima normal e a cota *maximorum* são coincidentes, situada a 558,5 metros acima do nível do mar (ENGIE Brasil Energia, 2023). O reservatório hidrelétrico de Jaguara é utilizado não só para a produção de energia, mas também para recreação, turismo, pesca e aquicultura.

O bioma da área de estudo apresenta as componentes do Cerrado e da Mata Atlântica visto que a Usina Hidrelétrica está situada numa zona de transição ecológica entre os dois biomas. As fitofisionomias presentes são floresta estacional semidecidual, campos sujos, vegetação em estágio secundário de regeneração, veredas e matas ciliares (Carvalho; Scolforo, 2008). As classes de solos predominantes na área de estudo são Latossolos e Neossolo (IDE-SISEMA, 2023).

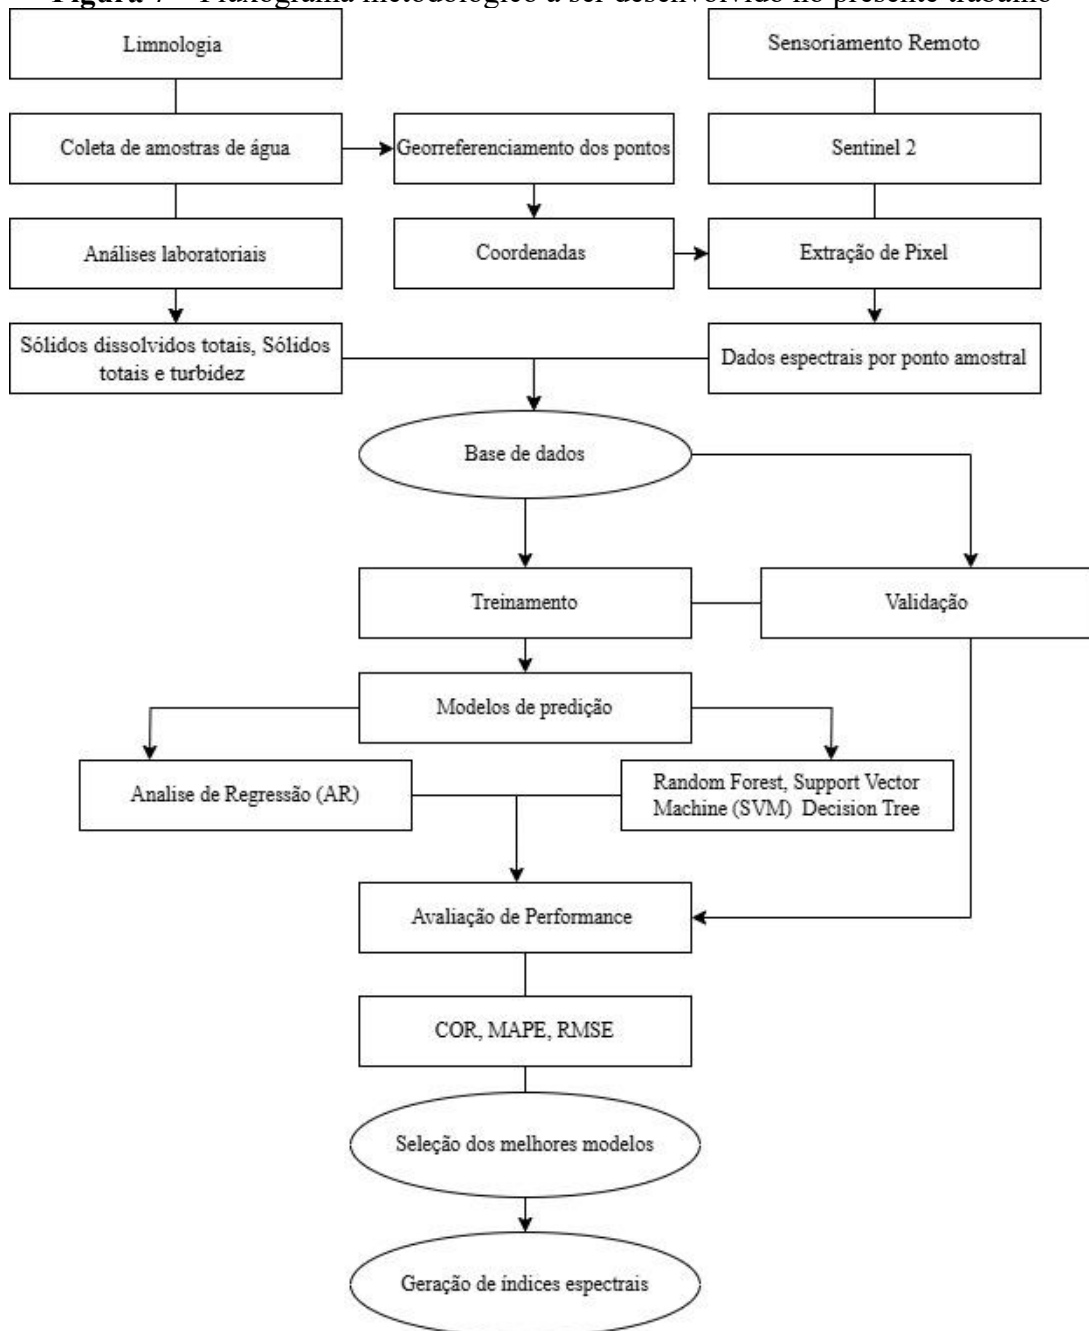
A principal utilização e cobertura da terra na bacia hidrográfica que alimenta o reservatório da Usina Hidrelétrica de Jaguara incluem pastagens para gado, áreas com Formação Florestal, Área Urbanizada e áreas destinadas a culturas anuais (MapBiomas, 2023).

Conforme a classificação climática de Köppen-Geiger, a área de estudo apresenta clima tropical de savana (Aw), caracterizado por temperaturas elevadas e alta umidade, com estação seca no inverno e chuvosa no verão. A temperatura média anual varia entre 19 °C e 23 °C.

4.2 Etapas Metodológicas

Este tópico apresenta uma visão geral da metodologia desenvolvida neste estudo, ilustrada na Figura 7. As etapas chave do processo estão detalhadas nas seções seguintes. Destacam-se os modelos desenvolvidos para prever três variáveis de qualidade de água: sólidos dissolvidos totais, sólidos totais, e turbidez.

Figura 7 – Fluxograma metodológico a ser desenvolvido no presente trabalho



Fonte: Do Autor (2025).

A metodologia do presente estudo foi dividida em quatro etapas principais:

1) **Aquisição de Dados Brutos:** nesta etapa, foram adquiridas as imagens do satélite Sentinel-2/MSI e os dados das 21 campanhas de campo de qualidade de água realizadas entre 2018 e 2023, no lago da Usina Hidrelétrica (UHE) Jaguará.

2) **Processamento e organização da base de dados:** utilizaram-se imagens de satélite, das quais foram extraídos os valores dos pixels nos pontos amostrados. As análises laboratoriais da água foram realizadas concomitantemente, e todos os dados foram organizados em uma planilha Excel para posterior análise e modelagem.

3) Geração de algoritmos para o cálculo das estimativas: nesta etapa, conduziu-se uma análise exploratória dos modelos ópticos destinados à sólidos dissolvidos totais, sólidos totais e turbidez. A validação dos modelos foi realizada por meio de campanhas, visando obter o ajuste mais preciso para a etapa subsequente.

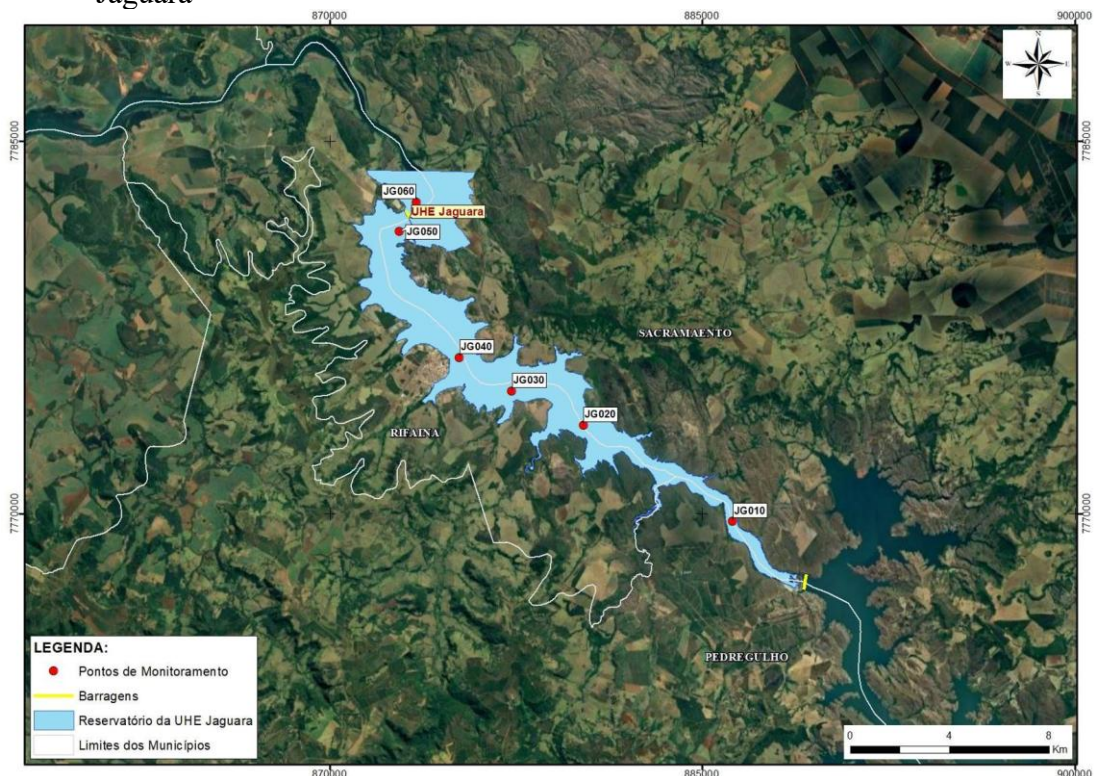
4) Estimativa da qualidade da água a partir de imagens: os modelos propostos foram calibrados e validados. Em seguida, foram aplicados às imagens dos dias de campanha, permitindo a estimativa dos valores das variáveis de qualidade da água do reservatório da UHE Jaguara.

Esta metodologia permitiu a análise e estimativa da qualidade da água com base em dados de sensoriamento remoto e medições de campo ao longo do tempo.

4.3 AQUISIÇÃO DE DADOS LIMNOLÓGICOS

Os dados de monitoramento utilizados no presente trabalho foram fornecidos pela Engie Brasil Energia empresa operadora da UHE Jaguara. A Figura 8 demonstra a área de estudo e os locais de amostragem.

Figura 8 – Pontos de coleta de amostras de água para avaliação da qualidade no lago da UHE Jaguara



Fonte: Do Autor (2025).

As amostras das águas superficiais do reservatório foram analisadas de acordo com o *Standard methods for the examination of water and wastewater* (APHA, 2017). Os dados de Sólidos Dissolvidos totais (Método 2540 D), sólidos totais (método 2540B) e turbidez (método 2130B) foram coletados em 21 campanhas de campo realizadas em campanhas trimestrais de dezembro de 2018 a dezembro de 2023, com amostragem de seis pontos em cada, totalizando 126 amostras.

As técnicas de coleta, preservação, transporte e análise atenderam ao estabelecido pelo Guia Nacional de Coleta e Preservação de Amostras da Agência Nacional de Águas e Saneamento Básico (CETESB, 2011; APHA, 2017).

Os resultados das análises de sólidos dissolvidos totais, sólidos totais e turbidez foram separados por data e organizados em uma planilha contendo coordenadas geográficas (latitude e longitude) no sistema de referência SIRGAS 2000. Na Tabela 1, está demonstrada a nomenclatura dos locais de amostragem.

Tabela 1 - Estações de Monitoramento de qualidade de água do reservatório da usina hidrelétrica de Jaguará.

Localização	Pontos	Coordenadas Geográficas	
	Nomenclatura	Latitude	Longitude
Município de Pedregulho, Rio Grande, reservatório,	JG010	20° 7'52.67"S	47°18'24.02"O
Município de Rifaina, Rio Grande, reservatório a montante do sistema de tanques-rede, trecho lântico	JG020	20° 5'51.22"S	47°21'53.76"O
Município de Rifaina, Rio Grande, reservatório a montante do sistema de tanques-rede	JG030	20° 5'8.74"S	47°23'33.95"O
Município de Rifaina, Rio Grande, reservatório, porção média,	JG040	20° 4'27.15"S	47°24'46.97"O
Município de Rifaina, Rio Grande, reservatório próximo à barragem	JG050	20° 1'43.41"S	47°26'13.59"O
Município de Rifaina, Rio Grande, reservatório próximo à barragem,	JG060	20° 1'23.52"S	47°26'6.36"O

Fonte: Adaptado de Engie Brasil Energia (2025).

4.4 CÁLCULO DO IQA – ÍNDICE DE QUALIDADE DAS ÁGUAS

A partir dos resultados das análises das variáveis de qualidade de água, foi efetuado o cálculo do IQA (Índice de Qualidade das Águas). Este índice baseia-se no resultado de nove variáveis: oxigênio dissolvido, coliformes termotolerantes, pH, DBO, nitrato, fosfato total, temperatura da água, turbidez e sólidos totais. De acordo com a metodologia elaborada pelo IGAM (2014), cada um desses parâmetros possui um peso durante o cálculo do IQA, conforme pode ser observado na Tabela 2.

Tabela 2 - Pesos atribuídos a cada um dos parâmetros utilizados no cálculo do IQA das amostras de água coletadas.

Parâmetro	Peso (wi)
Oxigênio dissolvido	0,17
Coliformes termotolerantes	0,15
pH	0,12
DBO	0,10
Nitratos	0,10
Fosfatos	0,10
Temperatura	0,10
Turbidez	0,08
Sólidos totais	0,08

Fonte: IGAM, (2014).

Com base nos pesos atribuídos e nos resultados das análises físico-químicas, o IQA foi calculado por meio do produtório ponderado dos valores de qualidade da água correspondentes a cada parâmetro, conforme apresentado na Equação 1:

$$IQA = \prod_{i=1}^n q_i^{w_i} \quad (1)$$

em que:

IQA – índice de qualidade da água, um número de 0 a 100;

q_i = qualidade do parâmetro i obtido através da curva média específica de qualidade, que é calculada através de equação própria, para cada um dos parâmetros;

w_i = peso atribuído ao parâmetro, em função de sua importância na qualidade, entre 0 e 1.

Os valores do índice variam entre 0 e 100, sendo atribuídas diferentes classificações de qualidade da água em função da faixa de IQA obtida (Tabela 3).

Tabela 3: Limites do índice de qualidade da água (IQA).

IQA	
ÓTIMA	80 - 100
BOA	52 - 79
ACEITÁVEL	37 - 51
RUIM	20 - 36
PÉSSIMA	0 - 19

Fonte: IGAM (2014).

4.5 AQUISIÇÃO DOS DADOS DE SENSORIAMENTO REMOTO

Neste estudo, foram utilizadas as bandas espectrais com resolução espacial de 10 metros e 20 metros com comprimentos de onda variando de 490 a 2190 nm coletadas entre 2018 e 2023. As imagens foram provenientes dos satélites Sentinel 2 (S2A e S2B), lançados em 2015 e 2017 pela Agência Espacial Europeia (ESA), que são idênticos e compartilham a mesma órbita, estando separados por 180°. Esses satélites fornecem dados de forma contínua. O instrumento *Multispectral Imager* (MSI) do Sentinel-2 oferece 13 bandas espectrais, abrangendo os comprimentos de onda do visível, infravermelho próximo (NIR) e infravermelho de onda curta (SWIR). Quatro dessas bandas têm resolução de 10 m (com comprimentos de onda centrados em 490 nm, 560 nm, 665 nm e 842 nm), seis possuem resolução de 20 m (centradas em 705 nm, 740 nm, 783 nm, 865 nm, 1610 nm e 2190 nm), e três possuem resolução de 60 m (centradas em 443 nm, 940 nm e 1375 nm). Cada satélite revisita a mesma área a cada 10 dias, ou a cada 5 dias quando operam em conjunto (Du *et al.*, 2016).

O pré-processamento das imagens teve início com a seleção das imagens com baixa cobertura de nuvem e com aquisição o mais próximo possível do dia da coleta das amostras de água. A Tabela 4 apresenta as características das bandas espectrais presentes no sensor MSI.

Tabela 4 - Descrição das bandas espectrais do sensor MSI/Sentinel-2, cujas imagens foram utilizadas no presente trabalho.

Banda espectral	Centro da banda (nm)	Comprimento de onda (nm)	Largura da banda (nm)	Resolução espacial (m)
B1.Coastal	443	421 – 457	36	60
B2. Azul	494	439 – 535	96	10
B3. Verde	560	537 – 582	45	10
B4. Vermelho	665	646 – 685	39	10
B5.Vegetation Red-Edge	704	694 – 714	20	20
B6.Vegetation Red-Edge	740	731 – 749	18	20
B7 Vegetation. Red-Edge	781	768 – 796	28	20
B8. NIR	834	767 – 908	141	10
B8A. NIR	864	848 – 881	33	20
B9. Vapor d'água	944	931 – 958	27	60
B10. Cirrus	1375	1338 – 1414	76	60
B11. SWIR	1612	1539 – 1681	142	20
B12. SWIR	2194	2072 – 2312	240	20

Fonte: Do Autor (2025).

Tendo em vista que a cobertura de nuvens das imagens pode inviabilizar sua utilização, foram escolhidas imagens com pouca ou nenhuma cobertura de nuvens. Para isso, analisaram-

se os arquivos de qualidade dos pixels, que indicam se há interferência de nuvens ou aerossóis. Imagens com mais de 50% dos pixels afetados foram descartadas. Com a intenção de que as imagens Sentinel adquiridas representassem da melhor forma possível as condições da represa no momento da coleta de dados em campo, procurou-se estabelecer o menor intervalo possível entre a data da coleta e de passagem do satélite. Na Tabela 5 estão apresentadas as datas das imagens que foram utilizadas no presente trabalho.

Tabela 5 – Data das imagens do reservatório da Usina Hidrelétrica Jaguara obtidas por meio do satélite Sentinel.

Ano	Data da imagem	Data da amostragem da água	Satélite
2018	21/12/2018	16/12/2018	L1C_T22KHC_A009359_20181221T132228
	10/05/2019	08/05/2019	L1C_T23KKT_A011361_20190510T132241
2019	19/06/2019	19/06/2019	L1C_T22KHC_A011933_20190619T132240
	02/09/2019	03/09/2019	L1C_T22KHC_A021914_20190902T132233
	31/12/2019	30/12/2019	L1C_T22KHC_A023630_20191231T132228
	29/04/2020	28/04/2020	L1C_T22KHC_A025346_20200429T132236
2020	18/06/2020	16/06/2020	L1C_T22KHC_A026061_20200618T132239
	26/09/2020	23/09/2020	L1C_T22KHC_A027491_20200926T132723
	30/12/2020	28/12/2020	L1C_T22KHC_A019941_20201230T132524
	19/05/2021	19/05/2021	L1C_T22KHC_A021943_20210519T132703
2021	28/06/2021	28/06/2021	L1C_T22KHC_A022515_20210628T132234
	06/09/2021	06/06/2021	L1C_T22KHC_A023516_20210906T132521
	10/12/2021	09/12/2021	L1C_T22KHC_A033783_20211210T132232
	10/03/2022	09/03/2022	L1C_T22KHC_A035356_20220330T132336
2022	03/06/2022	02/06/2022	L1C_T23KKT_A027377_20220603T132232
	12/08/2022	11/08/2022	L1C_T23KKT_A028378_20220812T132236
	03/12/2022	12/12/2022	L1C_T22KHC_N0400_20221205T172046
	15/02/2023	18/02/2023	L1C_T23KKT_N0509_20230218T163847
2023	03/06/2023	01/06/2023	L1C_T23KKT_N0509_20230603T181848
	22/08/2023	31/08/2023	L2A_T23KKT_N0509_20230822T183200
	05/12/2023	05/12/2023	L1C_T23KKT_N0509_20231205T135318

Fonte: Do Autor (2025).

4.6 CORREÇÃO ATMOSFÉRICA

A seleção dos algoritmos de correção atmosférica baseou-se em vários critérios fundamentais. Primeiramente, considerou-se a disponibilidade gratuita desses algoritmos, o que pode contribuir para uma maior difusão do conhecimento. Além disso, priorizou-se a facilidade

de compreensão e implementação desses algoritmos, tornando o processo de correção mais acessível e eficaz. Outro aspecto relevante foi a capacidade dos algoritmos de lidar e corrigir efeitos indesejados, como o brilho do sol e a influência de pixels terrestres próximos à área de interesse.

As imagens obtidas foram processadas utilizando o *software* Acolite. O Acolite, processador de imagens desenvolvido pelo *Royal Belgian Institute of Natural Sciences* (RBINS), é programado em Python (ACOLITE, 2021).

Assim, as imagens foram submetidas ao processo de correção atmosférica no Acolite (Vanhellemont; Ruddick, 2016), para remover os efeitos de atenuação causados por constituintes atmosféricos ativos, como dispersão molecular e de aerossol e absorção por vapor de água, ozônio, oxigênio e dióxido de carbono. Esta metodologia é indicada para aplicação em águas continentais e interiores (Song *et al.*, 2020).

Dessa forma, foi possível reduzir a influência das condições atmosféricas presentes no momento de aquisição das cenas (Martins *et al.*, 2017). Por fim, realizou-se o recorte para o quadrante de interesse utilizando o pacote “*terra*” em linguagem R (HIJMANS *et al.*, 2024; R Core Team, 2020).

4.7 EXTRAÇÃO DOS VALORES DE REFLECTÂNCIA

Após a correção atmosférica, as imagens foram importadas para o software ArcMap 10.5, no qual se deu início ao processo de extração das reflectâncias. Os valores de reflectância espectral foram obtidos por meio da ferramenta de geoprocessamento “*Extract Multi-Values to Points*”, em que as coordenadas georreferenciadas de cada estação de amostragem foram utilizadas para extrair as reflectâncias (Hossain *et al.*, 2021). Essa ferramenta registra a reflectância espectral para cada banda em cada local de amostragem, armazenando os dados na tabela de atributos associada a cada classe de feição correspondente. Para fins de análise estatística, as tabelas de cada classe de recurso foram posteriormente convertidas em planilhas do Excel usando a ferramenta “Tabela para Excel”.

4.8 GERAÇÃO DE MODELOS DE PREDIÇÃO

Com o conjunto de dados obtido nas etapas anteriores, composto por variáveis de qualidade da água coletadas *in situ* e variáveis espectrais das imagens Sentinel, foram realizadas análises visando estabelecer modelos empíricos de predição para a área de estudo. Essas

análises consideraram diferentes combinações de bandas espectrais, incluindo bandas individuais, razões entre bandas e o conjunto completo de bandas. Conseqüentemente, foram aplicadas análises de regressão linear, polinomial e quadrática, além de modelos de aprendizado de máquina, como *Support Vector Machine (SVM)*, *Random Forest* e *Decision Tree*, permitindo avaliar a capacidade preditiva de cada abordagem.

Em ambas as abordagens, tanto na Análise de Regressão (AR) quanto nos modelos de aprendizagem, o conjunto de dados coletados foi dividido aleatoriamente, alocando 70% dos dados para a calibração dos modelos. Os 30% restantes foram reservados para a validação ou teste dos modelos. Essa estratégia permitiu avaliar se as previsões estão em conformidade com o esperado e se os modelos são capazes de estimar os compostos usando dados que não foram usados em sua fase de calibração.

Foram gerados gráficos para estimar a correlação entre as bandas e/ou combinações de bandas do Sentinel-2 MSI e os valores coletados *in situ*. Todas as análises estatísticas, incluindo regressões lineares e não lineares, bem como os modelos de aprendizado de máquina, foram realizadas utilizando os softwares RStudio (versão 1.5.5109), Python e seus respectivos pacotes. Além disso, o Microsoft Excel foi empregado como ferramenta de suporte para a organização e formatação dos dados.

4.8.1 Análise de Regressão

Para a análise de regressão, foram conduzidos treinamento e validação de modelos com o intuito de prever as variáveis de qualidade da água, empregando diversas combinações de variáveis espectrais. Foram avaliadas tanto bandas individuais quanto razões entre bandas, utilizando três abordagens de regressão: linear, polinomial e quadrática. Ainda nesse contexto, os modelos foram avaliados em dois cenários distintos: um com o conjunto completo de dados e outro com a remoção de outliers, permitindo a análise do impacto de valores atípicos na precisão das previsões.

As imagens de satélite (Sentinel) utilizadas contêm 11 bandas espectrais distintas. Assim, ao considerar as bandas individuais (11) e as razões entre bandas (100), obteve-se um total de 111 combinações de variáveis predictoras. Cada uma dessas combinações foi aplicada aos três modelos de regressão mencionados, resultando em 333 testes por conjunto de dados. Como os experimentos foram conduzidos com e sem a presença de outliers, o total de testes realizados foi de 666, garantindo uma análise abrangente da influência dos diferentes cenários na modelagem dos parâmetros de qualidade da água.

