



UFOP



MINISTÉRIO DA EDUCAÇÃO

Universidade Federal de Ouro Preto

Escola de Minas – Departamento de Engenharia Ambiental

Curso de Graduação em Engenharia Ambiental



Lara Renata Mapelli

**APLICAÇÃO DE SENSORIAMENTO REMOTO E APRENDIZADO DE MÁQUINA
NA ESTIMATIVA DE TURBIDEZ DE CORPOS HÍDRICOS**

**Ouro Preto – MG
2025**

Lara Renata Mapelli

**APLICAÇÃO DE SENSORIAMENTO REMOTO E APRENDIZADO DE MÁQUINA
NA ESTIMATIVA DE TURBIDEZ DE CORPOS HÍDRICOS**

Projeto Final de Curso submetida à banca examinadora de graduação em Engenharia Ambiental da Universidade Federal de Ouro Preto, como requisito parcial para obtenção de grau de bacharel em Engenharia Ambiental.

Orientador: Prof. Dr. Múcio André dos Santos Alves Mendes.

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

M297a Mapelli, Lara Renata.

Aplicação de sensoriamento remoto e aprendizado de máquina na estimativa de turbidez de corpos hídricos. [manuscrito] / Lara Renata Mapelli. - 2025.

51 f.: il.: color., gráf., tab.. + Equações.

Orientador: Prof. Dr. Múcio André dos Santos Alves Mendes.
Monografia (Bacharelado). Universidade Federal de Ouro Preto.
Escola de Minas. Graduação em Engenharia Ambiental .

1. Sensoriamento remoto. 2. Aprendizado do computador. 3. Algoritmo Florestas Aleatórias. 4. Monitoramento da Água. 5. Turbidez da Água. I. Mendes, Múcio André dos Santos Alves. II. Universidade Federal de Ouro Preto. III. Título.

CDU 504:004

Bibliotecário(a) Responsável: Soraya Fernanda Ferreira e Souza - SIAPE: 1.763.787



FOLHA DE APROVAÇÃO

Lara Renata Mapelli

Aplicação de Sensoriamento Remoto e Aprendizado de Máquina na Estimativa da Turbidez de Corpos Hídricos

Monografia apresentada ao Curso de Engenharia Ambiental da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Engenheira Ambiental

Aprovada em 09 de abril de 2025

Membros da banca

Dr. Múcio André dos Santos Alves Mendes - Orientador - Universidade Federal de Ouro Preto
Dra. Ana Letícia Pilz de Castro - Universidade Federal de Ouro Preto
Me. Paula Cristine Silva Gomes - Universidade Federal de Ouro Preto

Múcio André dos Santos Alves Mendes, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 11/04/2025



Documento assinado eletronicamente por **Múcio André dos Santos Alves Mendes, PROFESSOR DE MAGISTERIO SUPERIOR**, em 14/04/2025, às 22:27, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0896502** e o código CRC **172EBD1E**.

*Dedico este trabalho aos meus pais,
José Renato e Maria Angélica, a minha irmã, Lina,
minha família, meus anjinhos caninos
e a todos que fizeram parte dessa caminhada.*

AGRADECIMENTOS

Em primeiro lugar, expresso minha gratidão à espiritualidade, que me fortaleceu nos momentos mais desafiadores. Aos meus pais, José Renato Mapelli e Maria Angélica Parreira Mapelli e à minha irmã, Lina Domênica Mapelli, dedico meu profundo reconhecimento, que apenas palavras não conseguem transmitir todo amor incondicional, apoio, paciência e força que nos cercam. Vocês são a base para que esses agradecimentos se materializassem.

Minha gratidão se estende a toda minha família, encarnada e desencarnada, todos foram essenciais para que eu conseguisse construir quem sou hoje. Em especial, obrigada às minhas queridas vovós Olga Mapelli Parreira e Thereza Aparecida Mapelli e obrigada aos meus queridos vovôs José Baptista Parreira e Manoel Mapelli.

A todos os meus fiéis companheiros caninos, em especial Mel, Melody e Quena, que contribuíram com meu entendimento e desenvolvimento como pessoa.

Aos amigos pelo companheirismo e risadas ao longo dessa trajetória. Em especial ao eterno grupo da ETEC VGS Carol, Aline, Tauã, Marcelo, Mariany. Aos amigos do IF que levo para vida Camila, Igor, Julia, Ana, ao nosso “Trio Parada Dura” Marcela, Gabriela, a amizade cheia de energia boas da Jeey, agradeço pelas risadas com a Beatriz e Fran e a todos os colegas de curso, em especial Alice, Isabela, Rayane e André. Deixo meu agradecimento a todas as meninas da República Tanto Faz pelo acolhimento e apoio. Agradeço aos meninos da República Nós é Nós por toda musicalidade e amizade (Reunidos!).

Ao meu orientador, Múcio agradeço pela paciência e orientações valiosas, que fizeram com que esse trabalho conseguisse ganhar forma e ser desenvolvido. A todos os professores do Departamento de Engenharia Ambiental (DEAMB) por todo conhecimento compartilhado.

A UFOP e a gloriosa Escola de Minas, pela carga de oportunidades e ensinamentos.