4.8.2 Aprendizado de máquina

Para o aprendizado de máquina, foram utilizadas diferentes combinações de variáveis espectrais. Foram testadas bandas espectrais individuais, razões entre bandas e o conjunto completo de bandas. Os modelos de aprendizado de máquina avaliados foram: *Support Vector Machine* (SVM), *Random Forest* e *Decision Tree*. Os modelos foram avaliados em dois cenários distintos: um com o conjunto completo de dados e outro com a remoção de *outliers*, permitindo analisar o impacto de valores atípicos na precisão das previsões.

As imagens de satélite (Sentinel) utilizadas contêm 11 bandas espectrais distintas. Assim, ao considerar as bandas individuais (11) e as razões entre bandas (100), e os conjuntos com todas as bandas (1) obteve-se um total de 112 combinações de variáveis preditoras. Cada uma dessas combinações foi aplicada aos três modelos de aprendizado de máquina mencionados, resultando em 336 testes por conjunto de dados. Como os experimentos foram conduzidos com e sem a presença de outliers, o total de testes realizados foi de 672, garantindo uma análise abrangente da influência dos diferentes cenários na modelagem dos parâmetros de qualidade da água.

4.9 AVALIAÇÃO DOS MODELOS DE PREDIÇÃO

A acurácia do algoritmo selecionado para a estimativa de sólidos dissolvidos totais, sólidos totais, e turbidez foi realizada por meio da comparação entre os valores preditos e os valores observados nas amostragens, utilizando as seguintes métricas estatísticas: coeficiente de correlação de Pearson (r), MAPE (Erro Percentual Absoluto Médio) e RMSE (raiz do erro médio quadrático), conforme Equações 2, 3 e 4.

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{[\sum_{i=1}^n (x_i - \bar{x})^2][\sum_{i=1}^n (y_i - \bar{y})^2]}} \quad (2)$$

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (3)$$

$$\text{RMSE} = \sqrt{\sum_{i=1}^n \frac{(y_i - \hat{y}_i)^2}{n}} \quad (4)$$

os termos na equação são definidos da seguinte forma:

N = número de amostras;

p = número de variáveis (ou dados de entrada do modelo);

\hat{y} = valor predito;

\bar{y} = valor médio das amostras; e

y = valor real.

Após a aplicação das métricas estatísticas, os modelos de regressão foram utilizados nas bandas dos satélites correspondentes por meio de álgebra de mapas, a fim de validar as respostas previstas com os dados amostrados *in situ*. A validação foi realizada para cada data de pesquisa, bem como para o conjunto de dados que continha todas as informações adquiridas.

4.10 MAPA DE ESTIMATIVAS

Para construir os mapas de estimativas de Sólidos dissolvidos totais, sólidos totais, e turbidez foram selecionados, dentre os modelos, o que apresentou o melhor desempenho na comparação dos valores preditos com os observados nas campanhas de campo.

A geração dos mapas representativos, contendo as estimativas de sólidos dissolvidos totais, sólidos totais e turbidez, foi realizada utilizando as ferramentas de software livre R, Python e ArcMap 10.5.

5 RESULTADOS E DISCUSSÃO

5.1 DADOS DE QUALIDADE E CÁLCULO DO IQA

Os dados apresentados nesta seção foram obtidos por meio de medições de diversas variáveis realizadas em campo, durante campanhas conduzidas e fornecidas pela ENGIE Brasil Energia. No total, foram coletadas 126 amostras de água no reservatório da UHE de Jaguará, realizadas em quatro campanhas anuais ao longo dos cinco anos analisados. Esses dados constituíram a base para a análise da qualidade da água do Reservatório de Jaguará e foram utilizados no cálculo do Índice de Qualidade da Água (IQA). Esse índice permitiu sintetizar, de forma objetiva, as condições da água, destacando padrões e variações essenciais para a gestão ambiental e o monitoramento contínuo.

Na Tabela 6 estão apresentados os resultados obtidos para o Índice de Qualidade da Água (IQA).

Tabela 6 – Histórico do Índice de Qualidade das Águas (IQA) observado no reservatório da UEH de Jaguará durante as amostragens realizadas entre 2018 e 2023

Campanha	Pontos de Monitoramento						Média
	JG010	JG020	JG030	JG040	JG050	JG060	
dez/18	88	93	91	84	86	68	85
mai/19	88	88	83	89	97	84	88
jun/19	91	89	95	91	92	93	92
set/19	95	91	94	91	94	93	93
dez/19	94	84	85	85	93	84	88
abr/20	81	87	85	85	90	91	87
jun/20	87	89	90	88	90	88	89
set/20	81	83	88	89	89	87	86
jul/20	87	89	89	91	91	91	90
mai/21	76	88	78	82	79	93	83
jul/21	87	84	83	85	79	92	85
set/21	89	91	90	91	93	89	91
dez/21	85	86	84	91	84	81	85
mar/22	78	79	73	86	76	78	78
jun/22	86	67	90	90	91	88	85
ago/22	68	68	69	69	66	75	69
nov/22	84	87	85	85	90	90	87
fev/23	80	83	84	89	88	93	86
jun/23	84	85	82	87	89	89	86
ago/23	93	92	91	91	92	93	92
dez/23	82	83	84	91	84	80	84
Média	85	85	85	87	87	87	86

Fonte: Do Autor (2025).

A qualidade da água do reservatório da UHE Jaguara apresentou, de modo geral, condições ótimas, conforme o Índice de Qualidade das Águas (IQA) calculado com base nos monitoramentos realizados. Contudo, foram observadas variações entre os diferentes pontos do reservatório, com alguns apresentando índices excelentes e outros classificados como bons.

Durante a campanha de dezembro de 2018, apenas o ponto JG060 apresentou qualidade aceitável, representando o pior resultado da série histórica analisada. Esse desempenho inferior no IQA provavelmente está relacionado à elevação dos níveis de coliformes termotolerantes, sendo o único ponto com contagens superiores a 100 UFC/mL. De acordo com a CETESB (2015), os coliformes termotolerantes são amplamente utilizados como indicadores de contaminação fecal, pois sua presença na água sugere a introdução recente de esgotos domésticos ou dejetos de origem animal.

Esse cenário é coerente com a localização do ponto JG060, situado a jusante da cidade de Rifaina, em uma área com intensa ocupação nas margens do reservatório, incluindo chácaras, hotéis e residências, fatores que podem contribuir para o aporte de esgoto e contaminantes difusos.

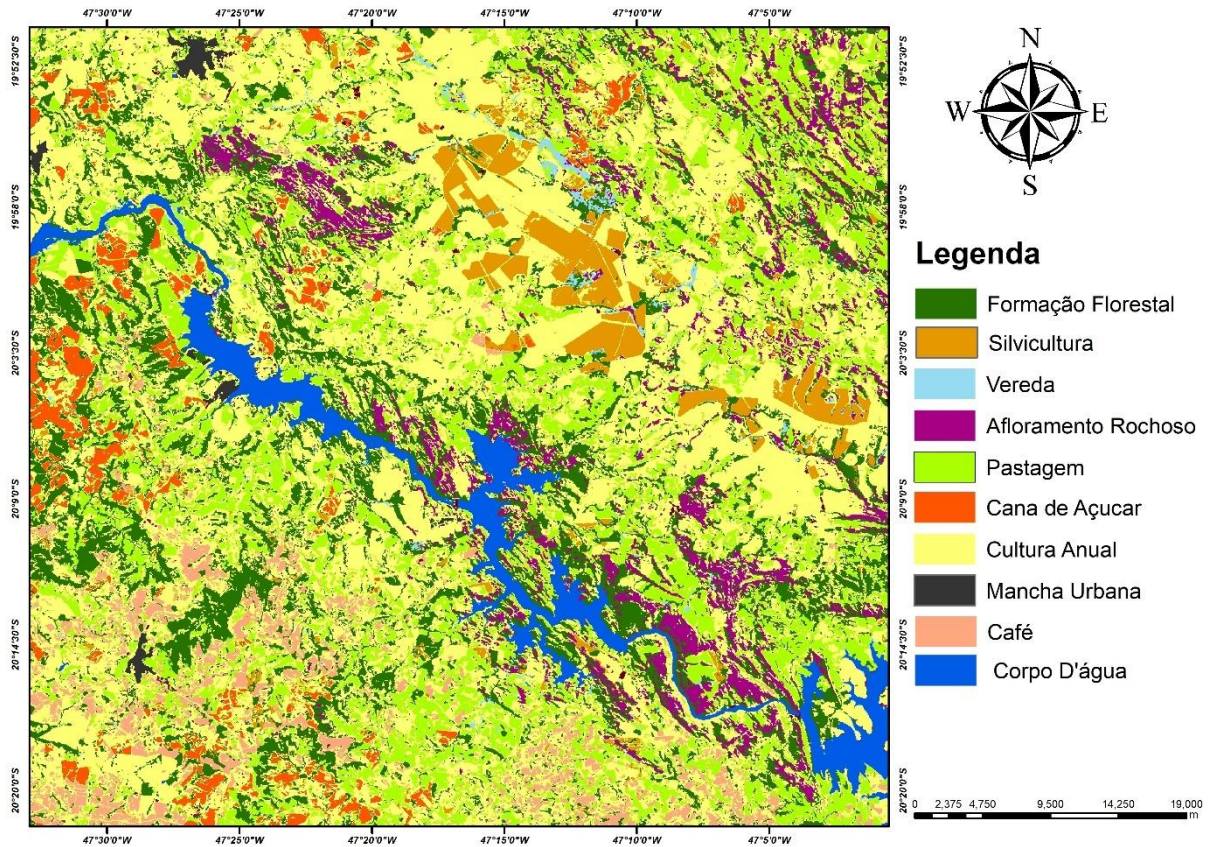
A análise dos seis pontos de monitoramento indica uma leve redução na qualidade da água ao longo do reservatório, especialmente nos meses chuvosos. Também foram registradas quedas durante períodos de estiagem, possivelmente devido à menor renovação da água, maior tempo de residência e concentração de poluentes. Nessas condições, a diluição é reduzida, o que pode intensificar a presença de nutrientes, coliformes e sólidos dissolvidos. Esse declínio é mais evidente próximo ao barramento, devido ao acúmulo de sedimentos e alterações hidrodinâmicas (Lima *et al.*, 2025; Oliveira, 2021).

Estudos realizados por Figueiredo, Becker e Mattos (2014), corroboram essas observações. Os autores avaliaram a qualidade da água do reservatório Gargalheiras durante diferentes anos de seca e constataram que, em 2013, durante um período de seca prolongada, a qualidade da água foi inferior em comparação a 2022, ano marcado por uma estiagem menos severa e maior renovação das águas.

Um aspecto relevante para a compreensão da qualidade da água no reservatório é o uso e ocupação do solo em seu entorno (Figura 9). O levantamento realizado identificou que as principais atividades próximas ao espelho d'água estão relacionadas a empreendimentos agrossilvipastoris, como manejo de gado, cultivo de florestas de eucalipto e lavouras irrigadas por pivôs centrais. Além disso, observou-se a presença de piscicultura, com cultivo de peixes em tanques-rede, o que também pode influenciar a qualidade da água.


Os dados demonstraram uma elevação nos níveis de sólidos dissolvidos totais, sólidos totais e turbidez nos pontos de entrada dos rios contribuintes, principalmente em áreas mais antropizadas a montante. Esse padrão pode estar associado à carga difusa de matéria orgânica e inorgânica oriunda de práticas agropecuárias e ocupações humanas nas bacias de drenagem. Por outro lado, nas proximidades do barramento, observou-se menor transporte de sedimentos em suspensão, mas maior tendência ao acúmulo de poluentes no fundo do reservatório, resultado da menor velocidade da água e do aumento do tempo de residência nesse trecho. Esse comportamento é reforçado pelos valores crescentes de Demanda Bioquímica de Oxigênio (DBO) ao longo dos pontos monitorados, evidenciando a influência da carga orgânica no processo de degradação da qualidade da água (Pizani *et al.*, 2022).

Figura 9 – Classificação do uso e cobertura do solo no entorno do reservatório da UHE Jaguará



Fonte: Do Autor (2025).

Figura 10 – Índices pluviométricos para estação de Sacramento-MG (A525) registrados para os anos de 2018, 2019, 2020, 2021, 2022 e 2023



Fonte: Adaptado de INMET (2025).

Segundo dados obtidos junto ao Instituto Nacional de Meteorologia (INMET), na estação localizada no município de Sacramento-MG (A525), foram registrados eventos significativos de precipitação durante o período que antecedeu as campanhas, evidenciando a forte sazonalidade característica da região. Os meses de verão, como dezembro, janeiro e fevereiro, concentram os maiores volumes de chuva, enquanto os meses de inverno, especialmente junho, julho e agosto, registram volumes extremamente baixos ou quase inexistentes, marcando o período seco.

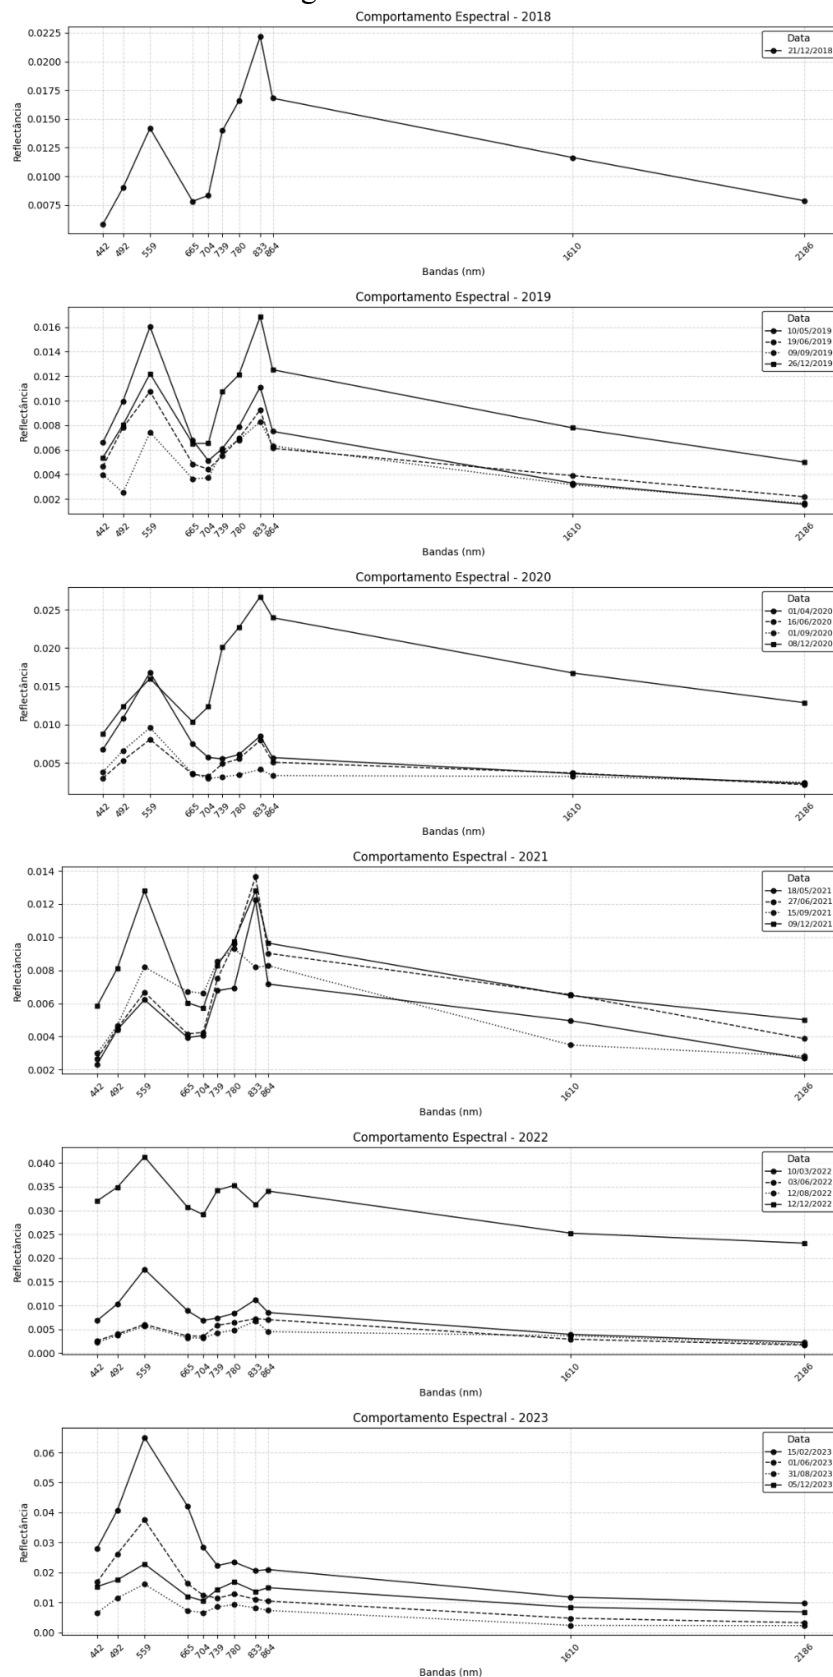
Em janeiro, os anos de 2020 e 2022 chamaram a atenção pelos elevados volumes de precipitação, sendo janeiro de 2022 um dos períodos mais chuvosos, apresentando acumulado de 406,0 mm.

Durante os meses de junho, julho e agosto, a precipitação foi mínima em todos os anos analisados, com destaque para julho de 2020 e de 2023, que praticamente não registraram chuva. Esses meses refletem a intensidade do período seco, típico da região.

5.2 COMPORTAMENTO ESPECTRAL DA ÁGUA DO RESERVATÓRIO

Para visualização da diferença entre os comportamentos espectrais das imagens na região foram construídos os gráficos exibidos na Figura 11, onde constam os valores médios de reflectância de todas as bandas para cada campanha.

Figura 11 – Variação do comportamento espectral médio extraído das imagens Sentinel-2, coincidentes com as diferentes campanhas amostrais de água do reservatório da usina hidrelétrica de Jaguará.



Fonte: Do Autor (2025).

Os gráficos obtidos para os anos de 2021, 2022 e 2023 revelam padrões distintos no comportamento espectral da água no Reservatório de Jaguará. O ano de 2022, em particular, apresentou um aumento expressivo da reflectância em algumas campanhas, especialmente na banda de 559 nm e na faixa de 704 a 864 nm. Esse padrão é consistente com os achados de Wu *et al.* (2014), que, ao monitorar rios de água doce em Taiwan utilizando sensores hiperespectrais, observaram que a reflectância aumentou de forma contínua entre 400 e 900 nm.

Ainda de acordo com Wu *et al.* (2014), os autores destacam que, fora desse intervalo (abaixo de 400 nm e acima de 920 nm), a separação entre curvas espectrais se torna mais difícil devido à saturação óptica. Da mesma forma, Pereira-Sandoval *et al.* (2023) identificaram que os aumentos de reflectância entre 490 e 705 nm estão fortemente associados à redução da transparência da água em lagos eutrofizados na Comunidade Valenciana, Espanha, reforçando a aplicabilidade dessas bandas no monitoramento de parâmetros de qualidade da água por sensoriamento remoto.

De forma semelhante, Toming *et al.* (2016), em lagos da Estônia, utilizaram imagens Sentinel-2 e identificaram que as bandas do infravermelho próximo (especialmente 705 e 740 nm) são sensíveis a variações de concentração de clorofila-a e sólidos em suspensão.

O ano de 2023 apresentou os maiores valores médios de reflectância entre todos os anos analisados no Reservatório de Jaguará, além da maior variabilidade espectral entre as campanhas. Destacaram-se elevações acentuadas nas bandas do espectro visível do satélite Sentinel-2, especificamente a banda 2 (490 nm), banda 3 (560 nm) e banda 4 (665 nm), com picos registrados principalmente nas datas de 15/02 e 5/12 de 2023. Esse comportamento espectral pode estar associado ao aumento da concentração de partículas em suspensão, como sedimentos inorgânicos e matéria orgânica, que contribuem para a elevação da turbidez da água.

Brito *et al.* (2022), ao analisarem o Rio Doce após o rompimento da barragem de Fundão, em Mariana (MG), utilizaram combinações de bandas espectrais do sensor OLI do satélite Landsat 8. Os autores destacam que a banda 5 (infravermelho próximo, 850–880 nm) apresentou os resultados de turbidez mais eficazes, pois seus valores de reflectância demonstraram maior sensibilidade aos eventos que impactaram a qualidade do corpo hídrico.

Estudos realizados por Lopes *et al.* (2014) no reservatório Orós, localizado no semiárido cearense, demonstraram que há forte correlação entre a resposta espectral e variáveis limnológicas relacionadas à qualidade da água. Em especial, o comprimento de onda de 720 nm, localizado na região do infravermelho próximo, apresentou correlação positiva com a concentração de sólidos inorgânicos suspensos (SIS).

Assim, ao analisar a relação entre os espectros de reflectância e os variáveis de qualidade da água, como sólidos dissolvidos totais (SDT), sólidos totais (ST) e turbidez, observa-se que picos elevados nas bandas do visível e do infravermelho próximo estão associados a maiores concentrações de sedimentos em suspensão. Esses resultados evidenciam a influência de eventos de precipitação intensa e mudanças no uso e ocupação do solo, como expansão agrícola, urbanização e desmatamento em áreas próximas aos corpos hídricos (Oliveira *et al.*, 2021).

5.3 MODELAGEM DOS SÓLIDOS DISSOLVIDOS TOTAIS

5.3.1 Resultados das amostragens de sólidos dissolvidos totais

Os resultados das análises laboratoriais para Sólidos Dissolvidos Totais estão apresentados na Tabela 7 de forma resumida com os valores de média, desvio padrão, coeficiente de variação (CV) e valores mínimos e máximos.

Tabela 7 – Resultados das análises de sólidos dissolvidos totais observados nas amostras de água coletadas no reservatório da usina hidrelétrica Jaguara entre 2018 e 2023.

Data	média	mínimo	máximo	desvio padrão	CV
dez/18	10,00	10,00	10,00	0,00	0,00
mai/19	30,00	26,00	34,00	2,83	9,43
jun/19	41,00	34,00	56,00	10,86	26,49
set/29	24,00	24,00	24,00	0,00	0,00
dez/19	28,33	26,00	30,00	1,51	5,31
abr/20	28,00	26,00	30,00	1,26	4,52
jun/20	29,00	28,00	32,00	1,67	5,77
set/20	28,33	28,00	30,00	0,82	2,88
dez/20	23,67	22,00	30,00	3,20	13,54
mai/21	16,17	10,00	36,00	9,91	61,29
jun/21	19,83	10,00	42,00	12,94	65,23
set/21	150,33	32,00	300,00	132,57	88,18
dez/21	17,83	10,00	27,00	6,49	36,41
mar/22	18,17	10,00	31,00	8,73	48,04
jun/22	57,33	31,00	89,00	22,54	39,31
ago/22	17,50	10,00	40,00	11,73	67,01
dez/22	28,33	27,00	31,00	1,75	6,18
fev/23	36,00	24,00	46,00	9,47	26,29
jun/23	14,33	10,00	26,00	6,25	43,61
ago/23	15,67	10,00	24,00	5,28	33,70
dez/23	28,67	26,00	31,00	1,75	6,11
	média	mínimo	máximo	média	média
	31,55	10,00	300,00	11,98	28,06


Fonte: Do Autor (2025).

Ao comparar os resultados com os limites estabelecidos pela Deliberação Normativa Conjunta COPAM/CERH-MG nº 08/2022 para corpos d'água de classe 2, que determina que os Sólidos Dissolvidos Totais não devem ultrapassar 500,00 mg/L verifica-se que todos os valores registrados nos estão dentro do limite estabelecido pela legislação supramencionada.

Embora a precipitação seja um fator relevante para o transporte de sólidos, os resultados evidenciam que não é a única variável determinante. Alterações no uso e ocupação do solo, como desmatamento, agricultura intensiva, também desempenham um papel na dinâmica dos SDT. Além disso, o despejo de efluentes não tratados podem amplificar as variações registradas. Assim, esses sólidos incluem tanto matéria orgânica morta quanto matéria inorgânica em suspensão, referenciadas como tripton ou fração não algal, que afetam diretamente a qualidade da água e o funcionamento do ecossistema aquático (Barbosa; Novo; Martins, 2019).

A Figura 12 apresenta o gráfico boxplot com os resultados de Sólidos dissolvidos totais para cada grupo de amostragens anuais.

Figura 12 – Boxplot dos resultados de sólidos dissolvidos totais agrupados para as campanhas anuais de amostragem de água no reservatório da usina hidrelétrica Jaguará entre 2018 e 2023.



Fonte: Do autor (2025).

Como mostrado na Figura 12, a distribuição anual dos sólidos dissolvidos totais (SDT) apresentou padrões distintos ao longo do período estudado. O ano de 2022 destacou-se pela maior amplitude interquartil e pela ocorrência dos maiores outliers da série (valores superiores a $80 \text{ mg}\cdot\text{L}^{-1}$), indicando episódios de entrada anormal de cargas dissolvidas, possivelmente relacionados ao escoamento superficial ou a alterações hidrossedimentológicas.

Em contraste, 2023 apresentou menor variabilidade e ausência de outliers extremos, sugerindo condições hidrológicas mais estáveis ou menor aporte externo de contaminantes dissolvidos.

Um destaque especial vai para o ano de 2018, que, por contar apenas com uma campanha realizada em dezembro, apresentou valores idênticos em todos os seus seis pontos de amostragem. Essa uniformidade compromete a representatividade do gráfico, dificultando a análise da variabilidade e a comparação com os demais anos, os quais apresentam maior dispersão e múltiplos eventos registrados.

Os dados referentes a 2023 demonstraram uma distribuição mais equilibrada, sem a ocorrência de outliers. Esse período se destacou pela menor variabilidade entre os valores registrados, refletindo uma maior consistência nas concentrações de SDT.

Vale ressaltar que, durante o processamento dos dados, valores muito discrepantes, como 200 e 300 mg·L⁻¹, foram removidos para evitar distorções na análise. Esses valores representam condições anômalas ou específicas, que não refletem o comportamento geral da série.

Com relação ao coeficiente de variação (CV), os valores apresentados indicam que a variabilidade foi mais alta em 2022, corroborando a elevada dispersão observada no gráfico. Em contrapartida, anos como 2019 e 2020 apresentaram menores coeficientes de variação, confirmando a consistência das amostras nesses períodos.

5.3.2 Modelos de predição sólidos dissolvidos totais

Os resultados da etapa de geração de modelos de predição para sólidos dissolvidos totais, foram divididos em duas abordagens distintas: análises de regressão e modelos de aprendizagem de máquinas. Os resultados de cada uma destas abordagens serão apresentados e discutidos nos tópicos a seguir,

5.3.2.1 Regressões

Para obter o melhor modelo para estimar os SDT a partir de dados espectrais obtidos das imagens Sentinel, foram testadas diversas combinações de variáveis espectrais. Essas combinações incluíram tanto bandas individuais quanto razões de bandas, aplicadas a diferentes abordagens de regressão (Linear, Quadrática e Polinomial). O desempenho dos modelos foi avaliado utilizando métricas, como o coeficiente de correlação de Pearson (r), o Erro Percentual

Absoluto Médio (MAPE) e a Raiz do Erro Médio Quadrático (RMSE), considerando tanto o conjunto completo de dados quanto os dados tratados para remoção de outliers. Na Tabela 8 está apresentado um resumo dos melhores resultados obtidos nas regressões, destacando os modelos e variáveis que demonstraram maior eficácia na previsão dos SDT.

Tabela 8 – Resultados das análises de regressão para sólidos dissolvidos totais (SDT)

Variável	Modelo	Pearson	MAPE	RMSE	Outliers
banda559/banda665	Polinomial	0,46	0,50	26,76	Com Outliers
banda559/banda665	Quadrática	0,38	0,60	27,27	Com Outliers
banda864/banda1610	Quadrática	0,38	0,76	28,16	Com Outliers
banda864/banda1610	Polinomial	0,37	0,74	28,21	Com Outliers
banda780/banda1610	Quadrática	0,36	0,75	28,18	Com Outliers
banda780/banda1610	Polinomial	0,36	0,75	28,18	Com Outliers
banda864/banda1610	Linear	0,35	0,63	28,56	Com Outliers
banda739/banda1610	Quadrática	0,34	0,79	28,86	Com Outliers
banda780/banda1610	Linear	0,33	0,63	28,74	Com Outliers
banda833/banda1610	Polinomial	0,32	0,77	28,77	Com Outliers

Fonte: Do Autor (2025).

Os resultados indicaram que, de forma geral, as razões de bandas apresentaram melhor desempenho em comparação com as bandas individuais, especialmente quando aplicadas a modelos polinomiais. As melhores calibrações foram alcançadas mesmo com a presença de outliers. A análise dos resultados mostrou que a razão de bandas 559/665 apresentou o melhor desempenho geral com o modelo polinomial, obtendo um coeficiente de correlação de Pearson (r) de 0,46, um MAPE de 0,50% e um RMSE de 26,76.

A frequência da banda 1610 nm (SWIR) nas combinações mais promissoras também sugere que essa região espectral possui sensibilidade relevante às variáveis analisadas, especialmente em ambientes com alta concentração de material particulado ou dissolvido. Essa sensibilidade reforça a importância de explorar combinações racionais de bandas, além de evidenciar a necessidade de tratamento prévio dos dados, como a exclusão de valores atípicos, para aprimorar o desempenho dos modelos preditivos.

Quevedo-Castro *et al.* (2024) desenvolveram modelos de regressão linear aplicando dados do satélite Landsat-8 para estimar parâmetros de qualidade da água, incluindo os sólidos dissolvidos totais (TDS), em um reservatório tropical. Os autores testaram diversas razões de bandas espectrais, verificando que algumas combinações envolvendo o infravermelho próximo e o SWIR foram eficazes na detecção de águas extremamente turvas. Esses resultados foram associados a altas concentrações de sólidos suspensos e dissolvidos, evidenciando o potencial

dessas bandas na modelagem de ambientes com significativa carga material.

O modelo quadrático aplicado à razão de bandas 559/665 também apresentou resultados promissores, com um coeficiente de correlação de Pearson de 0,38, um MAPE de 0,60 e um RMSE de 27,27, mostrando que ajustes quadráticos podem ser úteis ao simplificar a complexidade do modelo sem comprometer consideravelmente a precisão.

Os dados revelam que os melhores desempenhos foram obtidos com modelos polinomiais aplicados às razões de bandas, indicando que interações não lineares desempenham um papel crucial na relação entre os dados espectrais e os sólidos dissolvidos totais (SDT). A escolha de bandas localizadas na região espectral do verde (559 nm) e do vermelho (665 nm) reforça a relevância dessas faixas na análise da qualidade da água, pois estão diretamente associadas à absorção e reflexão de componentes ópticos ativos presentes em ambientes aquáticos (Barbosa; Novo; Martins, 2020).

Resultados semelhantes foram reportados por Dewidar *et al.* (2008), que utilizaram imagens do sensor Landsat 7 ETM+ para estimar concentrações de TDS na Lagoa Manzala, Egito. Nesse estudo, a razão de bandas B2 (azul, 0,45–0,515 μm) e B4 (vermelho, 0,63–0,69 μm) apresentou uma correlação moderada de 0,43 com os parâmetros de qualidade da água.

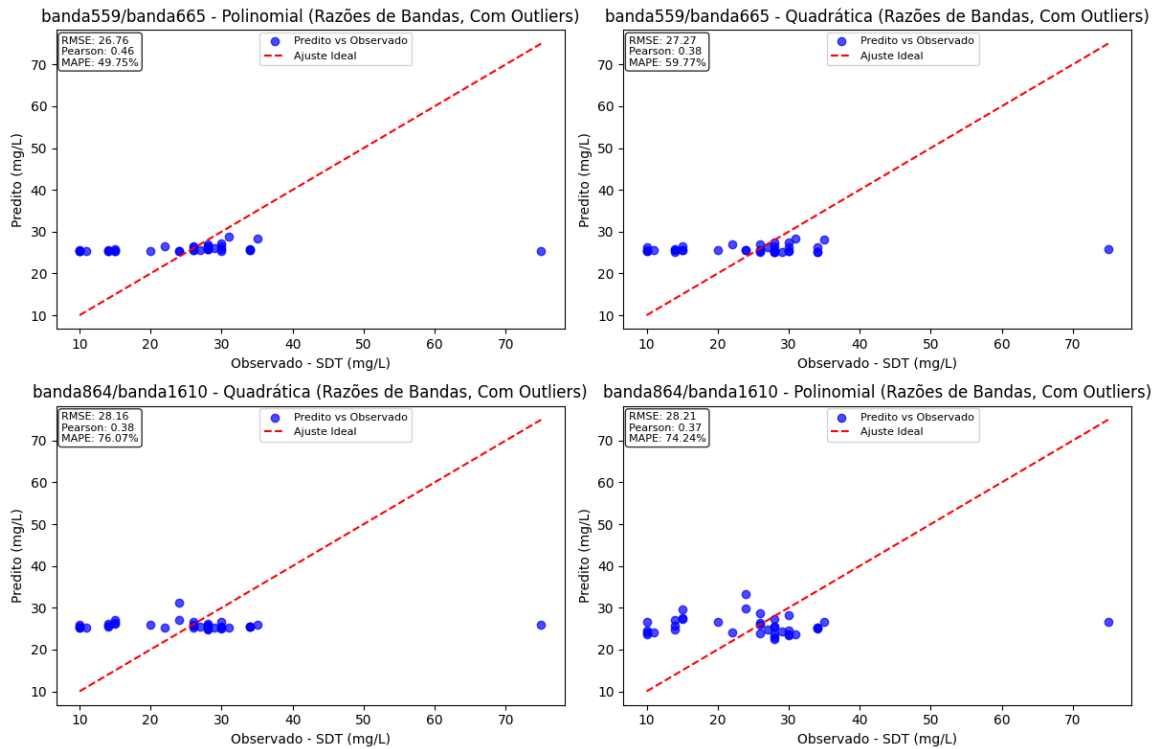
Embora modelos avançados como Redes Neurais Artificiais (ANN) e *Random Forest* tenham se destacado na estimativa de SDT, abordagens tradicionais como a regressão linear ainda se mostram eficazes em contextos com relações espectrais mais diretas. Autores como Maliki *et al.* (2020) utilizaram regressão múltipla baseada em índices espectrais de salinidade, como o NDSI (Normalized Difference Salinity Index), atingindo um R^2 de 0,94 em águas eutróficas do rio Shatt Al-Arab.

Ainda nesse contexto, embora o SDT seja um parâmetro opticamente inativo, com baixo índice sinal-ruído, Adjovu *et al.* (2023) destacam que sua estimativa pode ser realizada de forma indireta, por meio de modelos de regressão que correlacionam dados espectrais com medições *in situ*. Os autores também recomendam a aplicação de correções atmosféricas e a integração de dados ópticos com sensores de micro-ondas, como estratégia para aprimorar a precisão das estimativas de SDT.

No entanto, em ambientes aquáticos altamente dinâmicos e com elevada variabilidade óptica, como rios e estuários, a regressão linear pode ser insuficiente para capturar padrões complexos, sendo mais apropriados modelos com maior capacidade de lidar com relações não lineares, como demonstrado por Balasubramanian *et al.* (2020), ao propor algoritmos robustos com aprendizagem de máquinas, para estimativas de sólidos suspensos em águas interiores e costeiras.

Aplicando as equações ajustadas aos respectivos valores para os pontos amostrais, foram construídos os gráficos apresentados na Figura 13. Esses gráficos exibem os valores de sólidos dissolvidos totais observados em campo (eixo x) em comparação com os valores preditos pelos modelos de regressão (eixo y).

Figura 13 – Comparação entre os valores de sólidos dissolvidos totais observados nas diferentes campanhas amostrais e preditos pelas análises de regressão



Fonte: Do Autor (2025).

5.3.2.2 Aprendizado de máquina

Com o objetivo de verificar qual o melhor modelo para estimar os sólidos dissolvidos totais (SDT) a partir de dados espectrais obtidos das imagens Sentinel, foram testadas diversas combinações de variáveis espectrais e avaliadas três abordagens distintas: o uso de bandas individuais, razões de bandas e a combinação de todas as bandas espectrais. Os modelos de aprendizado de máquina *Random Forest*, *Decision Tree* e SVM foram aplicados com o objetivo de identificar as melhores combinações de variáveis espectrais e os ajustes mais precisos. As análises consideraram tanto os dados completos quanto os tratados para a remoção de outliers, utilizando métricas como o coeficiente de correlação de Pearson, o Erro Percentual Absoluto Médio (MAPE) e a Raiz do Erro Médio Quadrático (RMSE) para avaliar o desempenho dos modelos. A Tabela 9 apresenta um resumo dos melhores resultados obtidos nas modelagens de

aprendizagem por máquina.

Tabela 9 – Resultados dos modelos de aprendizagem para sólidos dissolvidos totais (SDT)

Variável	Modelo	Pearson	MAPE	RMSE	Outliers
banda2186	<i>Random Forest</i>	0,84	0,48	16,09	Com Outliers
banda492/banda665	<i>Decision Tree</i>	0,76	0,35	9,25	Sem Outliers
banda492/banda665	<i>Random Forest</i>	0,76	0,32	7,73	Sem Outliers
Todas as Bandas	<i>Random Forest</i>	0,72	0,58	21,36	Com Outliers
banda559/banda665	<i>Random Forest</i>	0,64	0,54	23,47	Com Outliers
banda780/banda864	<i>Decision Tree</i>	0,64	0,96	50,58	Com Outliers
banda780/banda864	<i>Random Forest</i>	0,63	0,82	32,53	Com Outliers
banda665	<i>Random Forest</i>	0,60	0,39	9,18	Sem Outliers
banda780/banda1610	<i>Random Forest</i>	0,58	0,54	24,66	Com Outliers
banda2186	<i>Decision Tree</i>	0,58	0,57	24,26	Com Outliers

Fonte: Do Autor (2025).

O modelo *Random Forest* aplicado à banda de 2186 nm (SWIR) apresentou o melhor desempenho geral na estimativa dos Sólidos Dissolvidos Totais (SDT), com coeficiente de correlação de Pearson (r) de 0,84, MAPE de 0,48 e RMSE de 16,09 mg/L. Resultados semelhantes foram relatados por Leggesse *et al.* (2023), que utilizaram o algoritmo *Random Forest* para estimar parâmetros ópticos da qualidade da água, incluindo TDS, no Lago Tana, Etiópia, alcançando um R^2 de 0,80. No entanto, diferentemente deste estudo, os autores utilizaram todas as bandas disponíveis do Sentinel-2, sem validação externa.

Os modelos de aprendizado de máquina *Decision Tree* e *Random Forest*, aplicados à razão de bandas 492/665 nm, também apresentaram desempenho satisfatório na estimativa dos SDT, com r igual a 0,76. Esse resultado está em concordância com os achados de Mamun *et al.* (2024), que identificaram a razão entre as bandas 665/492 nm como a de melhor desempenho preditivo para SDT em diferentes corpos d'água da Coreia do Sul, com o uso dos sensores Sentinel-2 MSI e Landsat-8 OLI.

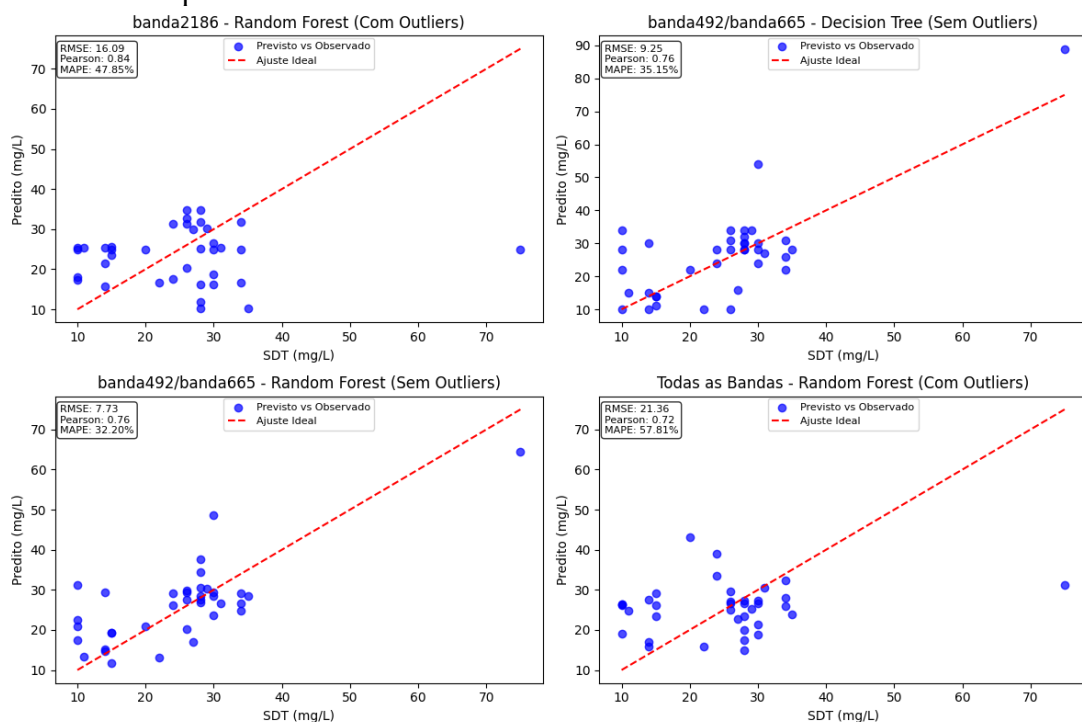
De forma semelhante, Wang *et al.* (2021) demonstraram que a razão entre as bandas do vermelho (665 nm) e azul (492 nm) foi a que melhor estimou a profundidade de Secchi em lagos dos Estados Unidos, evidenciando a sensibilidade dessas faixas espectrais a propriedades ópticas da água.

Entre os modelos que utilizaram bandas individuais, a banda 665 nm (vermelho), quando aplicada ao modelo *Random Forest*, destacou-se com coeficiente de correlação de Pearson (r) de 0,60, MAPE de 39,39% e RMSE de 9,18 mg/L. Essa banda é reconhecida na literatura como sensível à turbidez e à presença de partículas em suspensão, parâmetros

fortemente relacionados aos SDT, conforme demonstrado por Jiang *et al.* (2023) e por Barbosa, Novo e Martins (2019).

Aplicando as equações ajustadas aos respectivos valores para os pontos amostrais, foram construídos os gráficos apresentados na Figura 14. Esses gráficos exibem os valores de SDT observados em campo (eixo x) em comparação com os valores preditos pelos modelos de regressão (eixo y).

Figura 14 – Comparação entre os valores de sólidos dissolvidos totais observados nas diferentes campanhas amostrais e preditos pelos modelos de aprendizagem de máquina



Fonte: Do Autor (2025).

5.3.2.3 Mapa de estimativa de sólidos dissolvidos totais

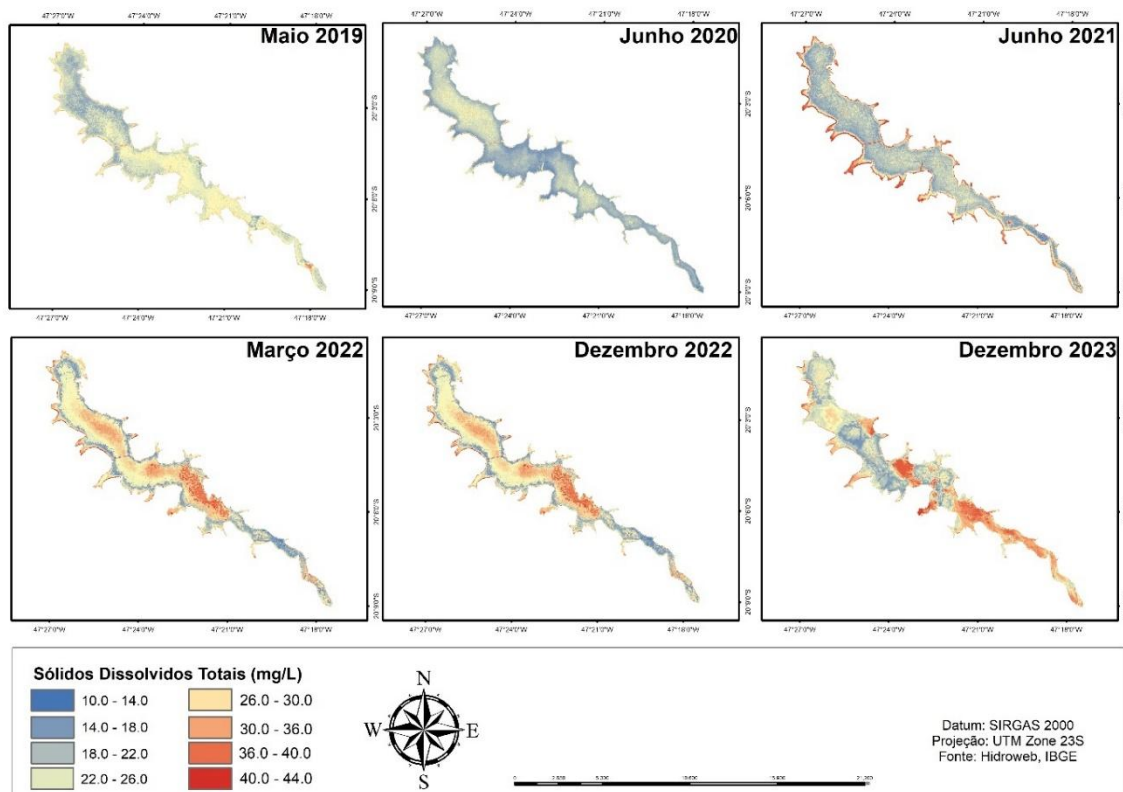
Com base nas análises realizadas, o modelo *Random Forest* aplicado à banda 2186 nm (SWIR) foi identificado como o mais eficiente para prever os Sólidos Dissolvidos Totais (SDT). Dessa forma, esse modelo foi utilizado na geração de mapas preditivos, proporcionando uma representação espacial detalhada dos valores estimados.

Essa banda é particularmente eficaz em cenários onde outras faixas espectrais apresentam limitações. Além disso, destaca-se por sua eficiência na correção atmosférica, permitindo a remoção de ruídos causados pelo vapor d'água e outras influências atmosféricas, resultando em imagens mais confiáveis e de maior qualidade, tal como verificado nos estudos

de Knaeps *et al.* (2015) e Vanhellemont e Ruddick (2015) que utilizaram as bandas SWIR (2186 nm) para estudar ambientes aquáticos turvos, incluindo águas oceânicas e costeiras.

Na Figura 15 pode-se observar a distribuição espacial da concentração de sólidos dissolvidos totais predita pelo modelo banda2186 *Random Forest*, para diferentes campanhas escolhidas de acordo com a sazonalidade.

Figura 15 – Predição de valores de sólidos dissolvidos totais pelo modelo *Random Forest* com a banda 2186 para o reservatório da usina hidrelétrica de Jaguara em diferentes datas.



Fonte: Do Autor (2025).

Durante o período de estiagem (maio a setembro), a Figura 15 mostra que o reservatório apresenta uma distribuição relativamente homogênea de SDT, com concentrações mais baixas, reflexo da menor entrada de materiais dissolvidos. Já na estação chuvosa, observa-se maior heterogeneidade espacial, com elevações nas zonas de entrada de água e redução gradual em direção à barragem, possivelmente devido ao aumento do escoamento superficial. Esse comportamento é consistente com Bertone e Hughes (2023), que relataram menores concentrações de sólidos dissolvidos na seca e maior variabilidade espacial durante as chuvas.

A análise temporal realizada no reservatório revelou-se de grande relevância, ao evidenciar a aplicabilidade do modelo sob diferentes condições ambientais e reforçar sua

capacidade de generalização espaço-temporal. Nesse contexto, Zhang, Huang e Wang (2020) destacam a importância da coleta de dados sob variadas condições sazonais para aumentar a sensibilidade do modelo às variações ambientais. Esses autores utilizaram dados de sensoriamento remoto em conjunto com o algoritmo SVM para a predição de parâmetros da qualidade da água.

Ainda na Figura 15, os maiores índices de SDT foram observados nas zonas de entrada de água, explicados pela menor profundidade e maior velocidade da água nessas regiões, que favorecem a ressuspensão de sedimentos. Concentrações elevadas são esperadas devido ao aporte de sedimentos dos afluentes e à produção primária local, que aumenta a quantidade de material em suspensão (Silva *et al.*, 2019). Além disso, conforme Butler e Ford (2018), o TDS é influenciado pela dissolução de minerais e precipitação atmosférica, processos que contribuem para a entrada de sedimentos e materiais dissolvidos no reservatório.

Os melhores resultados obtidos com as razões de bandas em relação ao conjunto de dados de SDT são justificados por sua capacidade de realçar contrastes espectrais entre constituintes opticamente ativos da água, como os sólidos dissolvidos e suspensos, além de minimizar interferências atmosféricas, efeitos relacionados à profundidade da coluna d'água e variações de iluminação. Segundo Kutser *et al.* (2016) e Novo (2008), essas combinações espectrais otimizam a resposta dos sensores remotos, tornando o sinal mais sensível às variações nas propriedades da água. Especificamente, as razões envolvendo as bandas do azul e do vermelho apresentam elevada resposta ao espalhamento de partículas e à absorção de material dissolvido, elementos diretamente associados aos SDT.

5.4 SÓLIDOS TOTAIS

5.4.1 Resultados das análises de sólidos totais

A análise dos dados de sólidos totais (ST) demonstrou uma variação ao longo das campanhas realizadas entre 2018 e 2023. Os valores de ST variaram de 10 mg L⁻¹ a 500 mg L⁻¹ após a remoção de outliers acima desse limite, evidenciando um padrão de dispersão elevado em determinados períodos.

Os resultados das análises laboratoriais para ST estão apresentados na Tabela 10 de forma resumida com os valores de média, desvio padrão, coeficiente de variação (CV) e valores mínimos e máximos.

Tabela 10 – Resultados de Sólidos Totais observados nas amostras de água coletadas no reservatório da usina hidrelétrica Jaguará entre 2018 e 2023.