“Nunca se vence uma guerra lutando sozinho

...

Coragem, coragem, se o que você quer é aquilo que pensa e faz,

Coragem, coragem, eu sei que você pode mais.”

Por quem os sinos doam (Raul Seixas)

RESUMO

Sabe-se que água é um recurso natural essencial para diversos fins, entretanto, devido ao consumo exacerbado e o crescimento populacional, que demanda cada vez mais desse bem, torna-se necessário a ampliação de sistemas de monitoramento quantitativo e qualitativo. Muito tem-se discutido acerca da implementação de tecnologias como a inteligência artificial (IA) para automatizar processos, inclusive no meio ambiental, onde as IAs têm se tornado cada vez mais recorrentes nos monitoramentos, permitindo a coleta simultânea de dados com maior confiabilidade e agilidade. Neste trabalho, objetivou-se desenvolver um método de aprendizado de máquina utilizando o modelo *Random Forest* (RF). Inicialmente, foram coletados 5731 dados de turbidez de monitoramento convencional da bacia do rio Doce, obtidos pelo portal Programa de Monitoramento Quali-Quantitativo Sistemático de Água e Sedimento (PMQQS), e as coordenadas dos pontos foram organizadas em uma planilha do Excel. Em seguida, esses dados foram processados no QGIS para extrair polígonos correspondentes às áreas de água. Utilizou-se imagens do satélite Sentinel-2, obtidas por meio do *Google Earth Engine* (GEE) com 10 bandas espectrais, as quais passaram por correção atmosférica no próprio GEE antes de serem processadas no *Phyton*. O sistema foi treinado com os dados de turbidez obtidos *in situ* entre 07/08/2017 e 19/12/2024, divididos em conjuntos de treinamento (70%) e teste (30%). A verificação do modelo foi realizada por meio de métricas de precisão, sendo essas: Erro Absoluto Médio (MAE); Erro Quadrático Médio (MSE); Raiz do Erro Quadrático Médio (RMSE); viés (*bias*); coeficiente de Eficiência de Nash-Sutcliffe (NSE); coeficiente de correlação de Pearson (r); coeficiente de determinação (R^2). Os resultados foram representados em um gráfico de dispersão, onde é possível interpretar que o modelo conseguiu alcançar resultados com boa precisão, apesar do viés revelar uma leve tendência do modelo implementado em subestimar os valores de turbidez. Recomenda-se, portanto, a continuidade de estudos para aprimorar a modelagem e implementar melhorias ao modelo de estimativa de turbidez.

Palavras-chave: Turbidez. Aprendizado de Máquina. *Random Forest*. Monitoramento.

ABSTRACT

It is well known that water is an essential natural resource for a variety of purposes. However, due to exacerbated consumption and population growth, which places increasing demands on this resource, it has become necessary to expand quantitative and qualitative monitoring systems. There has been much discussion about the implementation of technologies such as artificial intelligence (AI) to automate processes, including in the environmental field, where AI has become increasingly common in monitoring, allowing data to be collected simultaneously with greater reliability and agility. The aim of this study was to develop a machine learning method using the Random Forest (RF) model. Initially, 5731 turbidity data points from conventional monitoring of the Doce River basin were collected through the Systematic Qualitative and Quantitative Water and Sediment Monitoring Program (PMQQS) portal, and the coordinates of the points were organized in an Excel spreadsheet. This data was then processed in QGIS to extract polygons corresponding to the water areas. Sentinel-2 satellite images were used, obtained through Google Earth Engine (GEE) with 10 spectral bands, which underwent atmospheric correction in GEE itself before being processed in Python. The system was trained with turbidity data obtained in situ between 08/07/2017 and 12/19/2024, divided into training (70%) and test (30%) sets. The model was verified using accuracy metrics, such as: mean absolute error (MAE); Mean Square Error (MSE); Root Mean Square Error (RMSE); bias; Nash-Sutcliffe Efficiency coefficient (NSE); Pearson correlation coefficient (r); coefficient of determination (R^2). The results were represented in a scatter plot, where it is possible to interpret that the model was able to achieve results with good accuracy, despite the bias revealing a slight tendency for the implemented model to underestimate the turbidity values. It is therefore recommended that further studies be carried out to improve the modeling and implement improvements to the turbidity estimation model.

Keywords: Turbidity. *Machine Learning*. Random Forest. Monitoring.

LISTA DE FIGURAS

Figura 1 - Comitê da Bacia Hidrográfica (CBH) do rio das Velhas realiza vistoria e confirma alterações de cor e turbidez em afluente	16
Figura 2 - Turbidímetro	18
Figura 3 - Mapa de localização da área de estudo	32
Figura 4 - Mapa do dano ambiental decorrente do rompimento da barragem Fundão na bacia do rio Doce.....	33
Figura 5 - Gráfico de dispersão resultante da aplicação do modelo Random Forest na estimativa da turbidez.....	42

LISTA DE TABELAS

Tabela 1 - Dados de localização do monitoramento convencional	36
Tabela 2 - Descrição das bandas espectrais do Sentinel-2 utilizadas	38
Tabela 3 - Verificação do desempenho do modelo com aplicação de diferentes métricas	41

LISTA DE ABREVIATURAS E SIGLAS

ACORN	<i>Atmospheric Correction Now</i>
ANA	Agência Nacional de Águas e Saneamento Básico
ATCOR	<i>Atmospheric/Topographic Correction for Satellite Imagery</i>
AWE	<i>Automated Water Extraction</i>
CART	<i>Classification And Regression Tree</i>
CBH	Comitê da Bacia Hidrográfica
CIF	Comitê Interfederativo
CONAMA	Conselho Nacional do Meio Ambiente
d	Índice de Performance do Modelo
DOS	<i>Dark Object Subtration</i>
DSF	Ajuste de Espectro Escuro
ELM	<i>Extreme Learning Machine</i>
ETA	Estação de Tratamento de Água
EXP	Extrapolação Exponencial
FLAASH	<i>Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes</i>
FUNASA	Fundação Nacional da Saúde
FTU	<i>Formazin Turbidity Units</i>
GEE	<i>Google Earth Engine</i>
GTA	Grupo Técnico de Acompanhamento
hm ³	Hectômetro cúbico
IA	Inteligência Artificial
iCOR	<i>Image Correction for Atmospheric Effects</i>
IGAM	Instituto Mineiro de Gestão de Águas
INPE	Instituto Nacional de Pesquisa Espaciais
km	Quilômetros
km ²	Quilômetros quadrados
LASSO	<i>Least Absolute Shrinkagem and Selection Operation</i>
LaSRC	<i>Landsat Surface Reflectance Code</i>
LISS-3	<i>Linear Imaging Self-Scanning Sensor-3</i>
m	Metros
MAIAC	<i>Multi-Angle Implementation of Atmospheric Correction</i>

MARS	<i>Multivariate Adaptive Regression Splines</i>
mm	Milímetros
MNDWI	<i>Modified Normalized Difference Water Index</i>
MPF	Ministério Público Federal
MSE	<i>Mean Squared Error</i>
MUMM	Modelos Matemáticos da Unidade de Gestão
NDBI	<i>Normalized Difference Build-up Index</i>
NDTI	<i>Normalized Difference Turbidity Index</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
nm	Nanômetro
NTU	Unidade Nefelométrica de Turbidez
OD	Oxigênio Dissolvido
ODS	Objetivos de Desenvolvimento Sustentável
OLI	<i>Operational Land Imager</i>
ONU	Organização das Nações Unidas
PCD	Plataforma de Coleta de Dados
PMQQS	Monitoramento Quali-Quantitativo Sistemático de Água e Sedimento
QUACK	<i>Quick Atmospheric Correction</i>
R ²	Coeficiente de determinação
RF	<i>Random Forest</i>
RMSE	Erro Quadrático Médio da Raiz
SAVI	<i>Soil Adjustment Vegetation Index</i>
Sen2Cor	<i>Sentinel-2 Correction</i>
SINDA	Sistema Integrado de Dados Ambientais
SMAC	<i>Simplified Method for Atmospheric Correction in solar spectrum</i>
SR	<i>Surface Reflectance</i>
SWIR	Onda Curta Infravermelho
WRI	<i>Water Ratio Index</i>

SUMÁRIO

1	INTRODUÇÃO	13
2	OBJETIVOS	14
2.1	Objetivo geral	14
2.2	Objetivos específicos	14
3	REVISÃO BIBLIOGRÁFICA	15
3.1	Turbidez da água	15
3.1.1	Definição e importância da turbidez como um parâmetro da qualidade da água	15
3.1.2	Relação entre turbidez e concentração de sólidos em suspensão na água ...	17
3.1.3	Métodos tradicionais de medição da turbidez e suas limitações	18
3.2	Sensoriamento remoto	19
3.2.1	Conceitos básicos de sensoriamento remoto e sua aplicação no monitoramento da qualidade da água	19
3.2.2	Tipos de sensores remotos utilizados para medir as propriedades da água ..	20
3.2.3	Diferentes índices utilizados para determinar qualidade da água	21
3.3	Imagens de satélite	21
3.3.1	Tipos de satélites utilizados para observação da Terra	21
3.3.2	Resoluções espaciais e temporais em imagens de satélite	22
3.3.3	Métodos de correção atmosférica e remoção de ruídos nas imagens	24
3.3.4	Vantagens e desvantagens do uso de imagens de satélite para monitoramento ambiental	25
3.4	Relação entre imagens de satélite e turbidez	25
3.4.1	Métodos e algoritmos para estimar a turbidez a partir de imagens de satélite	25
3.4.2	Estudos de casos que demonstram a eficácia desses métodos em diferentes ambientes	27
3.5	Validação de modelos de estimativa de turbidez	28
3.5.1	Importância da validação para garantir a precisão dos modelos de estimativa ..	29
3.6	Desafios e limitações	29
3.6.1	Desafios associados à utilização de imagens de satélite na estimativa de turbidez	29
3.6.2	Limitações dos modelos existentes e áreas que necessitam de mais pesquisa	30