Data	média	mínimo	máximo	desvio padrão	CV
21/12/2018	29,67	28,00	32,00	1,51	5,07
10/05/2019	43,00	34,00	58,00	9,44	21,96
19/06/2019	56,67	36,00	66,00	10,56	18,63
09/09/2019	31,00	26,00	42,00	5,76	18,59
26/12/2019	31,33	26,00	36,00	3,50	11,18
01/04/2020	30,00	28,00	32,00	1,79	5,96
16/06/2020	32,17	29,00	38,00	3,37	10,48
01/09/2020	33,83	30,00	37,00	3,19	9,42
08/12/2020	25,00	22,00	30,00	2,76	11,03
18/05/2021	26,67	21,00	40,00	6,74	25,29
27/06/2021	155,00	27,00	400,00	189,81	122,46
15/09/2021	114,33	34,00	500,00	188,95	165,26
09/12/2021	22,00	1,00	38,00	13,55	61,59
10/03/2022	31,67	24,00	41,00	6,80	21,48
03/06/2022	52,67	38,00	61,00	8,52	16,19
12/08/2022	26,67	10,00	71,00	26,74	100,28
12/12/2022	53,33	33,00	69,00	12,74	23,88
15/02/2023	47,00	34,00	64,00	10,26	21,82
01/06/2023	70,67	42,00	108,00	24,02	33,99
31/08/2023	20,33	12,00	26,00	4,97	24,43
05/12/2023	26,67	20,00	33,00	4,32	16,20
	média	mínimo	máximo	média	média
	45,70	1,00	500,00	25,68	35,49


Fonte: Do Autor (2025).

Os valores mais baixos, na faixa de 10 mg L⁻¹, foram observados em meses de menor precipitação, como agosto de 2022, indicando menor transporte de material em suspensão. Por outro lado, meses como junho e dezembro apresentaram maiores valores médios de ST, o que pode estar relacionado ao aumento do escoamento superficial devido à maior precipitação sazonal, contribuindo para o transporte de sólidos, incluindo sedimentos e matéria orgânica.

A campanha de maior amplitude ocorreu em junho de 2023, com valores médios de ST acima de 70 mg L⁻¹ e desvio padrão significativo, refletindo alta variabilidade nesse período.

Os boxplots evidenciam a ocorrência de eventos extremos, como os outliers identificados, possivelmente associados a condições meteorológicas atípicas ou a alterações locais específicas. A Figura 16 apresenta o boxplot com os resultados de Sólidos Totais para cada grupo de amostragens anuais, fornecendo uma análise detalhada da distribuição e variação dos dados.

Figura 16 – Boxplot dos resultados de sólidos totais agrupados para as campanhas anuais de amostragem de água no reservatório da usina hidrelétrica Jaguara entre 2018 e 2023.



Fonte: Do autor (2025).

A Figura 16 mostra que o ano de 2023 apresentou o maior outlier da série histórica, ultrapassando 100 mg L^{-1} , o que sugere um evento anômalo significativo. Embora sua mediana tenha sido levemente inferior à de 2022, esse valor extremo pode estar potencialmente relacionado a uma carga sedimentar elevada em uma única campanha, como em períodos pós-chuva intensa, rompimento de taludes ou práticas agrícolas com baixa cobertura do solo.

O ano de 2022 apresentou a maior dispersão entre os valores de ST, com amplitude interquartil mais elevada em comparação aos demais anos. Embora não tenha exibido outliers extremos acima de 300 mg L^{-1} , a variabilidade observada pode estar associada não apenas a fatores climáticos, mas também à intensificação da produção primária local, que eleva a quantidade de material orgânico em suspensão. Além disso, a morfometria do reservatório, com zonas rasas e baixa renovação, pode favorecer a retenção e ressuspensão de sedimentos, especialmente sob a influência de ventos fortes ou alterações hidrodinâmicas.

Já em 2019, observa-se um aumento expressivo tanto na mediana quanto na amplitude interquartil, com valores variando de 26 a 66 mg L^{-1} . Essa variação pode estar associada à maior intensidade de escoamento superficial ou à presença de eventos sazonais que aumentaram o aporte de sólidos ao reservatório.

5.4.2 Modelos de predição sólidos totais

Os resultados da etapa de geração de modelos de predição para sólidos totais, foram divididos em duas abordagens distintas: análises de regressão e modelos de aprendizagem de máquina. Os resultados de cada uma destas abordagens serão apresentados e discutidos nos tópicos seguintes.

5.4.2.1 Regressões

Foram testadas diversas combinações de variáveis espectrais para obter o melhor modelo para estimar os ST a partir de dados espectrais obtidos das imagens Sentinel. Essas combinações incluíram tanto bandas individuais quanto razões de bandas, aplicadas a diferentes abordagens de regressão (Linear, Quadrática e Polinomial). O desempenho dos modelos foi avaliado utilizando métricas, como o coeficiente de correlação de Pearson (r), o Erro Percentual Absoluto Médio (MAPE) e a Raiz do Erro Médio Quadrático (RMSE), considerando tanto o conjunto completo de dados quanto os dados tratados para remoção de outliers. Na Tabela 11 está apresentado um resumo dos melhores resultados obtidos nas regressões, destacando os modelos e variáveis que demonstraram maior eficácia na previsão dos parâmetros analisados.

Tabela 11 – Resultados das análises de regressão para predição de sólidos totais (ST) nas águas do reservatório da UHE de Jaguará.

Variável	Modelo	Pearson r	MAPE	RMSE	Outliers
banda442/banda780	Quadrática	0,41	0,54	14,97	Sem Outliers
banda442/banda739	Quadrática	0,41	0,54	15,02	Sem Outliers
banda442/banda780	Polinomial	0,39	0,54	14,95	Sem Outliers
banda442/banda704	Quadrática	0,37	0,54	15,32	Sem Outliers
banda442/banda864	Quadrática	0,37	0,55	15,09	Sem Outliers
banda442/banda704	Linear	0,36	0,55	15,63	Sem Outliers
banda442/banda833	Quadrática	0,36	0,55	15,09	Sem Outliers
banda442/banda833	Polinomial	0,36	0,54	14,88	Sem Outliers
banda442/banda739	Linear	0,34	0,54	15,14	Sem Outliers
banda442/banda739	Polinomial	0,33	0,55	15,02	Sem Outliers

Fonte: Do autor (2025).

A análise dos resultados revelou que, com base nas métricas de desempenho (correlação de Pearson, MAPE e RMSE), as razões de bandas apresentaram melhor desempenho preditivo em comparação às bandas individuais, especialmente quando aplicadas a modelos quadráticos. Esse tipo de modelagem demonstrou maior sensibilidade na captura de relações não lineares

entre as variáveis espectrais e os sólidos totais (ST). As melhores calibrações foram obtidas após o tratamento adequado dos dados, com destaque para a remoção de outliers, o que contribuiu para reduzir distorções estatísticas e aumentar a robustez dos modelos. Dentre os cenários analisados, a razão de bandas 442/780 combinada ao modelo quadrático alcançou os melhores indicadores: correlação de Pearson (r) de 0,41, MAPE de 0,54 e RMSE de 14,97. Esses resultados evidenciam a eficácia do modelo em representar as variações de ST de forma mais precisa, mesmo em condições ambientais complexas.

Resultados semelhantes foram obtidos por Adjovu *et al.* (2023), que aplicaram regressão múltipla para estimar séries temporais de sólidos totais, tanto suspensos quanto dissolvidos, com coeficiente de determinação (R^2) de 0,81, evidenciando o potencial do sensoriamento remoto para o monitoramento da qualidade da água.

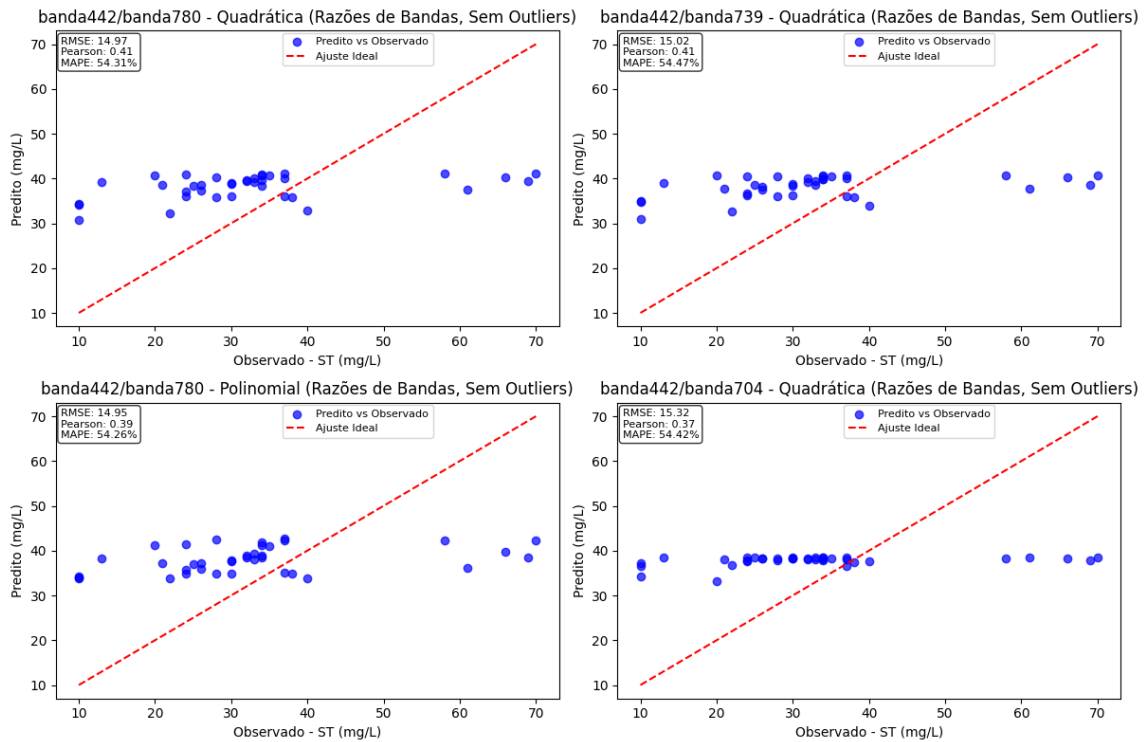
Pizani *et al.* (2022) também observaram bons resultados ao aplicar regressão múltipla para estimar parâmetros não opticamente ativos, como condutividade elétrica, SDT e oxigênio dissolvido, com coeficientes de determinação superiores a 0,71 em dados obtidos por meio do sensor MSI do Sentinel-2.

A razão de bandas 442/739 também apresentou desempenho considerável quando aplicada ao modelo quadrático, atingindo $r = 0,41$, MAPE de 0,54% e RMSE de 15,02. Esses achados reforçam a ideia de que combinações espectrais (razões de bandas) aumentam a capacidade preditiva dos modelos, ao realçarem contrastes espectrais entre constituintes opticamente ativos da água, como sólidos suspensos e dissolvidos.

Por outro lado, os modelos lineares aplicados às razões de bandas demonstraram desempenho inferior, com correlações de Pearson abaixo de 0,36, MAPE de 0,5 e RMSE acima de 15,63 indicando limitação dessas abordagens em capturar a complexidade das relações espectrais.

Aplicando-se as equações ajustadas aos respectivos pontos amostrais, foram construídos os gráficos apresentados na Figura 17. Esses gráficos exibem os valores de sólidos totais observados em campo (eixo x) em comparação com os valores preditos pelos modelos de regressão (eixo y).

Figura 17 – Comparação entre os valores de sólidos totais observados nas diferentes campanhas amostrais e preditos pelas análises de regressão.



Fonte: Do autor (2025).

5.4.2.2 Aprendizado de máquina

Com o objetivo de verificar qual é o melhor modelo para estimar os sólidos totais (ST) a partir de dados espectrais obtidos das imagens Sentinel, foram testadas diversas combinações de variáveis espectrais, foram avaliadas três abordagens distintas: o uso de bandas individuais, razões de bandas e a combinação de todas as bandas espectrais. Os modelos de aprendizado de máquina *Random Forest*, *Decision Tree* e SVM foram aplicados com o objetivo de identificar as melhores combinações de variáveis espectrais e os ajustes mais precisos. As análises consideraram tanto os dados completos quanto os tratados para a remoção de outliers, utilizando métricas como o coeficiente de correlação de *Pearson*, o Erro Percentual Absoluto Médio (MAPE) e a Raiz do Erro Médio Quadrático (RMSE) para avaliar o desempenho dos modelos. Na Tabela 12 está apresentado um resumo dos melhores resultados obtidos nas modelos de aprendizagem.

Tabela 12 – Resultados dos modelos de aprendizagem para sólidos dissolvidos totais (ST)

Variável	Modelo	Pearson	MAPE	RMSE	Outliers
banda559/banda864	<i>Decision Tree</i>	0,51	2,11	91,49	Com Outliers
banda704/banda780	<i>Decision Tree</i>	0,47	2,26	69,49	Com Outliers
banda559/banda864	<i>Random Forest</i>	0,45	2,00	77,98	Com Outliers
banda559/banda2186	<i>Random Forest</i>	0,39	1,27	72,00	Com Outliers
banda665/banda780	<i>Decision Tree</i>	0,39	0,54	15,82	Sem Outliers
banda739/banda780	<i>Decision Tree</i>	0,37	1,34	73,39	Com Outliers
banda739/banda780	<i>Random Forest</i>	0,37	1,24	74,37	Com Outliers
banda780	<i>Random Forest</i>	0,37	0,47	14,61	Sem Outliers
banda704/banda780	<i>Random Forest</i>	0,36	2,00	72,11	Com Outliers
banda492/banda780	<i>Random Forest</i>	0,36	0,64	17,22	Sem Outliers

Fonte: Do autor (2025).

Na Tabela 11, observa-se que o modelo *Decision Tree* aplicado às razões de bandas apresentou os melhores desempenhos preditivos. A razão entre a banda 559 e a banda 864 destacou-se com o maior coeficiente de correlação de Pearson ($r = 0,51$), indicando uma relação linear moderada com os valores de Sólidos Totais (ST). Além disso, a razão entre as bandas 704 e 780 também apresentou desempenho satisfatório em comparação aos demais modelos de regressão, com $r = 0,47$, MAPE de 2,26 e RMSE de 69,49.

Segundo Doxaran *et al.* (2009), o uso de razões de bandas é uma abordagem eficaz para mitigar os efeitos das variações no tamanho das partículas e na refletância bidirecional dos sedimentos, fatores fortemente influenciados pelas características físico-químicas do material em suspensão. Esses resultados corroboram os encontrados em outros estudos sobre o mapeamento de sedimentos suspensos e TSS, como os de Grendait *et al.* (2018) e Sankaran *et al.* (2023), que destacam a eficácia das combinações de bandas espectrais, incluindo Verde, Vermelho, Azul, NIR e SWIR, para estimar com precisão os sólidos totais suspensos na água utilizando dados de sensoriamento remoto.

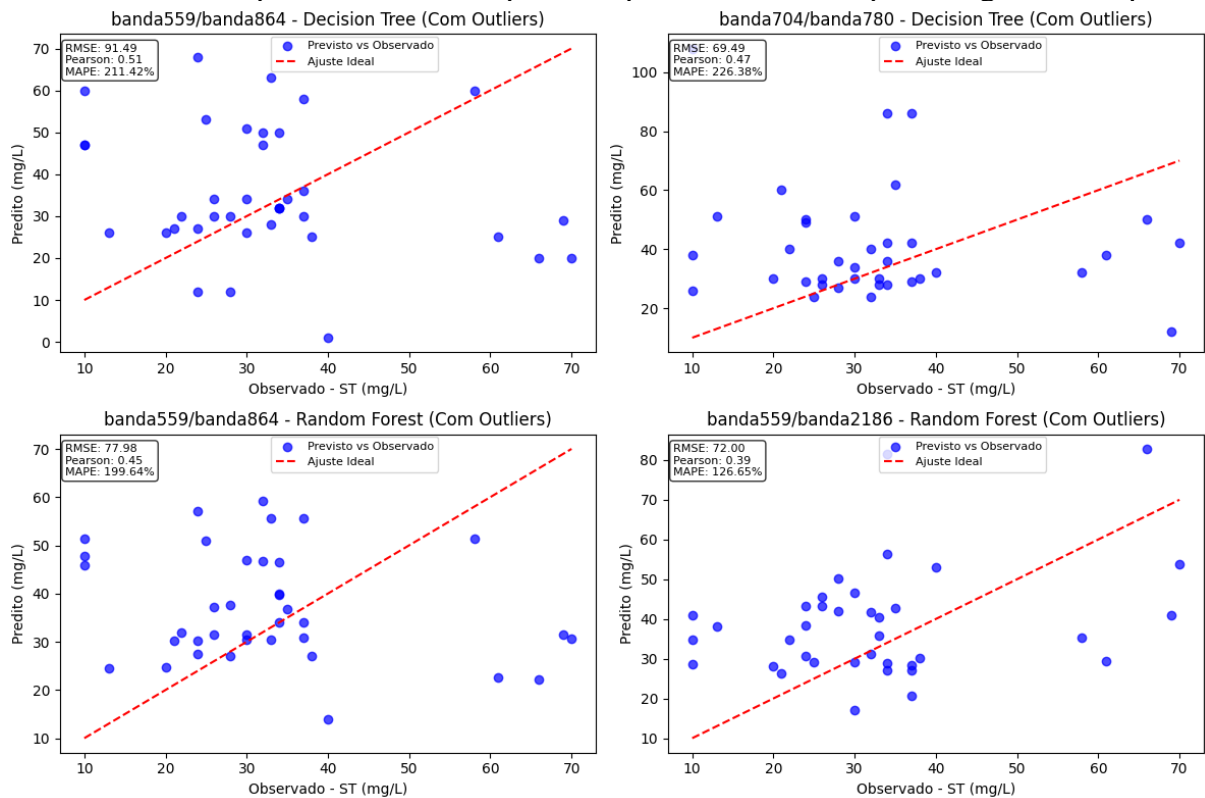
Outro aspecto relevante é a superioridade dos modelos baseados em razões de bandas quando comparados àqueles que utilizam bandas isoladas, no contexto da estimativa de ST. Isso reforça que as combinações espectrais são capazes de capturar nuances espectrais sutis, frequentemente não detectadas em bandas únicas. Em sistemas aquáticos opticamente complexos, tais razões espectrais proporcionam discriminações mais precisas de variáveis relacionadas à qualidade da água (Gholizadeh *et al.*, 2016; Maier; Keller, 2019).

O modelo *Random Forest*, quando aplicado à razão banda 559/banda 2186, alcançou $r = 0,39$, MAPE 1,27, RMSE 72,00. Embora o MAPE ainda seja elevado, os resultados indicam potencial de aprimoramento com ajustes no pré-processamento e na seleção de variáveis

espectrais. Tal melhoria reflete a robustez do algoritmo *Random Forest* em lidar com relações não lineares e mitigar os efeitos de outliers (Maier; Keller, 2019).

A Figura 18 ilustra os quatro melhores modelos de aprendizado de máquina aplicados para a predição de sólidos totais (ST), comparando os valores observados nas diferentes campanhas amostrais com os valores preditos

Figura 18 – Comparação entre os valores de sólidos totais observados nas diferentes campanhas amostrais e preditos pelos modelos de aprendizagem de máquina



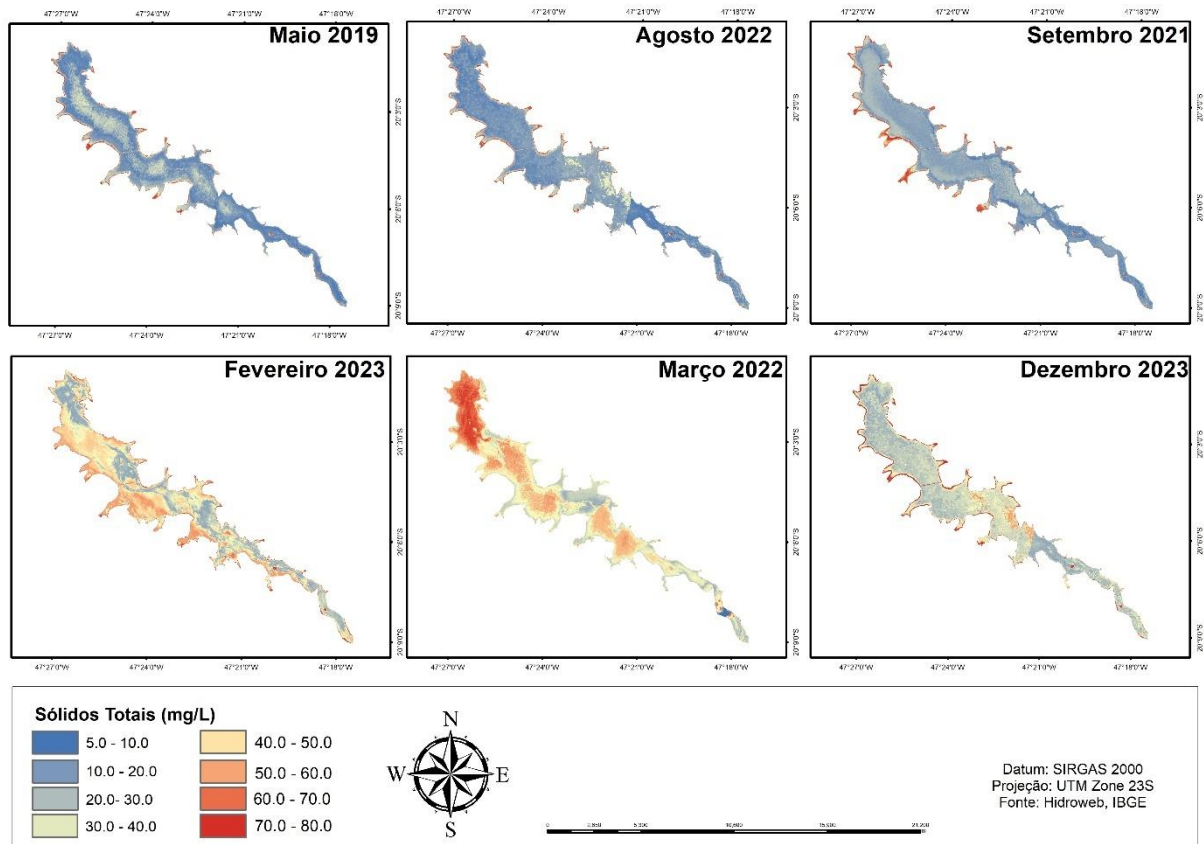
Fonte: Do autor (2025).

5.4.2.3 Mapa de estimativa sólidos totais

Com base nas análises realizadas, o modelo *Decision Tree* aplicado à razão de bandas 559/864 foi identificado como o mais eficaz para a predição dos valores de Sólidos Totais (ST). Dessa forma, ele foi utilizado na geração de mapas preditivos, fornecendo uma representação espacial detalhada das concentrações estimadas.

Na Figura 19, observa-se a distribuição espacial da concentração de Sólidos totais estimada pelo modelo, considerando diferentes campanhas amostrais selecionadas de acordo com a sazonalidade.

Figura 19 – Predição de valores de sólidos Totais pelo modelo *Decision tree* com razão de bandas 559/864 para o reservatório da usina hidrelétrica de Jaguará em diferentes datas.



Fonte: Do autor (2025).

Conforme observado na Figura 19, nos meses de maio de 2019, setembro de 2021 e agosto de 2022, os valores de Sólidos Totais (ST) foram predominantemente baixos, como indicado pelas tonalidades azuladas e amareladas no mapa. Esses padrões sugerem um ambiente mais homogêneo, com menores concentrações de ST, o que está em consonância com os resultados obtidos em campo.

Nas campanhas de março de 2022 e fevereiro de 2023, observou-se um aumento na heterogeneidade espacial da distribuição de ST, com áreas próximas às margens e regiões de entrada de água apresentando concentrações mais elevadas, evidenciadas por tons alaranjados e vermelhos. Esse aumento foi refletido em um aumento generalizado nas concentrações, especialmente nas extremidades do reservatório. Esse comportamento é consistente com os achados de Villota-González *et al.* (2023), que aplicaram modelos de aprendizado de máquina ao sensoriamento remoto para prever parâmetros de qualidade da água. Os autores destacaram que fatores ambientais, como o fluxo de água e a entrada de nutrientes, desempenham um papel crucial na distribuição espacial desses parâmetros. Seus resultados indicaram que esses fatores influenciam diretamente o acúmulo de sólidos nas áreas periféricas dos lagos, particularmente nas extremidades, um padrão também observado nas análises espaciais e temporais realizadas neste estudo.

No entanto, a modelagem para março de 2022 apresentou um comportamento particular, com concentrações de ST também elevadas nas proximidades da área da barragem. Esse padrão foi corroborado pelos dados coletados nos pontos de captação 5 e 6, que também apresentaram valores elevados de ST. Esse fenômeno pode ser explicado pela dinâmica hidrológica do reservatório, onde a retenção de água na região da barragem favorece a acumulação de sedimentos e materiais particulados, especialmente durante períodos de maior vazão ou após eventos de precipitação intensa (Silva *et al.*, 2024; França *et al.*, 2022).

Além disso, Hossain *et al.* (2021) destacam que a dinâmica do reservatório, como o fluxo de água e a entrada de sedimentos, influencia tanto a concentração de Sólidos Suspensos quanto a de Sólidos Totais. Em períodos de maior precipitação ou aumento da vazão, a concentração de Sólidos Suspensos tende a aumentar, o que, por sua vez, eleva o valor de Sólidos Totais (ST). Esse comportamento é importante para monitorar a qualidade da água e pode ser rastreado utilizando técnicas como sensoriamento remoto.

Esses achados reforçam o potencial do uso de razões de bandas e técnicas de aprendizado de máquina no monitoramento remoto da qualidade da água, contribuindo para uma compreensão mais abrangente dos padrões espaciais e temporais de Sólidos Totais (ST) em sistemas aquáticos.

5.5 TURBIDEZ

5.5.1 Resultados das análises de turbidez

Os resultados das análises laboratoriais para turbidez estão apresentados na Tabela 13 de forma resumida com os valores de média, desvio padrão, coeficiente de variação (CV) e valores mínimos e máximos.

Tabela 13 – Resultados de turbidez observados nas amostras de água coletadas no reservatório da usina hidrelétrica Jaguara entre 2018 e 2023.

Data	média	mínimo	máximo	desvio padrão	CV
21/12/2018	2,62	1,19	7,34	2,35	89,64
10/05/2019	3,67	2,57	6,97	1,68	45,68
19/06/2019	2,11	1,57	2,61	0,37	17,70
09/09/2019	0,64	0,48	0,88	0,15	23,44
26/12/2019	1,32	1,05	1,67	0,21	16,04
01/04/2020	3,28	2,08	4,38	0,85	25,82
16/06/2020	0,91	0,84	1,04	0,07	8,10
01/09/2020	1,22	1,09	1,35	0,11	8,94
08/12/2020	1,35	1,08	2,13	0,40	29,96
18/05/2021	0,50	0,50	0,50	0,00	0,00
27/06/2021	0,50	0,50	0,50	0,00	0,00
15/09/2021	0,50	0,50	0,50	0,00	0,00
09/12/2021	2,43	2,30	2,50	0,08	3,36
10/03/2022	6,52	4,90	10,70	2,12	32,46
03/06/2022	1,55	1,30	2,50	0,47	30,47
12/08/2022	1,32	1,10	1,50	0,16	12,17
12/12/2022	2,35	2,00	3,00	0,36	15,40
15/02/2023	2,28	0,50	5,10	2,21	96,76
01/06/2023	2,93	1,80	3,40	0,60	20,42
31/08/2023	0,50	0,50	0,50	0,00	0,00
05/12/2023	1,90	0,50	2,40	0,70	36,92
	média	mínimo	máximo	média	média
	1,92	0,48	10,70	0,61	24,44

Fonte: Do autor (2025).

Com base nos dados apresentados na Tabela 13, pode-se observar uma variação nos valores médios ao longo do período analisado, com médias variando entre 0,50 e 10,7 NTU. O menor valor médio foi registrado em maio, junho e setembro de 2021, e agosto de 2023 (0,50 NTU), enquanto o maior valor foi observado em março de 2022 (10,7 NTU), indicando possíveis influências sazonais e hidrológicas. Pode-se afirmar que, em relação às médias dos pontos coletados, houve uma grande variação, corroborada pelos resultados de desvio padrão e coeficiente de variação. Ouma *et al.* (2020) e Omondi *et al.* (2023) encontraram valores semelhantes para turbidez, variando de 1,36 NTU a 7,42 NTU, com médias de 2,83 e 7,69 NTU em reservatórios, e classificou as águas como de baixa turbidez.

O coeficiente de variação (CV) reforça essa observação, atingindo 96,76% em fevereiro de 2023, o que demonstra alta variabilidade nos dados. Já os menores valores de CV foram registrados em dezembro de 2021 (3,36%) e junho de 2020 (8,10%), apontando uma maior homogeneidade nas medições desses períodos.

Ainda conforme observado na Tabela 13, as campanhas realizadas em março de 2022 e abril de 2020 apresentaram os maiores valores de turbidez medidos em todas as campanhas:


5,10 NTU, 4,38 NTU e 10,7 NTU. Esses valores mais elevados de turbidez provavelmente ocorreram devido ao carreamento de partículas de solo para o reservatório, especialmente em períodos de maior vazão ou após eventos de precipitação intensa. De acordo com Piacentini *et al.* (2018), o transporte de sedimentos ocorre principalmente na época chuvosa ou durante fortes precipitações.

Por outro lado, os menores resultados registrados ocorreram em maio, junho e setembro de 2021, e agosto de 2023, com valores médios de 0,50 NTU, períodos tipicamente mais secos, nos quais há menor aporte de material em suspensão. Segundo o INMET (Instituto Nacional de Meteorologia), na estação localizada no município de Sacramento-MG (A525), foram registrados eventos de precipitação considerável durante o período que antecedeu as campanhas. Em janeiro e fevereiro de 2020, os acumulados foram de 388,0 mm e 285,6 mm, respectivamente, e em 2022, foram de 406,0 mm e 268,22 mm (INMET, 2022). Santos *et al.* (2024) também encontraram valores mais altos de turbidez em reservatórios durante campanhas realizadas no período chuvoso. Bertone e Hughes (2023) citaram em seu estudo que a turbidez não apresenta uma sazonalidade clara, refletindo uma provável resposta a eventos de curto prazo, como chuvas.

Ao comparar os resultados com os limites estabelecidos pela Deliberação Normativa Conjunta COPAM/CERH-MG nº 08/2022 para corpos d'água de classe 2, que determina que a turbidez não deve ultrapassar 100,00 NTU, verifica-se que todos os valores registrados estão dentro do limite estabelecido pela legislação supramencionada.

A Figura 20 apresenta o gráfico boxplot com os resultados de turbidez para cada grupo de amostragens anuais.

Figura 20 – Boxplot dos resultados de turbidez agrupados para as campanhas anuais de amostragem de água no reservatório da usina hidrelétrica Jaguará entre 2018 e 2023.



Fonte: Do autor (2025).

A análise dos boxplots apresentados na Figura 20 revela variações significativas nos valores de turbidez entre os anos de 2018 e 2023. Observa-se que os valores medianos da turbidez permaneceram relativamente estáveis entre 2018 e 2020, apresentando uma redução em 2021 e um aumento expressivo a partir de 2022. Além disso, destaca-se a presença de outliers ao longo das campanhas de monitoramento, especialmente no ano de 2020.

A campanha de 2020 apresentou dois outliers, com concentrações de turbidez de 4,38 e 3,79 NTU, valores superiores ao intervalo interquartil determinado para esse ano. Quando comparadas as amostras de cada campanha, observa-se uma distribuição relativamente uniforme entre o valor mínimo e os intervalos interquartis. A campanha realizada em 2022 apresentou maior discrepância quando comparada com as outras campanhas. Outro aspecto relevante é a baixa variabilidade observada em 2021, evidenciada pelo menor desvio padrão e ausência de outliers significativos.

Ainda analisando os boxplots apresentados na Figura 20, observa-se a presença de um outlier expressivo na campanha de 2022, evidenciado por um valor de turbidez significativamente superior aos demais registros desse período. Esse comportamento atípico pode estar associado a diferentes fatores além da precipitação, incluindo atividades antrópicas intensificadas na região da bacia hidrográfica, como obras de infraestrutura, expansão urbana

ou práticas agrícolas que potencializam a erosão e o carreamento de sedimentos para o corpo hídrico (Carvalho *et al.*, 2023).

A presença de um outlier expressivo no boxplot de 2022, com um valor de turbidez significativamente superior aos demais registros desse período, reflete um comportamento atípico. Esse aumento não pode ser explicado apenas pelas chuvas, mas também por fatores antrópicos, como o aumento das atividades humanas na região da bacia. (Barbosa; Novo; Martins, 2019). Tavora *et al.* (2023), ao utilizarem o algoritmo PLUMES para detectar plumas turvas na Lagoa dos Patos, no Brasil, observaram que atividades humanas, como construção e desmatamento, podem provocar variações significativas na turbidez da água, corroborando a hipótese de que essas interferências externas podem ter contribuído para o aumento atípico de turbidez registrado em 2022.

5.5.2 Modelos de predição de turbidez

Os resultados da etapa de geração de modelos de predição para turbidez, foram divididos em duas abordagens distintas: análises de regressão e modelos de aprendizagem de máquina. Os resultados de cada uma destas abordagens serão apresentados e discutidos nos tópicos seguintes.

5.5.2.1 Regressões

Para obtenção do melhor modelo para estimar turbidez a partir de dados espectrais obtidos das imagens Sentinel, foram testadas diversas combinações de variáveis espectrais. Essas combinações incluíram tanto bandas individuais quanto razões de bandas, aplicadas a diferentes abordagens de regressão (Linear, Quadrática e Polinomial). O desempenho dos modelos foi avaliado utilizando métricas, como o coeficiente de correlação de Pearson (r), o Erro Percentual Absoluto Médio (MAPE) e a Raiz do Erro Médio Quadrático (RMSE), considerando tanto o conjunto completo de dados quanto os dados tratados para remoção de outliers. Um resumo dos melhores resultados obtidos nas regressões, destacando os modelos e variáveis que demonstraram maior eficácia na previsão da turbidez está apresentado na Figura 14.

Tabela 14 – Resultados das análises de regressão para Turbidez

Variável	Modelo	Pearson	MAPE	RMSE	Outliers
banda665/banda739	Polinomial	0,70	0,74	0,92	Com Outliers
banda665/banda739	Quadrática	0,69	0,76	0,94	Com Outliers
banda665/banda739	Quadrática	0,65	0,63	0,94	Sem Outliers
banda665/banda704	Quadrática	0,65	0,60	0,99	Sem Outliers
banda665/banda704	Polinomial	0,65	0,59	0,98	Sem Outliers
banda559	Linear	0,64	0,87	1,13	Com Outliers
banda665/banda739	Polinomial	0,64	0,61	0,94	Sem Outliers
banda665/banda833	Polinomial	0,64	0,75	0,97	Com Outliers
banda665/banda833	Quadrática	0,63	0,65	1,00	Sem Outliers
banda665/banda833	Polinomial	0,63	0,61	0,96	Sem Outliers

Fonte: Do autor (2025).

A análise dos dados apresentados na Tabela 14 permite observar que as razões de bandas espectrais com modelos polinomiais e quadráticos demonstraram um desempenho significativo na predição dos parâmetros de qualidade da água. De acordo com Chowdhury *et al.* (2023), para mapear a turbidez, verificou-se que os algoritmos de duas bandas, baseados na razão azul e vermelha (ou seja, 412/620, 443/670) ou na razão verde e vermelho (ou seja, 510/681), bem como os algoritmos de três bandas, são as escolhas mais preferíveis para a estimativa de turbidez.

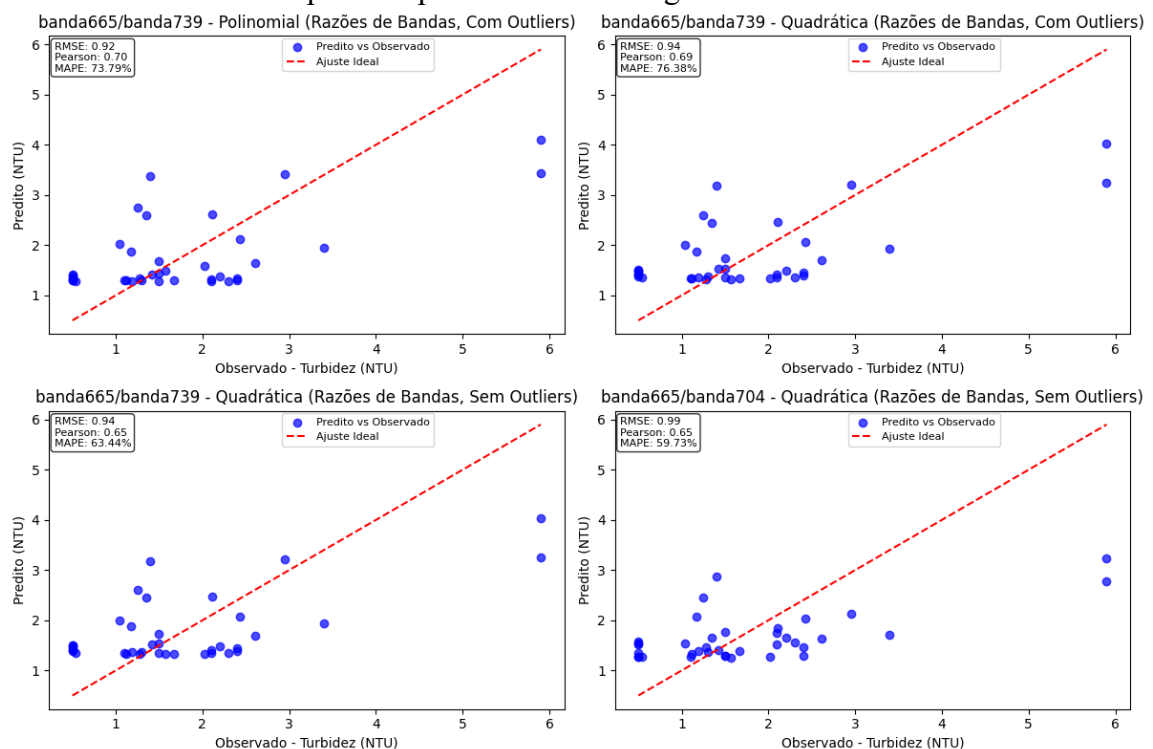
Os autores Chowdhury *et al.* (2023) e Pisanti *et al.* (2022) destacam que algumas bandas do Sentinel-2, como B3 (verde – 560 nm), B4 (vermelho – 665 nm) e B5 (red-edge – 705 nm), apresentam uma forte correlação com a concentração de turbidez em corpos d'água. Isso ocorre porque essas bandas capturam diferentes aspectos do comportamento da luz na água, permitindo estimar a concentração de sólidos em suspensão (turbidez). A combinação de diferentes bandas espectrais, por meio das chamadas razões de bandas, pode aprimorar ainda mais a estimativa de turbidez. Essas razões aumentam a sensibilidade a características específicas da água, minimizando o impacto de variáveis externas, como variações na profundidade ou no tipo de fundo aquático.

Ainda nesse contexto, o modelo de regressão linear aplicado à banda 559, que apresentou um coeficiente de correlação de 0,64, um MAPE de 0,87 e um RMSE de 1,13, sugere que determinadas bandas individuais podem ter potencial na modelagem dos parâmetros de interesse, embora seu desempenho tenha sido inferior ao das razões de bandas. Essa observação reforça a relevância da escolha criteriosa das variáveis espectrais para a construção de modelos mais robustos.

Em comparação, Hossain *et al.* (2021), que utilizaram imagens do Landsat 8 para estimar a turbidez no Rio Tennessee, obtiveram melhores resultados, com a faixa vermelha (0,640) apresentando o melhor desempenho para desenvolver o modelo de estimativa de turbidez.

A Figura 21 ilustra os quatro melhores modelos de regressão aplicados para a predição de turbidez, comparando os valores observados nas diferentes campanhas amostrais com os valores preditos.

Figura 21 – Comparação entre os valores de turbidez observados nas diferentes campanhas amostrais e preditos pelas análises de regressão



Fonte: Do autor (2025).

5.5.2.2 Aprendizado de máquinas

Para obtenção do melhor modelo para estimar turbidez a partir de dados espectrais obtidos das imagens Sentinel, foram testadas diversas combinações de variáveis espectrais, e avaliadas três abordagens distintas: o uso de bandas individuais, razões de bandas e a combinação de todas as bandas espectrais. Os modelos de aprendizado de máquina *Random Forest*, *Decision Tree* e *SVM* foram aplicados com o objetivo de identificar as melhores combinações de variáveis espectrais e os ajustes mais precisos. As análises consideraram tanto os dados completos quanto os tratados para a remoção de outliers, utilizando métricas como o

coeficiente de correlação de Pearson, o Erro Percentual Absoluto Médio (MAPE) e a Raiz do Erro Médio Quadrático (RMSE) para avaliar o desempenho dos modelos, e um resumo dos melhores resultados obtidos nos modelos de aprendizagem de máquina estão na Tabela 15.

Tabela 15 – Resultados dos modelos de aprendizagem de máquinas para Turbidez

Variável	Modelo	Pearson	MAPE	RMSE	Outliers
Todas as Bandas	<i>Random Forest</i>	0,77	0,51	0,78	Sem Outliers
banda559	<i>SVM</i>	0,64	0,65	1,30	Com Outliers
banda665/banda739	<i>SVM</i>	0,61	0,69	1,00	Com Outliers
banda665/banda704	<i>SVM</i>	0,59	0,57	1,06	Sem Outliers
banda492/banda559	<i>Decision Tree</i>	0,59	0,65	1,49	Com Outliers
banda665/banda739	<i>Random Forest</i>	0,59	0,66	1,08	Sem Outliers
Todas as Bandas	<i>Decision Tree</i>	0,58	0,70	1,17	Sem Outliers
banda492	<i>SVM</i>	0,58	0,65	1,30	Com Outliers
banda492	<i>Random Forest</i>	0,58	0,59	1,04	Sem Outliers
banda492/banda559	<i>Random Forest</i>	0,57	0,64	1,14	Com Outliers

Fonte: Do autor (2025).

Os resultados indicam que o modelo *Random Forest* aplicado a todas as bandas apresentou o melhor desempenho geral, com um coeficiente de correlação de Pearson (r) de 0,77, um MAPE de 0,51 e um RMSE de 0,78, na ausência de outliers. Esse resultado destaca a eficácia dos modelos baseados em aprendizado de máquina na identificação de padrões complexos nos dados espectrais, especialmente quando todas as variáveis disponíveis são consideradas (Ma *et al.*, 2021).

Os autores Kong *et al.*, (2023), em um estudo sobre turbidez da água costeira utilizando Sentinel-2 em Los Angeles, utilizaram diversos modelos de aprendizado de máquina, incluindo Random Forest (RF) e regressão linear simples (SLR), para estimar a turbidez. O *Random Forest* (RF) se destacou como o modelo de melhor desempenho. De acordo com os autores, o desempenho superior do RF pode ser atribuído à sua eficácia em capturar relações complexas entre dados de turbidez *in situ* e dados derivados de satélite, o que é crucial devido à alta variabilidade espacial e temporal dos indicadores de qualidade da água. Ao contrário de modelos como a regressão linear, o RF não faz suposições rígidas sobre a forma dessa relação, permitindo modelar de forma mais eficaz as interações complexas entre os dados.

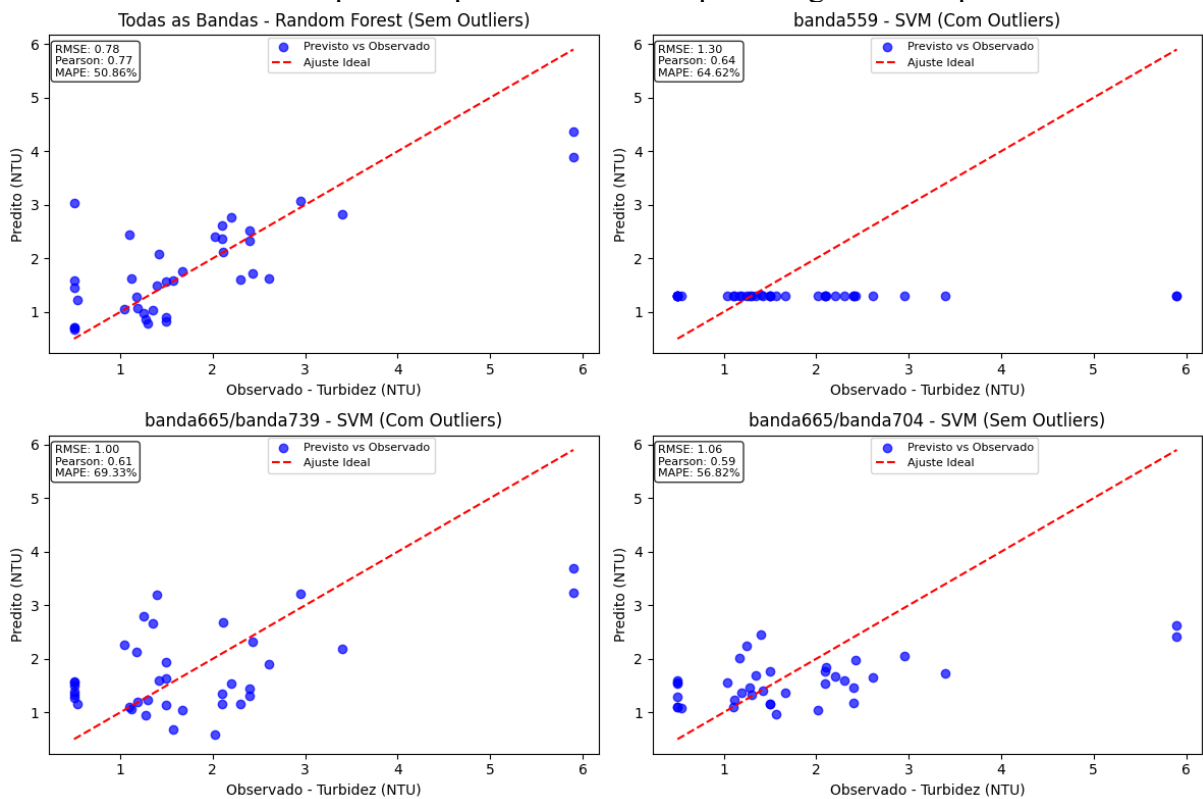
Entre os modelos que utilizaram bandas individuais ou razões de bandas, o Support Vector Machine (SVM) aplicado à banda 559 obteve um coeficiente de correlação de 0,64, um MAPE de 0,65 e um RMSE de 1,30, apesar da presença de outliers. Esse resultado sugere que a banda 559 contém informações relevantes para a estimativa da turbidez, mesmo com a

interferência de valores extremos. De maneira similar, a razão de bandas 665/739 apresentou um coeficiente de correlação de 0,61 quando modelada com SVM, reforçando que determinadas combinações espectrais podem melhorar a acurácia da predição.

Além disso, o modelo *Decision Tree* utilizando todas as bandas obteve um coeficiente de correlação de 0,58, um MAPE de 0,70 e um RMSE de 1,17, indicando que, embora tenha sido inferior ao *Random Forest*, ainda demonstrou um desempenho razoável. Esse resultado reforça que técnicas baseadas em árvores de decisão podem apresentar variações significativas conforme a complexidade do modelo e a presença de múltiplas variáveis.

A Figura 22 ilustra os quatro melhores modelos de aprendizado de máquina aplicados para a predição de turbidez, comparando os valores observados nas diferentes campanhas amostrais com os valores preditos.

Figura 22 – Comparação entre os valores de turbidez observados nas diferentes campanhas amostrais e preditos pelos modelos de aprendizagem de máquina.



Fonte: Do autor (2025).

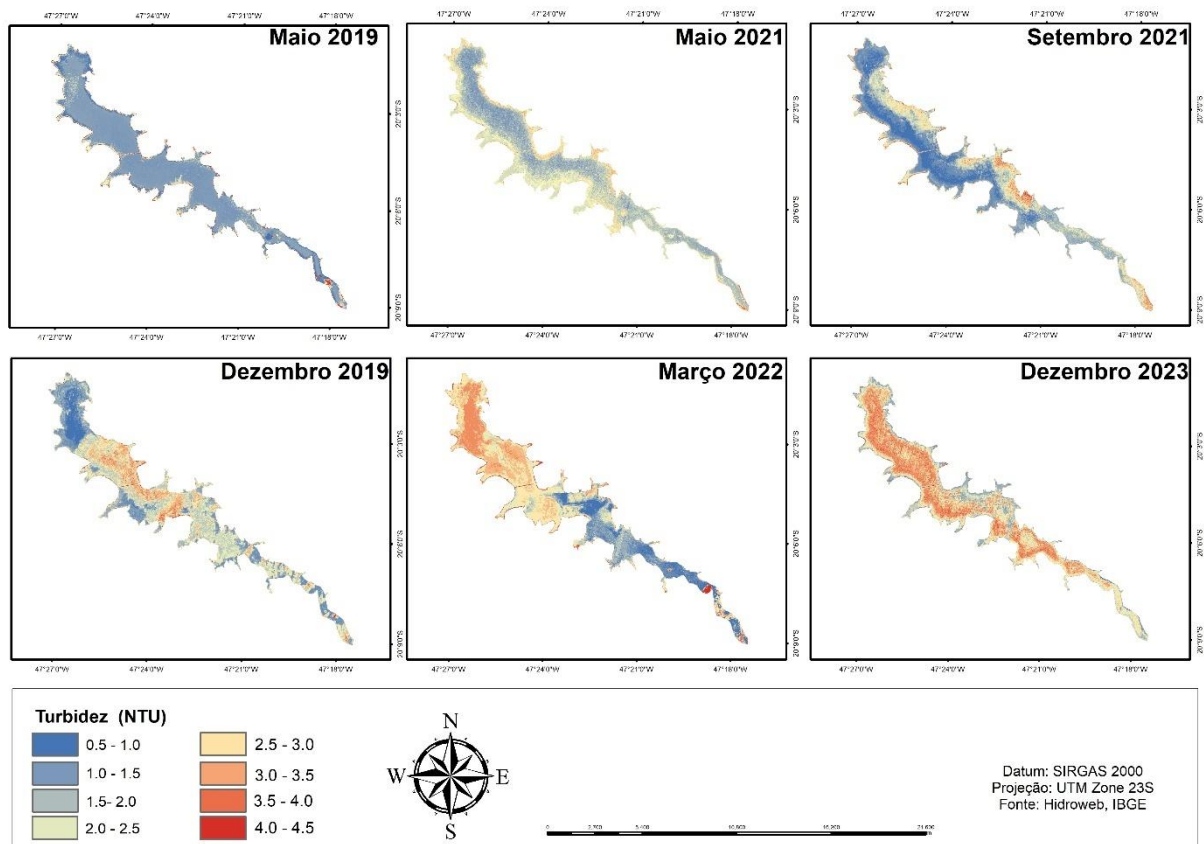
5.5.2.3 Mapa de estimativa

Com base nas análises realizadas, o modelo *Random Forest* utilizando todas as bandas foi identificado como o mais eficiente para prever a turbidez. Dessa forma, ele foi aplicado na

geração de mapas preditivos, proporcionando uma representação espacial detalhada dos valores estimados.