3.7	Aplicações práticas	31
3.7.1	Aplicações práticas e benefícios do monitoramento de turbidez por meio de imagens de satélite em diferentes contextos, como gestão de recursos hídricos e detecção de eventos extremos.....	31
4	MÉTODOS.....	32
4.1	Local de estudo	32
4.2	Coleta de dados de turbidez	34
4.3	Aquisição de imagens de satélite	37
4.4	Modelo de aprendizado de máquina	39
4.5	Validação e avaliação do modelo	39
5	RESULTADOS E DISCUSSÃO	40
6	CONCLUSÃO.....	43
	REFERÊNCIAS BIBLIOGRÁFICAS	45

1 INTRODUÇÃO

A água é um recurso natural essencial para consumo, recreação, abastecimento, processos industriais, geração de energia e principalmente para atividades agropecuárias, sendo esse o setor que consome anualmente 77,6% desse recurso, equivalente a 23.704 hm³ (Montoya, 2020). Apesar de 12% das reservas de água doce do mundo estar em território brasileiro, o uso intensivo impulsionado pelos diversos setores citados, é responsável pela escassez de água em algumas regiões.

O uso excessivo não compromete apenas a disponibilidade hídrica, mas também a qualidade da água, principalmente pela contaminação por agrotóxicos do setor agropecuarista (Menezes *et al.*, 2021) e efluentes não tratados e despejados aos corpos hídricos, exigindo um monitoramento rigoroso para garantir além da manutenção da biótica aquática, questões de saúde pública (Nakano *et al.*, 2022).

A Lei 14.026/2020 que atualizou o marco legal do saneamento básico no Brasil, tem como intuito alinhar-se ao 6º Objetivo de Desenvolvimento Sustentável (ODS), que visa assegurar a disponibilidade de água e saneamento (Leão; Souza, 2023). Essa legislação reforça a necessidade de controles e monitoramentos da qualidade da água, a fim de garantir a prevenção de doenças por veiculação hídrica e a segurança ambiental (Brasil, 2020).

Os padrões de qualidade de água estão diretamente associados aos seus diversos usos, logo os parâmetros devem estar de acordo para cada fim em que será empregada. No Brasil, esses parâmetros são definidos pelo Conselho Nacional do Meio Ambiente (CONAMA) (Brito *et al.*, 2022). Um dos principais indicadores da qualidade de água é a turbidez, sendo um medidor da capacidade da passagem de luz em ambiente aquático que sofre alterações devido à presença de partículas suspensas no meio aquático. Usualmente os parâmetros são medidos por meio da coleta de amostras de água para serem testados em equipamentos no campo ou em laboratório, o que demanda tempo e custo, limitação espacial e é passível de falhas ao realizar a testagem (Lima *et al.*, 2019).

A turbidez é um parâmetro crítico que contribui diretamente para a avaliação qualitativa da água, sendo utilizada como indicador de degradação ambiental de diversos meios, como em rompimentos de barragens e em eventos de chuvas intensas que transportam sedimentos e produtos agrícolas, favorecendo a

eutrofização (Leggesse *et al.*, 2023). Em desastres como os ocorridos em Mariana e Brumadinho, os níveis de turbidez medidos foram elevados. Por exemplo, no caso do rompimento da barragem B1 na Mina do Córrego do Feijão em Brumadinho, onde a turbidez foi analisada em um trecho logo após o rompimento e que marcava 34.500 NTU (Leuzinger *et al.*, 2022). Em situações como essa, em que extensos trechos dos cursos d'água são impactados, observa-se a dificuldade de se realizar o monitoramento em tempo real ao longo de toda a extensão afetada.

Diante de tais perspectivas, estudos como os de Li *et al.* (2019) discorrem sobre a possibilidade de viabilizar o monitoramento da qualidade da água em larga escala por meio do sensoriamento remoto, especialmente considerando os avanços nas tecnologias espaciais, não havendo a necessidade de deslocamento a campo para a amostragem, aumento na frequência na obtenção de valores e, conseqüentemente, da quantidade de dados de turbidez obtidos e sua confiabilidade. Para a turbidez, os autores Lin *et al.* (2023) já demonstraram aplicação do sensoriamento remoto para a estimativa com resultados satisfatórios. A integração do sensoriamento remoto e técnicas de Inteligência Artificial (IA) vem mostrando-se uma ferramenta promissora para a automatização do monitoramento da água para diferentes regiões e períodos de tempo (Leggesse *et al.*, 2023; Lin *et al.*, 2023; Ma *et al.*, 2021).

2 OBJETIVOS

2.1 Objetivo geral

O objetivo deste estudo é desenvolver um modelo de aprendizado de máquina, por meio de dados de sensoriamento remoto orbital, provenientes do satélite Sentinel-2, para estimar a turbidez da água em corpos hídricos.

2.2 Objetivos específicos

- a) Coletar dados de turbidez em site de monitoramento para estabelecer uma base de referência para a análise comparativa com os resultados obtidos através das imagens de satélite.

- b) Realizar a aquisição de imagens de satélite provenientes do sensor Sentinel-2, abrangendo diferentes áreas e períodos de tempo.
- c) Realizar o pré-processamento das imagens de satélite, incluindo correções atmosféricas, correções radiométricas e recortes espaciais relevantes.
- d) Extrair as bandas espectrais do Sentinel-2, as quais serão utilizadas como variáveis preditoras para modelar a turbidez.
- e) Aplicar técnicas de aprendizado de máquina, *Random Forest*, para estabelecer a relação entre as bandas espectrais do Sentinel-2 e a turbidez da água.
- f) Validar e avaliar o desempenho do modelo desenvolvido por meio de métricas estatísticas.

3 REVISÃO BIBLIOGRÁFICA

3.1 Turbidez da água

3.1.1 Definição e importância da turbidez como um parâmetro da qualidade da água

A turbidez é definida como uma medida para interferência a luz causada por sólidos suspensos no meio aquático, podendo ter origem natural ou antrópica. Alguns exemplos incluem a erosão, o lançamento de esgoto e o carreamento de sedimentos, tratando-se de um importante parâmetro utilizado para o monitoramento da qualidade da água. Quando a turbidez está elevada é um indicativo que a passagem de luz está restrita e conseqüentemente atrapalha o ciclo natural do bioma desse meio (Brasil, 2014; São Paulo, 2023). A Figura 1 ilustra como a turbidez interfere visualmente no corpo hídrico.

Figura 1 - Comitê da Bacia Hidrográfica (CBH) do rio das Velhas realiza vistoria e confirma alterações de cor e turbidez em afluente



Fonte: CBH rio das Velhas (2023).

De acordo com a Resolução CONAMA 357/2005 traz a classificação dos limites de parâmetros, no caso da turbidez para águas superficiais na classe 2 não pode ultrapassar 100 NTU no corpo receptor após mistura completa, esse valor indica a quantidade máxima de partículas em suspensão na água, para corpos d'água desta classe, mas o limite do efluente não é fixado diretamente em 100 NTU, pela Resolução Conama 430/2011.

Sabe-se que a turbidez sofre interferência considerável no período chuvoso, onde ocorre carreamento de sedimentos das encostas para os corpos hídricos, sendo agravada pela ausência de matas ciliares. Além do aumento perceptivo da turbidez, observa-se o processo de assoreamento dos rios, que também pode ser acelerado pela falta de vegetação (Coutinho, *et al.*, 2022).

Ao considerar a relação entre saúde pública e turbidez, essa surge como uma ferramenta na indicação da presença de microrganismos patogênicos, sendo utilizado como apoio para tratamento nas estações de tratamento de água (ETAs). Segundo Nakano *et al.* (2022), recomenda-se o monitoramento periódico da turbidez, já que a presença de microrganismos gera um aumento desse índice.

3.1.2 Relação entre turbidez e concentração de sólidos em suspensão na água

Há uma relação direta dos sólidos suspensos e a turbidez, haja visto que, ao medir a turbidez de um corpo hídrico, é possível realizar uma interpretação qualitativa da concentração sólidos em suspensão, indicando se esta encontra-se elevada ou baixa. Portanto essa concentração é uma variável determinante para a quantificação da turbidez (Brasil, 2014).

A falta de matas ciliares é um fator que contribui significativamente para o aumento dos níveis de turbidez da água. Isso ocorre devido à ausência de vegetação ao longo das margens que facilitam o escoamento superficial da água, carreando sedimentos para dentro dos corpos hídricos. Esse é o principal fator responsável pela elevação da turbidez em períodos de chuva (Machado; Rodrigues, 2020; Santos *et al.*, 2021).

Sabe-se ainda que a turbidez está relacionada não apenas aos sólidos suspensos, mas também ao processo de eutrofização, que dificulta a penetração da luz na coluna d'água (Santos *et al.*, 2024). O processo de eutrofização geralmente está relacionado ao excesso de nitrogênio, fósforo e potássio, que agem como fertilizantes para plantas aquáticas e microalgas intensificando o crescimento destas. Os altos níveis desses elementos na água devem-se a presença de matéria orgânica, que está associada a interferência antrópica (como o lançamento de esgoto) ou natural (como a decomposição de folhas). A concentração de matéria orgânica será estimada com o parâmetro de turbidez em análises.

Ademais o uso de fertilizantes nas plantações soma-se a essa questão, haja visto que a aplicação sob o solo pode ser acarreada ou infiltrada até um corpo hídrico (Santos *et al.*, 2019). Pode-se retratar ainda que a turbidez é um indicativo para locais onde há o maior uso de agrotóxicos e fertilizantes, reduzindo nesses pontos de descarga o Oxigênio Dissolvido (OD) em água, essencial para vida nesse bioma. Outro parâmetro afetado por essas condições é o pH, cujas variações interferem na sobrevivência dos peixes e demais organismos aquáticos (Souza *et al.*, 2019).

3.1.3 Métodos tradicionais de medição da turbidez e suas limitações

A Fundação Nacional da Saúde (FUNASA) recomenda o uso do turbidímetro com nefelômetro para medir a turbidez da água (Brasil, 2013), o turbidímetro é apresentado pela Figura 2. No entanto, esse método apresenta limitações significativas, como a necessidade de deslocamento até a área de interesse e a disponibilidade de amostras para análises em laboratório. Além disso, a metodologia de coleta das amostras pode sofrer variações conforme o operador, estando sujeito a erros de amostragem que comprometem a precisão e a confiabilidade dos dados obtidos, impactando diretamente no controle dos pontos monitorados (Lima *et al.*, 2019).