Na Figura 23 está apresentada a distribuição espacial dos valores de turbidez predita pelo modelo, considerando diferentes campanhas selecionadas com base na sazonalidade. Esses mapas permitem visualizar padrões de variação ao longo do tempo, auxiliando na compreensão dos impactos ambientais e das dinâmicas hidrológicas do reservatório.

Figura 23 – Predição de valores de turbidez pelo modelo *Random Forest* com todas as bandas para o reservatório da usina hidrelétrica de Jaguara em diferentes datas.



Fonte: Do autor (2025).

A Figura 23 ilustra as variações temporais e espaciais da turbidez, destacando os períodos de maior instabilidade na qualidade da água, como observado em março de 2022 e dezembro de 2023, quando as cores alaranjadas e vermelhas predominam, indicando valores superiores a 3,5 NTU. Esses picos de turbidez podem estar associados a fatores como chuvas intensas e processos erosivos. Assim, o modelo preditivo utilizado para a previsão dos dados de turbidez demonstrou resultados interessantes, evidenciando a capacidade do modelo em capturar as variações temporais e espaciais da turbidez, especialmente nos períodos de maior instabilidade na qualidade da água

De acordo com a Figura 23, as campanhas realizadas em março de 2022, dezembro de 2019 e dezembro de 2023 mostram valores elevados na coloração laranja, indicando picos de turbidez. Esses picos, atribuídos a chuvas intensas e processos erosivos, refletindo a precisão do modelo. Esses resultados são consistentes com os estudos de Dörnhöfer *et al.* (2016), que relacionam o aumento da turbidez ao escoamento superficial causado por chuvas intensas, e de Fassoni-Andrade *et al.* (2017), que associam a turbidez elevada a processos erosivos nas bacias hidrográficas, reforçando a confiabilidade do modelo na detecção de variações ligadas a fatores naturais, como o transporte de sedimentos.

Ainda observando a Figura 23, os mapas indicam que, em maio de 2019 e maio de 2021, a turbidez manteve-se predominantemente baixa, com valores entre 0,5 e 1,0 NTU, sugerindo um ambiente aquático estável e com reduzida carga de sedimentos em suspensão. Esse comportamento é corroborado por Ma *et al.* (2021), que identificaram uma turbidez estável em ambientes menos impactados, com valores baixos durante períodos secos.

Outro fator que pode ser atribuído aos elevados valores de turbidez são fatores além das chuvas. A intensificação da turbidez no final de 2023, em comparação com anos anteriores, pode ser atribuída a processos erosivos mais intensos, favorecidos por mudanças no uso da terra. Isso é corroborado pelos estudos de Fassoni-Andrade *et al.* (2017) e Zhu *et al.* (2022), que correlacionaram alterações no uso do solo com o aumento de sedimentos na água.

Durante a campanha de campo realizada em março de 2022, os maiores valores de turbidez foram registrados nos pontos 4 (5,3 NTU), 5 (10,7 NTU) e 6 (6,4 NTU). Esses resultados estão em boa concordância com as estimativas obtidas nos mapas preditivos, evidenciando a precisão do modelo utilizado. De maneira semelhante, Ma *et al.*, (2021) aplicaram modelos de regressão de aprendizado profundo para prever a turbidez nos rios da China, destacando a eficácia desses modelos em lidar com grandes volumes de dados e capturar relações não lineares e complexas, como as observadas nos picos de turbidez registrados em dezembro de 2023.

6 CONCLUSÃO

Este estudo demonstrou resultados promissores ao combinar os dados espectrais do Sentinel-2 com algoritmos de aprendizado de máquina, abrindo possibilidades para a previsão de parâmetros de qualidade da água, como Sólidos Dissolvidos Totais (SDT), Sólidos Totais (ST) e Turbidez no reservatório da UHE Jaguará. Os modelos de aprendizado de máquina, especialmente o *Random Forest* e a *Decision Tree*, se destacaram em cenários com alta variabilidade e presença de outliers, superando os modelos de regressão tradicionais. O modelo *Random Forest* apresentou um bom desempenho para a previsão de SDT, especialmente ao utilizar a banda SWIR (2186 nm). Para os ST, a combinação da razão de bandas 559/864 com a *Decision Tree* foi a mais eficaz, enquanto para a Turbidez, o modelo *Random Forest* usando todas as bandas espectrais obteve a maior precisão.

A análise espacial dos mapas preditivos validou os dados de campo, evidenciando que as maiores concentrações de Sólidos Dissolvidos Totais (SDT), Sólidos Totais (ST) e turbidez ocorreram predominantemente durante as estações chuvosas, com maior destaque nas áreas de entrada de água do reservatório. A implementação dos modelos de predição nos mapas, considerando as diferentes estações do ano, ou seja, períodos com maior e menor incidência de chuvas, demonstrou que os modelos foram eficazes, apresentando bom desempenho na identificação e quantificação das variações temporais e espaciais da qualidade da água, conseguindo discriminar adequadamente as flutuações induzidas por fatores naturais e antrópicos.

A aplicação dessas técnicas no reservatório da UHE Jaguará mostra grande potencial para expansão para outros reservatórios tropicais, particularmente em áreas com condições hidrológicas variadas. Futuras pesquisas poderiam explorar o uso de redes neurais profundas (*deep learning*) para melhorar a modelagem da qualidade da água, especialmente em cenários mais complexos. A comparação de dados de diferentes satélites de sensoriamento remoto, como o Landsat, também seria interessante para avaliar qual tecnologia oferece os melhores resultados em termos de resolução espacial e temporal. Por fim, a implementação de um sistema de monitoramento contínuo em tempo real, utilizando essas técnicas de modelagem, seria um avanço significativo na gestão dos recursos hídricos, permitindo respostas mais rápidas a possíveis eventos de poluição ou deterioração da qualidade da água.

7 REFERÊNCIAS

ABBAS, M. M.; MELESSE, A.M.; SCINTO, L. J.; REHAGE, J.S. Satellite Estimation of Chlorophyll-a Using Moderate Resolution Imaging Spectroradiometer (MODIS) Sensor in Shallow Coastal Water Bodies: Validation and Improvement. **Water**. v.11. 2019. <https://doi.org/10.3390/w11081621>.

ABDELMALIK, K. W. Role of statistical remote sensing for inland water quality parameters prediction. **The Egyptian Journal of Remote Sensing and Space Science** v. 21(2), p. 193–200. 2018. <https://doi.org/10.1016/j.ejrs.2016.12.002>.

ACOLITE (2021) <https://odnature.naturalsciences.be/remsem/software-and-data/acolite>

ADJOVU, G. E.; STEPHEN, H.; JAMES, D.; AHMAD, S. Overview of the Application of Remote Sensing in Effective Monitoring of Water Quality Parameters. **Remote Sens**. v. 15. 2023. <https://doi.org/10.3390/rs15071938>.

ADJOVU, G. E., SHAIKH, T. A., STEPHEN, H., & AHMAD, S. Utilization of machine learning models and satellite data for the estimation of total dissolved solids in the Colorado River system. **In World Environmental and Water Resources Congress 2023** p. 899–908. American Society of Civil Engineers. <https://doi.org/10.1061/9780784484258.106>.

ALBERT, A., GEGER, P. Inversion of irradiance and remote sensing reflectance in shallow water between 400 and 800 nm for calculations of water and bottom properties. **Applied Optics**, v. 45(10). 2006. <https://doi.org/10.1364/AO.45.002331>.

ALCÂNTARA, E., CURTARELLI, M., STECH, J. Estimating total suspended matter using the particle backscattering coefficient: results from the Itumbiara hydroelectric reservoir (Goiás State, Brazil). **Remote Sensing Letters**. v.7(4). p.397–406. 2016. <https://doi.org/10.1080/2150704X.2015.1137646>.

AL-FAHDAWI, A. A. H.; RABEE, A. M.; AL-HIRMIZY, S. M. Water quality monitoring of Al-Habbaniyah Lake using remote sensing and in situ measurements. **Environmental Monitoring and Assessment**. v. 187. 2015. <https://doi.org/10.1007/s10661-015-4607-2>.

AL-THANI, J. SOLIMAN, Y. AL-MASLAMANI, I. YIGITERHAN, O. AL-ANSARI, E, M. A. S. Physical drivers of chlorophyll and nutrients variability in the Southern-Central Arabian Gulf. **Estuarine, Coastal and Shelf Science**. v. 283(5). 2023. <https://doi.org/10.1016/j.ecss.2023.108260>.

AMERICAN PUBLIC HEALTH ASSOCIATION (APHA). (2017) **Standard Methods for the Examination of Water and Wastewater**. 23. ed. Washington, D.C.: APHA.

ANSPER, A.; ALIKAS, K. Retrieval Of Chlorophyll A From Sentinel-2 Msi Data For The European Union Water Framework Directive Reporting Purposes. **Remote Sens.**, v.11(64). 2019. <https://doi.org/10.3390/rs11010064>.

ARANGO, J. G.; NAIRN, R. W. Prediction of Optical and Non-Optical Water Quality Parameters in Oligotrophic and Eutrophic Aquatic Systems Using a Small Unmanned Aerial System. **Drone**, v. 4, n. 1. 2020. <https://doi.org/10.3390/drones4010001>.

ASSIS, L. F. F. G; FERREIRA, K, R; VINHAS, L; MAURANO, L; ALMEIDA, C; CARVALHO, A; RODRIGUES, J; MACIEL, CAMARGO, C. Terra Brasilis: A Spatial Data Analytics Infrastructure for Large-Scale Thematic Mapping. **International journal of geo-information**. v. 8. 2019. <https://doi.org/10.3390/ijgi8110513>.

ASTUTI, I. S., MISHRA, D. R., MISHRA, S., SCHAEFFER, B. Spatio-temporal dynamics of inherent optical properties in oligotrophic northern Gulf of Mexico estuaries. **Continental Shelf Research**. V. 166. p. 92–107. 2018. <https://doi.org/10.1016/j.csr.2018.06.016>.

AVDAN, Z. Y., G. KAPLAN, S. GONCU, U. AVDAN. Monitoring the water quality of small water bodies using high-resolution remote sensing data. **ISPRS International Journal of Geo-Information**. V. 8(12). 2019. <https://doi.org/10.3390/ijgi8120553>.

BALASUBRAMANIAN, S. V., PAHLEVAN, N., SMITH, B., BINDING, C., SCHALLES, J., LOISEL, H., GURLIN, D., GREB, S., ALIKAS, K., RANDLA, M. Robust algorithm for estimating total suspended solids (TSS) in inland and nearshore coastal waters. **Remote Sensing of Environment**, v. 246. 2020. <https://doi.org/10.1016/j.rse.2020.111768>.

BARBOSA, C., NOVO, E., MARTINS, V. **Introdução ao Sensoriamento Remoto de Sistemas Aquáticos: princípios e aplicações**. (1ª ed.). São José dos Campos: Instituto Nacional de Pesquisas Espaciais. 2019.

BARCELLOS, D. S. SOUZA, F. T. Optimization of water quality monitoring programs by data mining. **Water Research**. v. 221. 2022. DOI: 10.1016/j.watres.2022.118805.

BERTONE, E; HUGHES, S. P Probabilistic Prediction of Satellite-Derived Water Quality for a Drinking Water Reservoir. **Sustainability**. v. 15. 2023. <https://doi.org/10.3390/su151411302>.

BLASCHKE, T; HERMANN KUX, H. **Sensoriamento Remoto e SIG Avançados novos sistemas sensores, métodos inovadores**. 2. ed. São Paulo: Oficina de Textos, 2007.

BORGES, A. F. S.; LAURINDO, F. J. B.; SPÍNOLA, M. M.; GONÇALVES, C. A. M. The strategic use of artificial intelligence in the digital era: systematic literature review and future research directions. **International Journal Of Information Management**. v. 57, n. 1, p. 1-16. 2021. <https://doi.org/10.1016/j.ijinfomgt.2020.102225>.

BRASIL (1997). Lei no 9.433, de 08 de janeiro de 1997. Institui a Política Nacional de Recursos Hídricos, cria o Sistema Nacional de Gerenciamento de Recursos Hídricos, regulamenta o inciso XIX do art. 21 da Constituição Federal, e altera o art. 1º da Lei no 8.001, de 13 de março de 1990, que modificou a Lei no 7.990, de 28 de dezembro de 1989.

BREZONIK, P. L., OLMANSON, L. G., FINLAY, J. C., BAUER, M. E. Factors affecting the measurement of CDOM by remote sensing of optically complex inland waters. **Remote Sensing of Environment**. v. 157, p. 199–215. 2015. <https://doi.org/10.1016/j.rse.2014.04.033>.

BREIMAN, L. **Random forests**. **Machine learning**, v. 45.1, p. 27, 2001.

BRITO, H. C.; VASCONCELOS, R. S.; RUFINO, I. A. A.; BRITO, Y. M. A. Uso de sensoriamento remoto para monitoramento de parâmetros de qualidade de água no Rio Doce, Minas Gerais, Brasil. **Caminhos de Geografia**, v. 23, n. 90, p. 108–119. 2022. <https://doi.org/10.14393/RCG239060922>.

BROCKMANN, C., DOERFFER, R., Evolution of the C2RCC neural network for Sentinel 2 and 3 for the retrieval of ocean colour products in normal and extreme optically complex waters. **In: Living Planet Symposium**. ESA, Prague, Czech Republic 2016.

BUTLER, B.A.; FORD, R.G. Evaluating Relationships between Total Dissolved Solids (TDS) and Total Suspended Solids (TSS) in a Mining-Influenced Watershed. **Mine Water Environ.** v. 31, p. 18–30. 2018. <https://doi.org/10.1007/s10230-017-0484-y>.

CAI, X. WU, L. LI, Y. LEI, S. XU, J. J. LYU, H. LI, J. WANG, H. DONG, X. ZHU, Y. WANG. Remote sensing identification of urban water pollution source types using hyperspectral data. **Journal of Hazardous Materials.** v. 459. 2023. <https://doi.org/10.1016/j.jhazmat.2023.132080>.

CALLEGARI-JACQUES, S. M. **Bioestatística: Princípios e Aplicações**. Porto Alegre: Artmed, 2003.

CAO, Z. HU, C. MA, R. DUAN, H. LIU, M. LOISELLE, S. SONG, K. SHEN, M. LIU, D. XUE, K. MODIS observations reveal decrease in lake suspended particulate matter across China over the past two decades. **Remote Sensing of Environment** v. 295. 2023a. DOI:10.1016/j.rse.2023.113724.

CAO, X. ZHANG, J. MENG, H. LAI, Y. XU, M. Remote sensing inversion of water quality parameters in the Yellow River Delta. **Ecological Indicators.** v.155. 2023b. <https://doi.org/10.1016/j.ecolind.2023.110914>.

FERREIRA, W. J.; SUSZEK, E. B.; DOMINGUES, S. P.; CEZAR, V. R. S.; SILVA, R. C.; TARGA, M. S. Impactos das atividades antrópicas na qualidade da água e dinâmica hidrológica da bacia do rio Areal, Taubaté-SP. *Revista Técnica Ciências Ambientais*, v. 1, n. 8, p. 123–134, 2024.

CARVALHO, L. M. T.; SCOLFORO, J. R **Inventário florestal de Minas Gerais: monitoramento da flora nativa**. Lavras, MG: UFLA, 2008.

CETESB – Companhia Ambiental do Estado de São Paulo. **Relatório de qualidade das águas superficiais**. Significado ambiental e sanitário das variáveis de qualidade - Apêndice D, 2015.

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. 2020. <https://doi.org/10.1016/j.jhydrol.2020.124826>.

CHAPMAN, D. V. SULLIVAN, T. The role of water quality monitoring in the sustainable use of ambient waters. **One Earth** v 5, (2), p. 132-137. 2022. <https://doi.org/10.1016/j.oneear.2022.01.008>

CHEN, X.; LIU, L.; ZHANG, X.; LI, J.; WANG, S.; LIU, D.; DUAN, H.; SONG, K. An Assessment of Water Color for Inland Water in China Using a Landsat 8-Derived Forel-Ule Index and the Google Earth Engine Platform. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* v. 14, p. 5773–5785. 2021. DOI: 10.1109/JSTARS.2021.3085411.

CHEN, F., G. WU, J. WANG, J. HE, E Y. WANG (2016). A MODIS-based retrieval model of suspended particulate matter concentration for the two largest freshwater lakes in China. **Sustainability**. v. 8(8). 2016. <https://doi.org/10.3390/su8080832>.

CHEN, J; HAN, Q; YANLONG CHEN, Y; YONGDONG LI, Y. A Secchi depth algorithm considering the residual error in satellite remote sensing reflectance data. **Remote Sensing**, v. 11, n. 16, 2019. <https://doi.org/10.3390/rs11161948>.

CHOI, R, Y; COYNER, A. S; KALPATHY-CRAMER, J. K; MICHAEL F. CHIANG, M. F; CAMPBELL, J. P. Introduction to machine learning, neural networks, and deep learning. **Translational Vision Science & Technology**. The Association for Research in Vision and Ophthalmology, v. 9, n. 2, p. 14–14, 2020. doi: 10.1167/tvst.9.2.14.

CHOU, J.-S., HO, C.-C., HOANG, H.-S. Determining quality of water in reservoir using machine learning. **Ecological Informatics**. v. 44. p. 57–5. 2018. <https://doi.org/10.1016/j.ecoinf.2018.01.005>.

CHOWDHURY, M., VILAS, C., VAN BERGEIJK, S., NAVARRO, G., LAIZ, I., & CABALLERO, I. Monitoring turbidity in a highly variable estuary using Sentinel 2-A/B for ecosystem management applications. **Frontiers in Marine Science**. v. 10. 2023. <https://doi.org/10.3389/fmars.2023.1186441>.

CHU, H.-J.; KONG, S.-J.; CHANG, C.-H. Spatio-temporal water quality mapping from satellite images using geographically and temporally weighted regression. **International Journal of Applied Earth Observation and Geoinformation**. v. 65, p. 1–11. 2018. <https://doi.org/10.1016/j.jag.2017.10.001>.

COELHO, C., B. HEIM, S. FOERSTER, A. BROSINSKY, E J. C. ARAÚJO. In situ and satellite observation of CDOM and chlorophyll-a dynamics in small water surface reservoirs in the Brazilian semiarid region. **Water**. v. 9(12). 2017. <https://doi.org/10.3390/w9120913>.

CRASTO, N.; HOPKINSON, C.; FORBES, D.L.; LESACK, L.; MARSH, P.; SPOONER, I.; VAN DER SANDEN, J.J. A LiDAR-based decision-tree classification of open water surfaces in an Arctic delta. **Remote Sens. Environ.** v. 164. p. 90–102. 2015. <https://doi.org/10.1016/j.rse.2015.04.011>.

CURTARELLI, V. P. BARBOSA, C. C. F. MACIEL, D. A. JÚNIOR, R. F. CARLOS, F. M. NOVO, E. M. L. M. CURTARELLI, M. P. SILVA, E. F. F. Diffuse Attenuation of Clear Water Tropical Reservoir: A Remote Sensing Semi-Analytical Approach. **Remote Sens**. v. 12. 2020. <https://doi.org/10.3390/rs12172828>.

DEWIDAR, K., EZABY, K. E., DAYM, H. A., & IBRAHIM, M. Mapping some water quality parameters by using Landsat-7 ETM+ for Manzala Lagoon, Egypt. **Environmental Sciences & Technology Conference**, Cairo, Egypt, p. 1–16. 2008.

DIAS, R. L. S., DA SILVA, D. D., FERNANDES-FILHO, E. I., DO AMARAL, C. H., DOS SANTOS, E. P., MARQUES, J. F., VELOSO, G. V. Machine learning models applied to TSS estimation in a reservoir using multispectral sensor onboard to RPA. **Ecological Informatics**, v. 65. 2021. <https://doi.org/10.1016/j.ecoinf.2021.101414>.

DOXARAN, D., FROIDEFOND, J.-M., CASTAING, P., BABIN, M. Dynamics of the Turbidity Maximum Zone in a Macrotidal Estuary (the Gironde, France): Observations from Field and MODIS Satellite Data. **Estuarine, Coastal and Shelf Science**. v. 81. p. 321–332. 2009. DOI: 10.1016/j.ecss.2008.11.013.

DÖRNHÖFER, K.; GÖRITZ, A.; GEGER, P.; PFLUG, B.; OPPELT, N. Water constituents and water depth retrieval from Sentinel-2A-a first evaluation in an oligotrophic lake. **Remote Sensing**, v. 8, n. 11, p. 941-976. 2016. <https://doi.org/10.3390/rs8110941>.

DUBE, T.; MUTANGA, O.; SEUTLOALI, K.; ADELABU, S.; SHOKO, C. Water quality monitoring in sub-Saharan African lakes: A review of remote sensing applications. **African Journal of Aquatic Science**. v. 40. p. 1–7. 2015. DOI:10.2989/16085914.2015.1014994.

DU, C; WANG, Q; LI, Y; LYU, H; ZHU, L; ZHENG, Z; WEN, S; LIU, G; GUO, Y. Estimation of total phosphorus concentration using a water classification method in inland water. **International Journal of Applied Earth Observation and Geoinformation**. v.71. p. 29-42. 2018. <https://doi.org/10.1016/j.jag.2018.05.007>.

DU, Y; ZHANG, Y; LING, F; WANG, Q; WENBO LI, W; XIAODONG LI, X. 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. 2016. <https://doi.org/10.3390/rs8040354>. <https://doi.org/10.3390/rs8040354>.

ENGCHUAN, W; DIMOPOULOS, A. C; STEFANOS TYROVOLAS, S; CABALLERO, F. F; SANCHEZ-NIUBO, A. S; ARNDT, H; AYUSO-MATEOS, J. L; MARIA HARO, J.; SOMNATH CHATTERJI, S; DEMOSTHENES B. PANAGIOTAKOS, D. B. Sociodemographic indicators of health status using a machine learning approach and data from the english longitudinal study of aging (ELSA). **Medical Science Monitor**, v. 25, p. 1994–2001. 2019. doi: 10.12659/MSM.913283.

ENERGIA, E. B. ENGIE **Energia**. Disponível em: <https://www.engie.com.br/usinas/usina-hidreletrica-jaguara/> Acesso em: 21 set. 2024.

ESA (2021). Sentinel-2 MSI User Guide. <<https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi>>. ESA - **European Space Agency**.

FAROUK, M. I. H. JAMIL, Z. LATIP, M. F. A. Towards online surface water quality monitoring technology: A review. **Environmental Research**. v. 238. 2023. <https://doi.org/10.1016/j.envres.2023.117147>.

FASSONI-ANDRADE, A. C.; PAIVA, R. C. D. Mapping spatial-temporal sediment dynamics of river-floodplains in the Amazon. **Remote Sensing of Environment**, v. 221. p. 94-107. 2019. <https://doi.org/10.1016/j.rse.2018.10.038>.

FENG, L.; HU, C.; HAN, X.; CHEN, X.; QI, L. Long-Term Distribution Patterns of Chlorophyll-a Concentration in China's Largest Freshwater Lake: MERIS Full-Resolution Observations with a Practical Approach. **Remote Sens**. v. 7. p. 275–299. 2014. <https://doi.org/10.3390/rs70100275>.

FERRÁNDEZ-PASTOR, F., GARCÍA-CHAMIZO, J., NIETO-HIDALGO, M. Electromagnetic Differential Measuring Method: Application in Microstrip Sensors Developing. **Sensors**. v.17(7). 2017. DOI: 10.3390/s17071650.

FERNANDES, A. C. P., DE OLIVEIRA MARTINS, L. M., PACHECO, F. A. L., FERNANDES, L. F. S. The consequences for stream water quality of long-term changes in landscape patterns: Implications for land use management and policies. **Land Use Policy**. v. 109, 105679. 2021.

FERREIRA, R. G., SILVA, D. D. ELESBON, A. A. A., FERNANDES-FILHO, E. I., VELOSO, G. V., FRAGA, M. S., FERREIRA, L. B. Machine learning models for streamflow regionalization in a tropical watershed. **Journal of Environmental Management**. v. 28 (9) 2021. <https://doi.org/10.1590/1807-1929/agriambi.v28n9e276836>.

FIGUEIREDO, A. V.; BECKER, V.; MATTOS, A. O efeito da seca prolongada na qualidade da água do reservatório Gargalheiras na região tropical semiárida. In: **SIMPÓSIO DE RECURSOS HÍDRICOS DO NORDESTE – XII SRHNE**, 2014, Natal – RN. Anais [...]. Natal: ABRH, ISSN 2359-1900. 2014.

FRAGA, R. S., GUEDES, H. A. S., MARTINS, V. S., CABALLERO, C. B., MENDES, K. G. P., MONKS, J. L. F., FASSONI-ANDRADE, A. C. Empirical modelling of suspended solids in a subtropical lagoon (Brazil) using linear spectral mixing algorithm. **Remote Sensing Applications: Society and Environment**. v. 15(11). 2020. <https://doi.org/10.3390/rs15112822>.