Figura 2 - Turbidímetro



Fonte: Direct Industry (2025).

Uma alternativa para aprimorar a medição é o uso de técnicas baseadas na detecção fotoelétrica. A principal diferença da detecção fotoelétrica e nefelometria é a forma de coleta de dados. A nefelometria mede a luz refletida através da água, enquanto a detecção fotoelétrica detecta a quantidade de luz refletida diretamente pelos sólidos suspensos (Zhu *et al.*, 2020).

Portanto, embora os métodos tradicionais ainda sejam amplamente utilizados e forneçam resultados úteis como indicadores de turbidez em monitoramentos ambientais, eles estão sujeitos a limitações. O uso de equipamentos portáteis ou a

análise laboratorial demanda além do tempo e custo, a calibração frequente. Tais limitações tornam os métodos tradicionais menos eficazes em cenários que exigem o monitoramento contínuo, resultados rápidos e precisos e uma abrangência espacial ampla, como é o caso do monitoramento de bacias hidrográficas (Lima *et al.*, 2019; Ma *et al.*, 2021).

3.2 Sensoriamento remoto

3.2.1 Conceitos básicos de sensoriamento remoto e sua aplicação no monitoramento da qualidade da água

O sensoriamento remoto pode ser definido como a aquisição de dados a distância, sendo uma ferramenta fundamental para a extração de informações sobre o objeto de interesse, como por exemplo a obtenção de imagens via satélite (Brasil, 2015). As ondas eletromagnéticas emitidas na superfície terrestre são utilizadas para obtenção de dados, onde geram imagens com alta precisão. Essas ondas podem ser divididas em diferentes faixas espectrais, como o multiespectral, cada tipo de faixa fornece informações específicas sobre diferentes características do ambiente observado (Zhang *et al.*, 2024).

Segundo os autores Zhang e Han (2023), o sensoriamento remoto é uma tecnologia capaz de fornecer dados de forma ampla e contínua. Os dados quando devidamente tratados e interpretados tornam-se uma fonte essencial para o monitoramento ambiental, permitindo a avaliação qualitativa e quantitativa de parâmetros, como exemplo a turbidez (Baptista; Machado, 2016). O sensoriamento remoto ocorre a partir da reflexão da radiação emitida em diferentes comprimentos de onda, que, ao encontrar uma superfície ou material, gera uma resposta espectral específica. Essa resposta varia de acordo com as propriedades dos materiais observados, o que permite aos sensores captarem dados cada vez mais precisos (Brito *et al.*, 2022). Relacionando-se aos métodos tradicionais que exigem a coleta de amostras de uma demanda de tempo, logística e custos, o sensoriamento remoto é uma alternativa mais eficiente para o monitoramento em uma escala maior do que aquela alcançada pelos métodos tradicionais (Ma *et al.*, 2021). O sensoriamento

remoto torna-se um aliado para a gestão dos recursos hídricos, por facilitar a localização de fontes contribuidoras de alta turbidez em um corpo hídrico.

3.2.2 Tipos de sensores remotos utilizados para medir as propriedades da água

Nos estudos analisados, observou-se uma prevalência dos sensores multiespectrais para a análise dos corpos d'água, com dados obtidos por satélites. Os autores Brito *et al.* (2022) destacaram o uso dos satélites Landsat 7 e 8 com sensor OLI (*Operational Land Imager*), descrevendo-o como o mais eficiente para análise da água em corpos hídricos com porte médio. Outro sensor citado por Brito *et al.* (2022) foi o satélite Sentinel-2A, os autores Crioni *et al.* (2023) utilizaram o Sentinel-2.

Os modelos de satélite Sentinel faz parte do programa *Copernicus* de Observação da Terra da União Europeia e estão disponíveis de forma gratuita. O Sentinel-2 possui um ciclo de 10 dias com um satélite e de 5 dias quando em conjunto com dois satélites, gerando uma boa resolução espacial e temporal (Chowdhury *et al.*, 2023).

Rudorff *et al.* (2018) também destaca o uso do Landsat e do MODIS-*Aqua* para monitoramento das propriedades da água. O satélite LISS-3 (*Linear Imaging Self-Scanning Sensor-3*) foi utilizado pelos autores Toniolo *et al.* (2018) em conjunto com o satélite ResourceSat-2, sendo que o autor também avaliou o uso do Landsat 8 em conjunto com OLI. No entanto, embora os sensores OLI e LISS-3 ofereçam uma ampla cobertura temporal e sejam de acesso gratuito, os autores Toniolo *et al.* (2018) ressaltam que é essencial reconhecer a necessidade de mais estudos para validar a eficácia dessa metodologia para a avaliação das condições de ecossistemas aquáticos.

De modo geral, os estudos que envolvem a aplicação dessas ferramentas, reflete uma tendência crescente no uso de sensores multiespectrais para monitoramento e gestão ambiental, tendo em vista sua capacidade de fornecer dados detalhados, de forma eficiente e em ampla escala.