FRANÇA, J. M. B. DE, MONTEIRO, C. M. G., SILVA, S. M. O. DA, PAULINO, W. D., & NETO, J. C. Qualidade da água em um sistema de reservatórios em cascata – um estudo de caso no semiárido brasileiro. **Engenharia Sanitária e Ambiental**. v. 27(1), p.113-123. 2022. <https://doi.org/10.1590/S1413-415220200328>.

FRANZ, B.A.; BAILEY, S.W.; KURING, N.; WERDELL, P.J. Ocean Color Measurements from Landsat-8 OLI using SeaDAS. **In Proceedings of the Ocean Optics XXII**, Portland, MA, USA. p. 26–31. 2014.

FENG, L. YOU, Y. LIAO, W. PANG, J. HU, R. FENG, L. Multi-scale change monitoring of water environment using cloud computing in optimal resolution remote sensing images. **Energy Reports**. v. 8, 2022, p.13610-13620. 2022. <https://doi.org/10.1016/j.egyr.2022.09.134>.

GAIDA, W.; BREUNIG, F. M.; GALVÃO, L. S.; PONZONI, F. J. Correção Atmosférica em Sensoriamento Remoto: Uma Revisão. **Revista Brasileira de Geografia Física**, v. 13, n. 01, p. 229-248, 2020. DOI: 10.26848/rbgf.v13.1.p229-248.

GASCON, F.; BOUZINAC, C.; THÉPAUT, O.; JUNG, M.; FRANCESCONI, B.; LOUIS, J.; LONJOU, V.; LAFRANCE, B.; MASSERA, S.; GAUDEL-VACARESSE, A. Copernicus Sentinel-2 Calibration and Products Validation Status. **Remote Sensing**, v. 9, n. 6. 2017. <https://doi.org/10.3390/rs9060584>.

GEEKSFORGEES. Introduction to Support Vector Machine (SVM). GeeksforGeeks, 2024. Disponível em: <https://www.geeksforgeeks.org/introduction-to-support-vector-machine/>. Acesso em: 24 maio. 2025

GHOLIZADEH, M. H.; MELESSE, A.M.; REDDI, L. A Comprehensive Review on Water Quality Parameters Estimation Using Remote Sensing Techniques. **Sensors**, v. 16 .8. 2016. <https://doi.org/10.3390/s16081298>.

GOHER, E. M; HASSAN, A. M. ABDEL-MONIEM, I. A. FAHMY, A. H. EL-SAYED, S. M. Evaluation of surface water quality and heavy metal indices of Ismailia Canal, Nile River, Egypt. **The Egyptian Journal of Aquatic Research**, v. 40, n. 3. p. 225–233, 2014. <https://doi.org/10.1016/j.ejar.2014.09.00>.

GOMES, V. C. F., QUEIROZ, G. R., FERREIRA, K. R. An Overview of Platforms for Big Earth Observation Data Management and Analysis. **Remote Sensing**. v. 12(8). 2020. <https://doi.org/10.3390/rs12081253>.

GORGAN-MOHAMMADI, F.; RAJAEI, T.; ZOUNEMAT-KERMANI, M. Decision tree models in predicting water quality parameters of dissolved oxygen and phosphorus in lake water. **Sustainable Water Resources Management**, v. 9, n. 1, p. 1–12, 2023. <https://doi.org/10.1007/s40899-022-00776-0>.

GRAHAM, C. T. CONNOR, I. O. BRODERICK, L. BRODERICK, M. O. JENSEN, O. LALLY, H. T. Drones can reliably, accurately and with high levels of precision, collect large volume water samples and physio-chemical data from lakes. **Science of The Total Environment**. v. 824. 2022. <https://doi.org/10.1016/j.scitotenv.2022.153875>.

GRENDAIT, D. E. STONEVIUS, J. KAROSIEN, K. SAVADOVA, J. KASPEROVIEN. Chlorophyll-a concentration retrieval in eutrophic lakes in Lithuania from Sentinel-2 data. **Geologia. Geografia**, v. 4. 2018. DOI: <https://doi.org/10.6001/geol-geogr.v4i1.3720>.

GUNEROGLU, A.; KARSLI, F.; DIHKAN, M. Automatic detection of coastal plumes using Landsat TM/ETM+ images. *Int. J. Remote Sens.* v. 34, p. 4702–4714. 2013. DOI:10.1080/01431161.2013.782116.

GUO, X. HOU, B. YANG, C. MA, S. REN, B. WANG, S. JIAO, L. Visual explanations with detailed spatial information for remote sensing image classification via channel saliency.

International Journal of Applied Earth Observation and Geoinformation.

v.118, 2023, 103244. 2023a. <https://doi.org/10.1016/j.jag.2023.103244>.

GUO, H. ZHU, X. HUANG, J. J. ZHANG, Z. IAN, S. CHEN, Y. An enhanced deep learning approach to assessing inland lake water quality and its response to climate and anthropogenic factors. **Journal of Hydrology.** v.620, 129466. 2023b. DOI:10.1016/j.jhydrol.2023.129466.

HA, N. T. T., THAO, N. T. P., KOIKE, K., & NHUAN, M. T. Selecting the optimal band ratio for chlorophyll-a concentration estimation in a tropical freshwater lake using Sentinel 2A images: A case study of Lake Ba Be (Northern Vietnam). **ISPRS International Journal of Geo-Information.** V. 6(9), 290. 2017. <https://doi.org/10.3390/ijgi6090290>.

HALL, N. RUST, A. HOGUE, T. S. SINGHA, K. Analysis of watershed parameters controlling turbidity following the West Fork Complex fire. **Journal of Hydrology.** v. 609. 127712. 2022. <https://doi.org/10.1016/j.jhydrol.2022.127712>.

HELLWEGER, F.; SCHLOSSER, P.; LALL, U.; WEISSEL, J. Use of satellite imagery for water quality studies in New York Harbor. *Estuar. Coast.* **Shelf Sci.** v. 61, p. 437–448. 2004. <https://doi.org/10.1016/j.ecss.2004.06.019>.

HIJMANS, R. J. terra: Spatial Data Analysis. Versão 1.8-27. Acesso em: 10 de novembro de 2024. <https://rspatial.github.io/terra/>.

HOSSAIN, A. K. M. A., MATHIAS, C., BLANTON, R. Remote sensing of turbidity in the tennessee river using landsat 8 satellite. **Remote Sensing.** v. 13(18), 3785. 2021. <https://doi.org/10.3390/rs13183785>.

IDE-SISEMA. Infraestrutura de Dados Espaciais do Sistema Estadual de Meio Ambiente e Recursos Hídricos-MG. Mapeamento de solos Semad UFV. Dado em formato vetorial (shapefile).

INSTITUTO MINEIRO DE GESTÃO DAS ÁGUAS - IGAM. Qualidade das águas superficiais de Minas Gerais em 2013: Resumo Executivo. Belo Horizonte: 2014.

INMET, 2020. **Instituto Nacional de Meteorologia**. <http://www.inmet.gov.br/portal>.

INPE. Projeto Terra Class Cerrado. **Mapeamento do uso e Cobertura Vegetal do Cerrado**. 2017. Disponível online: <http://www.dpi.inpe.br/tccerrado/download>.

JAFARBIGLU, H. POURREZA, A. A comprehensive review of remote sensing platforms, sensors, and applications in nut crops. **Computers and Electronics in Agriculture**. v.197, 106844. 2022. <https://doi.org/10.1016/j.compag.2022.106844>.

JAVAID, M., HALEEM, A., RAB, S., PRATAP SINGH, R., SUMAN, R. Sensors for daily life: A review. **Sensors International**. v. 2, 100121. 2021. <https://doi.org/10.1016/j.sintl.2021.100121>.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. Tradução José Carlos Neves Epiphanyo (coordenador) São José dos Campos: Parêntese, 2011. 598 p.

JENSEN, J. R. (2009). **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese. 598 p.

JIANG, J., TANG, S., HAN, D., FU, G., SOLOMATINE, D., ZHENG, Y. A comprehensive review on the design and optimization of surface water quality monitoring networks. **Environmental Modelling & Software**. v. 132. 2020. <https://doi.org/10.1016/j.envsoft.2020.104792>.

JIANG, D., MATSUSHITA, B., PAHLEVAN, N., GURLIN, D., FICHOT, C. G., HARRINGMEYER, J., SENT, G., BRITO, A. C., BROTHAS, V., WERTHER, M., MASCARENHAS, V., BLAKE, M., HUNTER, P., TYLER, A., & SPYRAKOS, E. Estimating the concentration of total suspended solids in inland and coastal waters from Sentinel-2 MSI: A semi-analytical approach. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 204. p.362-377. 2023. <https://doi.org/10.1016/j.isprsjprs.2023.09.020>.

KARAOUI, I., A. ARIOUA, A. BOUDHAR, M. HSSAISOUNE, S. EL MOUATASSIME, K. OUHAMCHICH, D. ELHAM- DOUNI, A. IDRISSE, E W. NOUAIM. Evaluating the potential of Sentinel-2 satellite images for water quality characterization of artificial reservoirs: The Bin El Ouidane reservoir case study (Morocco). **Meteorology Hydrology and Water Management**. Research and Operational Applications v. 7(1), p. 31–39. 2019. DOI. 10.26491/mhwm/95087

KARIMI, B. HASHEMI, S. H. H. AGHIGHI, H. Development of the best retrieval models of non-optically active parameters for an artificial shallow lake by random forest algorithm. **Remote Sensing Applications: Society and Environment**. v. 29,100926. 2023. <https://doi.org/10.1016/j.rsase.2023.100926>.

KEUKELAERE, L., STERCKX, S., ADRIAENSEN, S., KNAEPS, E., REUSEN, I., GIARDINO, C., BRESCIANI, M., HUNTER, P., NEIL, C., VAN DER ZANDE, D., VAICIUTE, D. Atmospheric correction of Landsat-8/OLI and Sentinel-2/MSI data using iCOR algorithm: validation for coastal and inland waters. **European Journal of Remote Sensing**. v. 51, p. 525–542. 2018. <https://doi.org/10.1080/22797254.2018.1457937>.

KIM, H.-C.; SON, S.KIM, Y. H. KHIM, J. S. NAM, J. CHANG, W. K. LEE, J. LEE, C. H. RYU, J. Remote sensing and water quality indicators in the Korean West coast: Spatio-temporal structures of MODIS-derived chlorophyll-a and total suspended solids. **Marine Pollution Bulletin**. v. 121, n. 1–2, p. 425–434, 2017. DOI: 10.1016/j.marpolbul.2017.05.026.

KIRK, J. T. (2011). Light and photosynthesis in aquatic ecosystems. Third Edition Cambridge university press.

KNAEPS, E., MERTENS, J., VUONG, C., YANG, X., & STAHL, A. The SeaSWIR dataset: Investigating the spectral reflectance in coastal and inland waters using Sentinel-2. **Earth System Science Data**. v. 10(3), p. 1439–1450. 2015. DOI:10.5194/essd-2018-10.

KONDRATYEV, K.Y.; POZDNYAKOV, D.V.; PETTERSSON, L.H. Water quality remote sensing in the visible spectrum. **International Journal of Remote Sensing**. v. 19, p. 957–979. 1998. <https://doi.org/10.1080/014311698215810>.

KONG, Y.; JIMENEZ, K.; LEE, C. M.; INVERNO, S.; SUMMERS-EVANS, J.; CAO, A.; MENCZER, M.; HAN, R.; CADE, M.; MCCARTHY, S.; BLATZHEIM, K.; JAY, J. A. Monitoring Coastal Water Turbidity Using Sentinel2—A Case Study in Los Angeles. **Remote Sensing**, v. 17, n. 2, p. 201, 2023. <https://doi.org/10.3390/rs17020201>.

KUPSSINSKÜ, L. S.; GUIMARÃES, T.T.; SOUZA, E.M.; ZANOTTA, D.C.; VERONEZ, M.R.; GONZAGA, L.; MAUAD, F.F. A method for chlorophyll-a and suspended solids prediction through remote sensing and machine learning. **Sensors**. v.20, n.7, 2020. <https://doi.org/10.3390/s20072125>.

KUTSER, T., B. PAAVEL, C. VERPOORTER, M. LIGI, T. SOOMETS, K. TOMING, E G. CASAL. Remote sensing of black lakes and using 810 nm reflectance peak for retrieving water quality parameters of optically complex waters. **Remote Sensing** v. 8(6), 497. 2016. <https://doi.org/10.3390/rs8060497>.

KUTSER, T.; HEDLEY, J.; GIARDINO, C.; ROELFSEMA, C.; BRANDO, V. E. Remote sensing of shallow waters – A 50 year retrospective and future directions. **Remote Sensing of Environment**. v. 240. 2020. <https://doi.org/10.1016/j.rse.2019.111619>.

LAI, L. ZHANG, Y. CAO, Z. LIU, Z. YANG, Q. Algal biomass mapping of eutrophic lakes using a machine learning approach with MODIS images. **Science of The Total Environment**. v. 880, 1.163357. 2023a. <https://doi.org/10.1016/j.scitotenv.2023.163357>.

LAI, L. LIU, Y. ZHANG, Y. CAO, Z. YANG, Q. CHEN, X. MODIS Terra and Aqua images bring non-negligible effects to phytoplankton blooms derived from satellites in eutrophic lakes. **Water Research**. v. 246, 1 120685. 2023b. <https://doi.org/10.1016/j.watres.2023.120685>.

LEE, C. KUO, C. Y. YANG, C. KAO, H. K. TSENG, K. LAN, W. Assessment of hydrological changes in inland water body using satellite altimetry and Landsat imagery: A case study on Tsengwen Reservoir. **Journal of Hydrology: Regional Studies**. v. 44, 101227. 2022. <https://doi.org/10.1016/j.ejrh.2022.101227>.

LEGGESSE, E.S.; ZIMALE, F.A.; SULTAN, D.; ENKU, T.; SRINIVASAN, R.; TILAHUN, S.A. Predicting Optical Water Quality Indicators from Remote Sensing Using Machine Learning Algorithms in Tropical Highlands of Ethiopia. **Hydrology**. v. 10(6), 110. 2023. <https://doi.org/10.3390/hydrology10050110>.

LI, Z., ROY, D., ZHANG, H., VERMOTE, E., HUANG, H. Evaluation of Landsat-8 and Sentinel-2A Aerosol Optical Depth Retrievals across Chinese Cities and Implications for Medium Spatial Resolution Urban Aerosol Monitoring. **Remote Sensing**, v.11(2), 122. 2019. <https://doi.org/10.3390/rs11020122>.

LI, Y., L. TIAN, W. LI, J. LI, A. WEI, S. LI, E R. TONG. Design and experiments of a water color remote sensing-oriented unmanned surface vehicle. **Sensors**. v. 20(8), 2183. 2020a. <https://doi.org/10.3390/s20082183>.

LI, Lingling; LI, Yunmei; LÜ, Heng. Remote sensing classification of urban black-odor water based on decision tree. **Environmental Science**. v. 41, p. 5060–5072, 2020b. DOI: 10.13227/j.hjcx.202003266.

LI, S. TOMING, K. NÖGES, T. KUTSER, T. Integrating remote sensing of hydrological processes and dissolved organic carbon fluxes in long-term Lake Studies. **Journal of Hydrology**. v. 605, 127331. 2022. <https://doi.org/10.1016/j.jhydrol.2021.127331>.

LIMA, E. L. F.; SOARES, M. D. R.; MACIEL, C. R.; SIMÃO, M. A. G.; CAVALCANTE, L. V. M.; NOGUCHI, H. S.; NASCIMENTO, F. R. do. Assessment of water quality for human consumption in the municipality of Manicoré-AM. **Scientific Reports**, v. 15, 10248. 2025. <https://doi.org/10.1038/s41598-025-90167-0>.

LIOMBAS, J. CHRISTODOULOU, A. KATSIAPI, M. XANTHOPOULOU, N. STOURNARA, P. SPAHOS, T. SERETOUDI, G. MENTES, A. THEODORIDOU, N. Satellite remote sensing to improve source water quality monitoring: A water utility's perspective. **Remote Sensing Applications: Society and Environment**. v. 32, 101042. 2023. <https://doi.org/10.1016/j.rsase.2023.101042>.

LIU, W.T.H. **Aplicações de sensoriamento remoto**. Campo Grande: Ed. Uniderp, 2007.

LIU, H.; LI, Q.; SHI, T.; HU, S.; WU, G.; ZHOU, Q. Application of sentinel 2 MSI images to retrieve suspended particulate matter concentrations in Poyang Lake. **Remote Sens**. v. 9, 761. 2017. <https://doi.org/10.3390/rs9070761>.

LIU, C.; ZHANG, F.; JIM, C. Y.; OKE, S. A.; ADAM, E. Evaluation of atmospheric correction algorithms for salt lake water assessment: Accuracy, band-specific effects, and sensor consistency. **PLoS One**. v. 19, n. 12, e0315837, 2024. <https://doi.org/10.1371/journal.pone.0315837>.

LIU, L.-W.; WANG, Y.-M. Modelling reservoir turbidity using Landsat 8 satellite imagery by gene expression programming. **Water**. v. 11 p. 2 – 16. 2019. <https://doi.org/10.1016/j.measurement.2021.109193>.

LIU, Y., BAO, Y. Review of electromagnetic waves-based distance measurement technologies for remote monitoring of civil engineering structures. **Measurement**, v 176, 109193. 2021. <https://doi.org/10.1016/j.measurement.2021.109193>.

LOPES, F. B.; BARBOSA, C. C. F.; NOVO, E. M. L. M.; ANDRADE, E. M.; CHAVES, L. C. G. Modelagem da qualidade das águas a partir de sensoriamento remoto hiperespectral. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18. p. S13–S19. 2014. <https://doi.org/10.1590/1807-1929/agriambi.v18nsuppS13-S19>.

MA, Y., SONG, K., WEN, Z., LIU, G., SHANG, Y., LYU, L., DU, J., YANG, Q., LI, S., TAO, H., & HOU, J. Remote sensing of turbidity for lakes in Northeast China using sentinel-2 images with machine learning algorithms. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**. v. 14. p. 9132–9146. 2021. DOI: 10.1109/JSTARS.2021.3109292.

MAGRÌ, S. OTTAVIANI, E. PRAMPOLINI, E. FABIANO, B. F. FEDERICI, B. Application of machine learning techniques to derive sea water turbidity from Sentinel-2 imagery. **Remote Sensing Applications: Society and Environment**. v. 30, 100951. 2023. <https://doi.org/10.1016/j.rsase.2023.100951>.

MAIMOUNI, S. MOUFGARI, A. A. DAGHOR, L. FEKRI, A. OUBRAIM, S. LHISSOU, R. Spatiotemporal monitoring of low water turbidity in Moroccan coastal lagoon using Sentinel-2 data. **Remote Sensing Applications: Society and Environment** v. 26. 100772. 2022. <https://doi.org/10.1016/j.rsase.2022.100772>.

MAIER, P. M. AND KELLER, S., 2019. Estimating chlorophyll a concentrations of several inland waters with hyperspectral data and machine learning models, *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.*, IV-2/W5, 609–614. <https://doi.org/10.5194/isprs-annals-IV-2-W5-609-2019>.

MALIKI, A. A. A., CHABUK, A., SULTAN, M. A., HASHIM, B. M., HUSSAIN, H. M., & AL-ANSARI, N. Estimation of Total Dissolved Solids in water bodies by spectral indices: Case study: Shatt Al-Arab River. **Water, Air, & Soil Pollution**. v. 231(482) 2020. <https://doi.org/10.1007/s11270-020-04844-z>.

MAMEDES, I.; GUERRA, A.; RODRIGUES, D. B. B.; GARCIA, L. C.; GODOI, R. F.; OLIVEIRA, P. T. S. Brazilian payment for environmental services programs emphasize water-related services. **International Soil and Water Conservation Research**. v. 11, n. 2, p. 276–289, 2023. <https://doi.org/10.1016/j.iswcr.2023.01.001>

MAMUN, M.; HASAN, M.; AN, K.-G. Advancing reservoirs water quality parameters estimation using Sentinel-2 and Landsat-8 satellite data with machine learning approaches. **Ecological Informatics**, v. 81, 102608, 2024. <https://doi.org/10.1016/j.ecoinf.2024.102608>.

MAPBIOMAS MAPBIOMAS v. 8.0. 2023. Disponível online: <https://mapbiomas.org/>. acesso em 15 de novembro de 2024.

MATTHEWS, M. W. A current review of empirical procedures of remote sensing in Inland and near-coastal transitional waters. **International Journal of Remote Sensing**, v. 32, n. 21, p. 6855–6899, 2011. <https://doi.org/10.1080/01431161.2010.512947>.

MARTINS, V. S.; BARBOSA, C. C. F.; CARVALHO, L. A. S.; JORGE, D. S. F.; LOBO, F. L.; NOVO, E. M. L. M. Assessment of atmospheric correction methods for Sentinel-8 MSI images applied to Amazon floodplain lakes. **Remote Sensing**. v.9, p. 322-346. 2017. <https://doi.org/10.3390/rs9040322>.

MARKERT, K. N., C. M. SCHMIDT, R. E. GRIFFIN, A. I. FLORES, A. POORTINGA, D. S. SAAH, R. E. MUENCH, N. E. CLINTON, F. CHISHTIE, K. KITYUTTACHAI, SOMETH, P. ANDERSON, E. R. AEKAKKARARUNGROJ, A. GANZ, D. J. Historical and operational monitoring of surface sediments in the lower Mekong Basin using Landsat and Google Earth Engine cloud computing. **Remote Sensing**. v. 10(6), 909. 2018. <https://doi.org/10.3390/rs10060909>.

MCCARTHY, M. J.; COLNA, K. E.; EL-MEZAYEN, M. M.; LAUREANO-ROSARIO, A. E.; MÉNDEZ-LÁZARO, P.; OTIS, D. B.; TORO-FARMER, G.; VEGA-RODRIGUEZ, M.; MULLER-KARGER, F. E. Satellite Remote Sensing for Coastal Management: A Review of Successful Applications. **Environmental Management**. v. 60, p. 323–339. 2017. <https://link.springer.com/article/10.1007/s00267-017-0880-x>.

MCCULLOUGH, I. M.; LOFTIN, C. S.; SADER, S. A. Combining lake and watershed characteristics with Landsat TM data for remote estimation of regional lake clarity. **Remote Sensing of Environment**. v. 123, p. 109–115. 2012. <https://doi.org/10.1016/j.rse.2012.03.006>.

MELLO, K. TANIWAKI, R. H., PAULA, F. R. DE, VALENTE, R. A., RANDHIR, T. O., MACEDO, D. R., LEAL, C. G. RODRIGUES, C. B. HUGHES, R. M.. Multiscale land use impacts on water quality: Assessment, planning, and future perspectives in Brazil. **Journal of Environmental Management**. v. 270, 110879. 2020. <https://doi.org/10.1016/j.jenvman.2020.110879>.

MEYER, H.; REUDENBACH, C. HENGL, T. KATURJI, M. NAUSS, T. Improving performance of spatio-temporal machine learning models using forward feature selection and target-oriented validation. **Environmental Modelling and Software**, v. 101, p. 1–9, 2018. <https://doi.org/10.1016/j.envsoft.2017.12.001>.

MINAS GERAIS. Conselho Estadual de Política Ambiental; Conselho Estadual de Recursos Hídricos. **Deliberação Normativa Conjunta COPAM-CERH/MG nº 08, de 25 de agosto de 2022**. Estabelece critérios e diretrizes para o lançamento de efluentes em corpos de água e em sistemas de disposição no solo no Estado de Minas Gerais. Diário do Executivo – MG, Belo Horizonte, 26 ago. 2022. Disponível em: <https://www.siam.mg.gov.br>. Acesso em: 7 maio 2025.

MISHRA, S.; STUMPF, R.P.; MEREDITH, A. Evaluation of RapidEye data for mapping algal blooms in inland waters. **International Journal of Remote Sensing**. v.40, p. 2811–2829. 2019. <https://doi.org/10.1080/01431161.2018.1533657>.

MOBLEY, C. D. Polarized reflectance and transmittance properties of windblown sea surfaces. **Applied Optics**, v. 54, n. 15, p. 4828–4849, 2015. <https://doi.org/10.1364/AO.54.004828>.

MOBLEY, C. D.; BOSS, E. S.; ROESLER, C. Ocean optics web book, 2010. Disponível em: <http://www.oceanopticsbook.info/>.

MURPHY, K. P. **Machine Learning: A Probabilistic Perspective Chance Encounters: Probability in Education London**, England The MIT Press, 2013.

NAZEER, M., ILORI, C. O., BILAL, M., NICHOL, J. E., WU, W., QIU, Z., GAYENE, B. K. Evaluation of atmospheric correction methods for low to high resolutions satellite remote sensing data. **Atmospheric Research**. v. 249, 105308. 2021. [10.1016/j.atmosres.2020.105308](https://doi.org/10.1016/j.atmosres.2020.105308).

NETO, V. J. d. S.; BONACELLI, M. B. M.; PACHECO, C. A. O sistema tecnológico digital: inteligência artificial, computação em nuvem e big data. **Revista Brasileira de Inovação**, SciELO Brasil, v. 19. p. 1-31. 2021. <https://doi.org/10.20396/rbi.v19i0.8658756>.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**. 3. ed. São Paulo: Blucher, 2008.