3.2.3 Diferentes índices utilizados para determinar qualidade da água

Alguns índices estudados pelos autores Bangira *et al.* (2019), são comumente utilizados com dados para o satélite Sentinel-2, que possui resolução espacial de 10 m, sendo eles: *Normalized Difference Water Index* (NDWI); *Modified Normalized Difference Water Index* (MNDWI). Complementando os índices descritos, os autores Laonamsai *et al.* (2023) tratam de índices como: *Water Ratio Index* (WRI); *Soil Adjustment Vegetation Index* (SAVI); e *Automated Water Extraction Index* (AWEI). No contexto do monitoramento da turbidez, os autores Santos *et al.* (2024) utilizaram o índice *Normalized Difference Turbidity Index* (NDTI), que é utilizado para estimar a diferença de turbidez na água no decorrer do tempo.

O índice NDWI, utiliza das bandas espectrais de infravermelho próximo (NIR) e de verde visível (*Green*), sendo esse utilizado para diferenciar solo e água. O índice SAVI, pode ser um elemento aplicado em conjunto ao NDWI a fim de aprimorar os resultados, haja visto que sua banda espectral é aplicada para solo (Laonamsai *et al.*, 2023). No caso da SAVI as bandas espectrais são o vermelho e o NIR. O índice MNDWI utiliza a banda espectral verde e infravermelho de ondas curtas 1 (SWIR1) e, segundo os autores, apresenta desempenho similar ao NDWI para o monitoramento de recursos hídricos.

O índice WRI utiliza a como base a reflectância da água sendo suas bandas a vermelha, verde e SWIR1. Já o AWEI é um índice mais complexo e preciso, pois, utiliza um maior número de bandas espectrais, azul, verde, NIR, SWIR1 e SWIR2 (Laonamsai *et al.*, 2023). Por fim, o índice NDTI utiliza as bandas vermelha e verde, os autores Santos *et al.* (2024) retratam que esse índice vem sendo utilizado frequentemente para análise de turbidez gerando resultados satisfatórios na estimativa da variação temporal desse parâmetro.

3.3 Imagens de satélite

3.3.1 Tipos de satélites utilizados para observação da Terra

Diante da preocupação em relação as questões ambientais o uso de satélites tem se consolidado com uma ferramenta essencial em diversas áreas no

monitoramento ambiental. Esta tecnologia possibilita a coleta de dados de qualidade, em larga escala e, muitas vezes em tempo real, o que permite a análise dos impactos que as atividades humanas causam ao ambiente (Kabir *et al.*, 2022). O monitoramento por satélite é aplicado desde estudos climatológicos a desastres ambientais pontuais como queimadas (Kang *et al.*, 2023; Raspollini *et al.*, 2022).

A diversidade de satélites contribui para uma visão mais abrangente da Terra, sendo fundamental para compreensão e gestão dos recursos naturais. Como foi descrito, os satélites comumente citados pelos estudos são: Landsat, MODIS e LISS, a escolha para aplicação depende diretamente do tipo de imagem e da resolução necessária para a pesquisa em questão. No Brasil, o Instituto Nacional de Pesquisas Espaciais (INPE) retrata a preocupação com as questões ambientais, por isso, faz o uso dos satélites com função para o monitoramento ambiental. Com o intuito de promover com maior embasamento as pesquisas espaciais, surge em 1988 o programa entre Brasil e China nomeado de CBERS (Satélite Sino-Brasileiro de Recursos Terrestres). O primeiro satélite nacional lançado foi o SCD-1 em 1993, tendo como missão obtenção de dados para o monitoramento de bacias hidrográficas e da Amazônia (Brasil, 2024).

Alguns pesquisadores demonstraram a viabilidade de aplicação do Sentinel-2, como é o caso dos autores Ma *et al.* (2021), que realizaram o estudo para estimar a turbidez em larga escala por meio do uso deste satélite. Os autores demonstraram sua eficiência por meio da combinação entre a correlação de Pearson e modelos baseados em árvores. O Sentinel por ser uma missão com dados abertos do programa *Copernicus* e que apresenta imagens com altas resoluções se torna viável para pesquisas e implementação em modelos (Chowdhury *et al.*, 2023), mostrando-se importante no uso para o monitoramento ambiental, podendo ser aplicado no monitoramento regular de turbidez conforme apresentado pelos autores Chowdhury *et al.* (2023), que também realizou seu estudo com o Sentinel-2.

3.3.2 Resoluções espaciais e temporais em imagens de satélite

De acordo com a Agência Espacial Brasileira (AEB), as imagens obtidas por satélites são adquiridas remotamente por meio de sensores, permitindo a captura de imagens terrestres em diferentes intervalos temporais. Essas imagens são

constituídas por pixels, e a dimensão desses pixels determina a resolução das imagens. A escolha da resolução espacial e temporal do satélite dependerá das necessidades específicas de aplicação. As resoluções espaciais definem o menor tamanho de um objeto que pode ser identificado em uma área de análise, ao passo que as resoluções temporais indicam o tempo necessário para que o satélite revise a mesma região (Brasil, 2024).