NOVOA, S. DOXARAN, D. ODY, A. VANHELLEMONT, Q. LAFON, V. LUBAC, B. GERNEZ, P. Atmospheric corrections and multi-conditional algorithm for multi-sensor remote sensing of suspended particulate matter in low-to-high turbidity levels coastal waters. **Remote Sensing**. v. 9, n. 1, 2017. <https://doi.org/10.3390/rs9010061>.

ODERMATT, D., O. DANNE, P. PHILIPSON, E C. BROCKMANN. Diversity II water quality parameters from ENVISAT (2002-2012): a new global information source for lakes. **Earth System Science**. v. 10, p. 1527–1549, 2018. <https://doi.org/10.5194/essd-10-1527-2018>.

OGASHAWARA, I. LI, L. DRUSCHEL, G. K. Retrieval of inherent optical properties from multiple aquatic systems using a quasi-analytical algorithm for several water types. **Remote Sensing Applications: Society and Environment**. v. 27, 100807. 2022. <https://doi.org/10.1016/j.rsase.2022.100807>.

OGASHAWARA, I. The use of Sentinel-3 imagery to monitor cyanobacterial blooms. **Environ-ments** v. 6(6), 60. 2019. <https://doi.org/10.3390/environments6060060>.

OLIVE, D. J. **Multiple linear regression. Linear regression**. Springer, Cham, p. 17–83, 2017.

OLIVEIRA, F. C. Impactos de um evento de seca prolongada na qualidade da água após esgotamento hídrico do reservatório Cruzeta, na Região Tropical Semiárida. *Tratamento de Água*, 2021.

OMONDI, A. N; OUMA, Y; KOSGEI, J. B.; KONGO, V.; KEMBOI, E. J. NJOROGE, S. M. MECHA, A. C. EMMANUEL. Estimation and mapping of water quality parameters using satellite images: a case study of Two Rivers Dam, Kenya. **Water Practice & Technology**. v. 18 (2): p. 428–443. 2023. <https://doi.org/10.2166/wpt.2023.010>.

OUMA, Y. O., NOOR, K., & HERBERT, K. (2020). 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, 8858408. 2020. <https://doi.org/10.1155/2020/8858408>.

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

PAHLEVAN, N., MANGIN, A., BALASUBRAMANIAN, S. V., SMITH, B., ALIKAS, K., ARAI, K., BARBOSA, C. BÉLANGER, S. BINDING, C. BRESCIANI, M. GIARDINO, C. GURLIN, D. FAN, Y. HARMEL, T. HUNTER, P. RONGHUA MA, R. WARREN, M. ACIX-Aqua: A global assessment of atmospheric correction methods for Landsat-8 and Sentinel-2 over lakes, rivers, and coastal waters. **Remote Sensing of Environment**. v. 258, 112366. 2021. <https://doi.org/10.1016/j.rse.2021.112366>.

PAHLEVAN, N., SCHOTT, J.R., FRANZ, B.A., ZIBORDI, G., MARKHAM, B., BAILEY, S., SCHAAF, C.B., ONDRUSEK, M., GREB, S., STRAIT, C.M. Landsat 8 remote sensing reflectance (Rrs) products: evaluations, intercomparisons, and enhancements. **Remote Sens. Environ.** v190, p. 289–301, 2017. <https://doi.org/10.1016/j.rse.2016.12.030>.

PAN, Y.; BÉLANGER, S.; HUOT, Y. Evaluation of atmospheric correction algorithms over lakes for high-resolution multispectral imagery: Implications of adjacency effect. **Remote Sensing**. v. 14, n. 13, 2979. 2022. <https://doi.org/10.3390/rs14132979>.

PASQUALETTO, A. PASQUALETTO, G. N; PASQUALETTO, T. L. L; MENDES, T. A. **Disponibilidade e demanda de recursos hídricos no Brasil**. Informe GEPEC, v. 26, n. 1, p. 46-61, 2022.

PAPA, F., CRÉTAUX, J. F., GRIPPA, M., ROBERT, E., TRIGG, M., TSHIMANGA, R. M., KITAMBO, B., PARIS, A., CARR, A., FLEISCHMANN, A. S., DE FLEURY, M., GBETKOM, P. G., CALMETTES, B., & CALMANT, S. Water Resources in Africa under Global Change: Monitoring Surface Waters from Space. **In Surveys in Geophysics** (Vol. 44, Issue 1). 2023. <https://doi.org/10.1007/s10712-022-09700-9>.

PELLEGRINI, C. C.; NETO, A V L; ASSIS, J. V. B; ASSIREU, A. T; Um Estudo Numérico da Intensificação do Vento em Reservatórios de Centrais Hidroelétricas da Região Sudeste do Brasil. **Ciência e Natura**, vol. 38, p. 197-203. 2016. DOI:10.5902/2179460X20170.

PEIXOTO, F. S. VICTOR, J. A. RIBEIRO, V. S. Conflitos pela água no Brasil. **Sociedade Natureza**. Uberlândia, MG v.34. 59410. 2022. <https://doi.org/10.14393/SN-v34-2022-59410>.

PEREIRA-SANDOVAL, M.; DELEGIDO, J.; SÒRIA-PERPINYÀ, X.; MORENO, J. Estimating water transparency using Sentinel-2 images in a Mediterranean eutrophic lagoon. **Water**. v. 15, n. 20, 3669. 2023. <https://doi.org/10.3390/w15203669>.

PIACENTINI, T, ALBERTO; G. MARSALA, V. MICCADEI, E. Analysis of Soil Erosion Induced by Heavy Rainfall: A Case Study from the NE Abruzzo Hills Area in Central Italy. **Water**. v. 10(10). 2018. <https://doi.org/10.3390/w10101314>

PINTO, C. E., P. H. MENEZES, J. M. MARTINEZ, H. L. ROIG, E R. A. VILLAR. Uso de imagens MODIS no monitoramento do fluxo de sedimentos no reservatório de Três Marias. **Revista Brasileira de Engenharia Agrícola e Ambiental-Agriambi** v. 18(5). p. 507–516, 2014. <https://doi.org/10.1590/S1415-43662014000500007>.

PISANTI, A., MAGRÌ, S., FERRANDO, I., & FEDERICI, B. Sea water turbidity analysis from Sentinel-2 images: Atmospheric correction and bands correlation. The International Archives of the Photogrammetry, **Remote Sensing and Spatial Information Sciences**. V. XLVIII-4/W1-2022, p. 371–378. 2022. <https://doi.org/10.5194/isprs-archives-XLVIII-4-W1-2022-371-2022>.

PIZANI, F.M.C.; FERREIRA, A.F.F.; MAILLARD, P. Estimativa de parâmetros não-opticamente ativos de qualidade da água a partir de sensores Sentinel-2/MSI e Landsat-8/OLI. **Caminhos da Geografia (UFU. Online)**, v. 23, p. 399-414. 2022. DOI: <https://doi.org/10.14393/RCG239061589>.

PHILIPSON, P., S. KRATZER, S. BEN MUSTAPHA, N. STROMBECK, E K. STELZER. Satellite-based water quality monitoring in Lake Vanern, Sweden. **International Journal of Remote Sensing**. V. 37(16), p. 3938–3960. 2016. <https://doi.org/10.1080/01431161.2016.1204480>.

PORWAL, A. GONZÁLEZ-ÁLVAREZ, I. Reprint of: Introduction to special issue on geologic remote sensing. **Ore Geology Reviews**. V. 108. p. 1–7. 2019. <https://doi.org/10.1016/j.oregeorev.2019.05.004>.

QUANG, N.H.; SASAKI, J.; HIGA, H.; HUAN, N.H. Spatiotemporal variation of turbidity based on Landsat 8 OLI in Cam Ranh Bay and Thuy Trieu Lagoon, Vietnam. **Water**. v.9, n.8. 2017. <https://doi.org/10.3390/w9080570>.

QUEVEDO-CASTRO, A.; MONJARDÍN-ARMENTA, S. A.; PLATA-ROCHA, W.; RANGEL-PERAZA, J. G. Implementation of remote sensing algorithms to estimate TOC, Chl-a, and TDS in a tropical water body: Sanalona reservoir, Sinaloa, Mexico. **Environmental Monitoring and Assessment**. v. 196, n. 1, p. 1–15, 2024. DOI: 10.1007/s10661-024-12305-x.

R CORE TEAM. R: A language and environment for statistical computing, version 3.3. 1. Vienna, Austria: R Foundation for Statistical Computing. 2020. Disponível em: <<https://www.r-project.org>>

RIAZ, M. T.; RIAZ, M. T.; REHMAN, A.; BINDAJAM, A. A.; MALLICK, J.; ABDO, H. G. An integrated approach of support vector machine (SVM) and weight of evidence (WOE) techniques to map groundwater potential and assess water quality. **Scientific Reports**, v. 14, 26186, 2024. <https://doi.org/10.1038/s41598-024-76607-3>

RITCHIE, J. C; ZIMBA, P. V; EVERITT, J. H. Remote sensing techniques to assess water quality. **Photogrammetric Eng. Remote Sens.** v. 69, n. 6, 2003. <https://doi.org/10.14358/PERS.69.6.695>

ROLIM, S. B. VEETIL, B. K. VIEIRO, A. P. KESSLER, A. B. GONZATTI, C. Remote sensing for mapping algal blooms in freshwater lakes: a review. **Environmental Science and Pollution Research.** v. 30, p.19602–19616. 2023. DOI:10.1007/s11356-023-25230-2

ROSA, R. **Introdução ao Sensoriamento Remoto**, 6^o edição, Uberlândia. Ed EDUFU 2007.

RUDORFF, N.; RUDORFF, C.M.; KAMPEL, M.; ORTIZ, G. Remote sensing monitoring of the impact of a major mining wastewater disaster on the turbidity of the Doce River plume off the eastern Brazilian coast. **ISPRS J. Photogramm. Remote Sensing.** v145, p.349–361, 2018. <https://doi.org/10.1016/j.isprsjprs.2018.02.013>.

SAAD, S. I.; SILVA, J. M.; PONETTE-GINZÁLEZ, A. G.; SILVA, M. L. N.; ROCHA, H. R. Modeling the on-site and off-site benefits of Atlantic Forest conservation in a Brazilian watershed. **Ecosystem Services**, v. 48, p. 101260, 2021. <https://doi.org/10.1016/j.ecoser.2021.101260>.

SABAT-TOMALA, A.; JAROCINSKA, A.M.; ZAGAJEWSKI, B.; MAGNUSZEWSKI, A.S.; SLAWIK, L.M.; OCHTYRA, A.; RACZKO, E.; LECHNIO, J.R. Application of HySpex hyperspectral images for verification of a two-dimensional hydrodynamic model. **European Journal of Remote Sensing**, v.51, n.1, p. 637-649, 2018. DOI:10.1080/22797254.2018.1470905.

SABERIOON, M.; JAKUB BROMC, J; VACLAV NEDBAL, V PAVEL SOUCEK, P; PETR CÍŠAR Chlorophyll-a and total suspended solids retrieval and mapping using Sentinel-2A and machine learning for inland waters. **Ecological Indicators**, v. 113, n., 106236. 2020. <https://doi.org/10.1016/j.ecolind.2020.106236>.

SAGAN, V., PETERSON, K. T., MAIMAITIJIANG, M., SIDIKE, P., SLOAN, J., GREELING, B. A., MAALOUF, S. ADAMS, C. Monitoring inland water quality using remote sensing: potential and limitations of spectral indices, bio-optical simulations, machine learning, and cloud computing. **Earth-Science Reviews**. V 205. 2020. <https://doi.org/10.1016/j.earscirev.2020.103187>.

SANKARAN, P., NAIR, K. P., & OTHERS spectral band ratios for monitoring suspended sediments in water bodies. **Environmental Monitoring and Assessment**, v195(4). 2023. <https://doi.org/10.1716/j.rse.2023.02.007>

SANTOS, E. V. R; SILVA, I. S; NASCIMENTO, D. T. F; LUZ, M. P. Application of spectral indexes in the evaluation of sediment input to the reservoirs of the Itumbiara and Batalha hydroelectric power plants (Brazil). **Agua y Territorio**. V. 23 p. 99-109. 2024. DOI:10.17561/at.23.7205.

SCHUWIRTH, N. Towards an integrated surface water quality assessment: Aggregation over multiple pollutants and time. **Water Research**. v. 186, 116330. 2020. <https://doi.org/10.1016/j.watres.2020.116330>

SHAH, A, A. BAROUTAJI, A. ZAKHAROVA, J. A review of physicochemical and biological contaminants in drinking water and their impacts on human health. **Water Science and Engineering**. 2023. <https://doi.org/10.1016/j.wse.2023.04.003>.

SHANG, S., LEE, Z., LIN, G., HU, C., SHI, L., ZHANG, Y. LI, X. WU, J. YAN, J. Sensing an intense phytoplankton bloom in the western Taiwan Strait from radiometric measurements on a UAV. **Remote Sensing of Environment**, v. 198, p. 85–94. 2017. <https://doi.org/10.1016/j.rse.2017.05.036>.

SHI, K.; ZHANG, Y.; ZHU, G.; QIN, B.; PAN, D. Deteriorating water clarity in shallow waters: Evidence from long term MODIS and in-situ observations. **International Journal of Applied Earth Observation and Geoinformation**. v. 68, p. 287–297. 2018. <https://doi.org/10.1016/j.jag.2017.12.015>.

SCIKIT-LEARN. 1.4. **Máquinas de Vetores de Suporte**. Disponível em: <https://scikit-learn.org/stable/modules/svm.html>. Acesso em: 23 maio. 2025.

SILVA, T. F. G.; VINÇON-LEITE, B.; LEMAIRE, B. J.; PETRUCCI, G.; GIANI, A.; FIGUEREDO, C. C.; NASCIMENTO, N. O. Impact of urban stormwater runoff on cyanobacteria dynamics in a tropical urban lake. **Water**, v. 11, n. 5, 2019. <https://doi.org/10.3390/w11050946>.

SILVA, M. M. A. P. M., S. D. FARIA, E P. M. MOURA. Modelagem da qualidade da água na bacia hidrográfica do Rio Piracicaba (MG). **Engenharia Sanitária e Ambiental**. V. 22(1), p. 133–143. 2017. <https://doi.org/10.1590/S1413-41522017134420>.

SILVA, T. A; DUARTE, M. L; VALENTE, Keith S; GUANDIQUE, M. E G. Avaliação da concentração de sedimentos em represas utilizadas para abastecimento público no município de Sorocaba-SP. **Journal of Environmental Analysis and Progress**, v. 9, n. 3, p. 179-187. 2024. DOI: <https://doi.org/10.24221/jeap.9.3.2024.6057.179-187>.

SONG, K.; WANG, Z.; BLACKWELL, J.; ZHANG, B.; LI, F.; JIANG, G. Water quality monitoring using Landsat Themate Mapper data with empirical algorithms in Chagan Lake, China. **Journal of Applied Remote Sensing**. v. 5, 53506. 2011. <https://doi.org/10.1016/j.rse.2020.111800>.

SONG, K; LIU, G; WANG, Q; WEN, W; LYU, L; DU, Y; SHA, L; FANG, C. Quantification of lake clarity in China using Landsat OLI imagery data. **Remote Sensing of Environment**, v. 243. 2020. DOI. 10.1117/1.3559497.

SOUZA, A. P. OLIVEIRA, B. A. ANDRADE, M. L. STARLING, M. C. V. M. PEREIRA, A. H. MAILLARD, P. NOGUEIRA, K. SANTOS, J. A. AMORIM, C. C. Integrating remote sensing and machine learning to detect turbidity anomalies in hydroelectric reservoirs. **Science of The Total Environment**. v. 902. 2023. <https://doi.org/10.1016/j.scitotenv.2023.165964>.

STEINMETZ, F., DESCHAMPS, P.-Y., RAMON, D. Atmospheric correction in presence of

sun glint: application to MERIS. **Optics express**. v. 19, 2011. <https://doi.org/10.1364/OE.19.009783>.

SUN, X., ZHANG, Y., SHI, K., ZHANG, Y., LI, N., WANG, W. HUANG, X. QIN, B. Monitoring water quality using proximal remote sensing technology. **Science of The Total Environment**. v 803, 149805. 2022. <https://doi.org/10.1016/j.scitotenv.2021.149805>.

TALUKDAR, S. SHAHFAHAD. AHMED, S. NAIKOO, M. W. RAHMAN, A. MALLIK, S. NINGTHOUJAM, S. BERA, S. RAMANA, G. V. Predicting lake water quality index with sensitivity-uncertainty analysis using deep learning algorithms. **Journal of Cleaner Production**. v.406, 20. 136885. 2023. <https://doi.org/10.1016/j.jclepro.2023.136885>.

TAVORA, J.; GONÇALVES, G. A.; FERNANDES, E. H.; SALAMA, M. S.; VAN DER WAL, D. Detecting turbid plumes from satellite remote sensing: State-of-art thresholds and the novel PLUMES algorithm. **Frontiers in Marine Science**, v. 10, 1215327. 2023. <https://doi.org/10.3389/fmars.2023.1215327>

TOMING, K.; KUTSER, T.; LAAS, A.; SEPP, M.; PAAVEL, B.; NÖGES, T. First experiences in mapping lake water quality parameters with Sentinel-2 MSI imagery. **Remote Sensing**. v.8, p. 640. 2016. <https://doi.org/10.3390/rs8080640>.

TUNDISI, J. G. Reservoirs: New challenges for ecosystem studies and environmental management. **Water Security**. V. 4–5, p. 1-7. 2018. <https://doi.org/10.1016/j.wasec.2018.09.001>

TYRALIS, H.; PAPACHARALAMPOUS, G.; LANGOUSIS, A. A brief review of random forests for water scientists and practitioners and their recent history in water resources. **Water**. v. 11, n. 5, 2019. <https://doi.org/10.3390/w11050910>.

UDDIN, M. G., NASH, S., OLBERT, A. I. A review of water quality index models and their use for assessing surface water quality. **Ecological Indicators**. v. 122, 107218. 2021. <https://doi.org/10.1016/j.ecolind.2020.107218>.

UUDEBERG, K.; AAVASTE, A.; KÕKS, K.; ANSPER, A.; UUSÕUE, M.; KANGRO, K.; ANSKO, I.; LIGI, M.; TOMING, K.; REINART, A. Optical water type guided approach to estimate optical water quality parameters. **Remote Sensing**. v.12, n.6. 2020. <https://doi.org/10.3390/rs12060931>.

VAPNIK, Vladimir N. **The Nature of Statistical Learning Theory**. New York: Springer-Verlag, 1995.

VAN DER MERWE, D. E. K. P. PRICE. Harmful algal bloom characterization at ultra-high spatial and temporal resolution using small unmanned aircraft systems. **Toxins**. v. 7(4), p. 1065–1078. 2015. doi: 10.3390/toxins7041065.

VANHELLEMONT, Q.; RUDDICK, K. Acolite for Sentinel-2: Aquatic applications of MSI imagery. **In Proceedings of the ESA Living Planet Symposium**, Pragur, Czech Republic, p. 9–13. 2016. <https://doi.org/10.1016/j.rse.2015.02.007>.

VANHELLEMONT, Q.; RUDDICK, K. Advantages of high quality SWIR bands for ocean colour processing: Examples from Landsat-8. **Remote Sens. Environ.** v 161, p. 89–106. 2015. <https://doi.org/10.1016/j.rse.2015.02.007>.

VANHELLEMONT, Q. Adaptation of the dark spectrum fitting atmospheric correction for aquatic applications of the Landsat and Sentinel-2 archives. **Remote Sensing of Environment**. v. 225 p. 175-192. 2019. <https://doi.org/10.1016/j.rse.2019.03.010>.

VASISTHA, P. GANGULY, R. Water quality assessment of natural lakes and its importance: An overview. **Materials Today: Proceedings**. V. 32 p. 544-552. 2020. <https://doi.org/10.1016/j.matpr.2020.02.092>.

VILLOTA-GONZÁLEZ, F. H.; SULBARÁN-RANGEL, B.; ZURITA-MARTÍNEZ, F.; GURUBEL-TUN, K. J.; ZÚÑIGA-GRAJEDA, V. Assessment of Machine Learning Models for Remote Sensing of Water Quality in Lakes Cajititlán and Zapotlán, Jalisco—Mexico. **Remote Sensing**. V.15(23), 5505. 2023. <https://doi.org/10.3390/rs15235505>.

VON SPERLING, M. **Introdução à qualidade das águas e ao tratamento de esgotos**. 4. ed. Belo Horizonte: Editora UFMG, 2014.

VON SPERLING, E. Hydropower in Brazil: Overview of Positive and Negative Environmental Aspects. **Energy Procedia**. v.18, p. 110–118. 2012.

WANG, Q., S. LI, P. JIA, C. QI, E F. DING. A review of surface water quality models. **The Scientific World Journal**. v. 2013. p. 1–7. 2013. <https://doi.org/10.1155/2013/231768>.

WANG, X., YANG, W. Water quality monitoring and evaluation using remote sensing techniques in China: a systematic review. **Ecosystem Health and Sustainability**. v. 5, n 1. 2019. <https://doi.org/10.1080/20964129.2019.1571443>.

WANG, F., WANG, Y., ZHANG, K., HU, M., WENG, Q., ZHANG, H. Spatial heterogeneity modeling of water quality based on random forest regression and model interpretation. **Environmental Research**. v. 202. 2021. <https://doi.org/10.1016/j.envres.2021.111660>.

WANG, Q. TANG, Y. GE, Y. XIE, H. TONG, X. PETER M. ATKINSON, P. M. A comprehensive review of spatial-temporal-spectral information reconstruction techniques. **Science of Remote Sensing**. v.8. 2023. <https://doi.org/10.1016/j.srs.2023.100102>.

WARREN, M. A.; SIMIS, S. G.H.; MARTINEZ-VICENTE, V.; POSER, K.; BRESCIANI, M.; ALIKAS, K.; SPYRAKOS, E; GIARDINO, C.; ANSPER, A. Assessment of atmospheric correction algorithms for the Sentinel-2A MultiSpectral Imager over coastal and inland waters. **Remote Sensing of Environment**, v. 225, p. 267–289. 2019. <https://doi.org/10.1016/j.rse.2019.03.018>.

WANG, Q., SONG, K., XIAO, X., JACINTHE, P.-A., WEN, Z., ZHAO, F., TAO, H., LI, S., SHANG, Y., & WANG, Y. Mapping water clarity in North American lakes and reservoirs using Landsat images on the GEE platform with the RGRB model. **ISPRS Journal of Photogrammetry and Remote Sensing**. 175, 67–81. 2021. <https://doi.org/10.1016/j.isprsjprs.2022.09.014>.

WU, J.-L., HO, C.-R., HUANG, C.-C., SRIVASTAV, A. L., TZENG, J.-H., & LIN, Y.-T. Hyperspectral sensing for turbid water quality monitoring in freshwater rivers: Empirical relationship between reflectance and turbidity and total solids. **Sensors**. v. 14, n. 12, p. 22670–22688, 2014.; <https://doi.org/10.3390/s141222670>.

XIAO, J. AGGARWAL, A. K. DUC, N. H. ARYA, A. RAGE, U. K. AVTAR, R. A review of remote sensing image spatiotemporal fusion: Challenges, applications and recent trends. **Remote Sensing Applications: Society and Environment**. v. 32. 2023. <https://doi.org/10.1016/j.rsase.2023.101005>.

YANG, H.; KONG, J.; HU, H.; DU, Y.; GAO, M.; CHEN, F. A Review of Remote Sensing for Water Quality Retrieval: Progress and Challenges. **Remote Sens**. v. 14. 2022. <https://doi.org/10.3390/rs14081770>.

YAO, K.; CHEN, Y.; LI, Y.; ZHANG, X.; ZHU, B.; GAO, Z.; LIN, F.; HU, Y. Water quality prediction of small-micro water body based on the intelligent-algorithm-optimized support vector machine regression method and unmanned aerial vehicles multispectral data. **Sustainability**, v. 16, n. 2. 2024. <https://doi.org/10.3390/su16020559>

ZHANG, Y., MIGLIAVACCA, M., PENUELAS, J., JU, W. Advances in hyperspectral remote sensing of vegetation traits and functions. **Remote Sensing of Environment**. v. 252. 2021. <https://doi.org/10.1016/j.rse.2020.112121>.

ZHANG, T.; HUANG, M.; WANG, Z. Estimation of chlorophyll-a Concentration of lakes based on SVM algorithm and Landsat 8 OLI images. *Environmental Science and Pollution Research*, v. 27, n. 13, p. 14977–14990. 2020. DOI.10.1007/s11356-020-07706-7.

ZHOU, Y.; DONG, J.; XIAO, X.; XIAO, T.; YANG, Z.; ZHAO, G.; ZOU, Z.; QIN, Y. Open surface water mapping algorithms: A comparison of water-related spectral indices and sensors. **Water** v. 9. 2017. <https://doi.org/10.3390/w9040256>.

ZHU, W.; QIANYU, Q. TIAN, Y. Q. BECKER, B. L. TAO ZHENG, T. HUNTER J. CARRICK, H. An assessment of remote sensing algorithms for colored dissolved organic matter in complex freshwater environments. **Remote Sensing of Environment**, v. 140, p. 766–778. 2014. DOI:10.1016/j.rse.2013.10.015.

ZHU, X., GUO, H., HUANG, J.J., TIAN, S., XU, W., MAI, Y. An ensemble machine learning model for water quality estimation in coastal area based on remote sensing imagery. **J. Environ. Manage.** v. 323. 2022. <https://doi.org/10.1016/j.jenvman.2022.116187>