A escolha dos satélites e as resoluções espaciais dependem de qual resolução temporal pretende-se analisar. No caso do Landsat a resolução temporal que está presente nas imagens é de 30 m e com tempo de revisita do satélite em 16 dias. Esse tempo de revisita é necessária como método para reduzir presença de nuvens que reduzem a qualidade das imagens. Por outro lado, o MODIS consegue fornecer imagens diariamente, mas sua resolução espacial é entorno de 250 m, 500 m e 1 Km (Fung *et al.*, 2019), resultando na redução da qualidade das imagens, quando comparadas as obtidas pelo Landsat. Enquanto, como descrito pelo autor Chowdhury *et al.* (2023), o satélite tipo Sentinel consegue gerar resoluções de 10 m, 20 m e 60 m, sendo seu campo de visão de 290 km de largura, o que o torna adequado para o monitoramento ambiental em larga escala.

O uso do Sentinel-2 para o monitoramento de parâmetros relacionados a qualidade da água, deve-se pelo seu modelo multiespectral totalizando 13 bandas, 3 dessas bandas são utilizadas para correção. O uso de um satélite multiespectral consegue capturar imagens de infravermelho próximo a infravermelho de onda curta (Garg *et al.*, 2020). É importante ressaltar que o Sentinel-2 é a junção de dois satélites o Sentinel-2A e Sentinel-2B, podendo ser chamado em alguns casos de Sentinel-2AB (Chowdhury *et al.*, 2023) e é essa união que permite a ampla faixa de atuação do satélite, com uma largura de faixa de 290 km de resolução (Crioni *et al.*, 2023).

As bandas vermelhas e NIR são as mais sensíveis para o monitoramento de turbidez da água. Além disso bandas verdes, NIR e SWIR são utilizadas geralmente para distinguir a água do meio em que ela está inserida, como margens, vegetação e meio urbano (Garg *et al.*, 2020; Laonamsai *et al.*, 2023). No estudo do pesquisador Vanhellefont (2019), a banda azul mostrou uma performance melhor ao longo dos espectros utilizados pelos satélites Sentinel-2A/B e Landsat 5/7/8, quando comparada a medições autônomas da rede AERONET-OC.

3.3.3 Métodos de correção atmosférica e remoção de ruídos nas imagens

As técnicas de correção apresentam-se como uma solução para mitigar ruídos nas imagens, provenientes de fatores físicos, químicos e biológicos presentes na atmosfera. A eficácia do método escolhido está associada ao tipo de sensor e satélite utilizado, bem como às condições ambientais. Sendo um processo fundamental para a qualidade e precisão dos dados obtidos (Gaida *et al.*, 2020).

Em relação a correção atmosférica, o autor Gaida *et al.* (2020) citam e comparam diversos algoritmos aplicados ao processamento de imagens, entre eles: *Atmospheric Correction Now* (ACORN); *Atmospheric/Topographic Correction for Satellite Imagery* (ATCOR); *Fast Line-of-Sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH); *Landsat Surface Reflectance Code* (LaSRC); *Multi-Angle Implementation of Atmospheric Correction* (MAIAC); *Dark Object Subtraction* (DOS); *Image Correction for Atmospheric Effects* (iCOR); *Quick Atmospheric Correction* (QUACK); *Sentinel-2 Correction – Sen2Cor*, *Simplified Method for Atmospheric Correction in solar spectrum* (SMAC).

No estudo realizado pelos autores Bangira *et al.* (2019), empregou-se o Sentinel-2 para uma análise multiespectral. O satélite captura seis bandas espectrais na faixa de 20 m, três na faixa de 60 m e quatro bandas espectrais na faixa de 10 m, sendo elas: azul, verde, vermelha, NIR, SWIR, vermelho de contorno da vegetação, espectro para vapor d'água e SWIR – Cirrus (Crioni *et al.*, 2023). Para o processamento das imagens, utilizaram-se do algoritmo Sen2cor, que usa como base de fonte de dados um software que caracteriza as imagens obtidas de acordo com o clima no período de tempo estimado. Os autores optaram por manter a correção na faixa de 10 m e considerando as de 20 m como 10 m, excluindo por tanto a faixa de 60 m.

Outro estudo ainda aponta que o uso do satélite Landsat-8 associado ao OLI, resulta em imagens de alta definição que quando combinadas a dados de satélite com alta resolução temporal consegue fornecer informações sobre turbidez (Novoa *et al.*, 2017).

3.3.4 Vantagens e desvantagens do uso de imagens de satélite para monitoramento ambiental

As vantagens do uso para o monitoramento ambiental estão relacionadas a eficiência e à ampla cobertura na obtenção de dados sobre recursos hídricos, desmatamento, incêndios florestais, explorações ilegais, entre outros. Quando comparado aos monitoramentos convencionais e suas limitações, o uso de imagens de satélite, apesar de requererem um bom poder de processamento para monitoramentos simultâneos, apresenta uma abordagem efetiva na aplicação de monitoramentos pontuais ou em larga escala, conforme apresentado em pesquisas (Leggesse *et al.*, 2023; Li *et al.*, 2020; Lin *et al.*, 2023). Há também a disponibilidade de acesso a dados abertos de satélites com alta qualidade de imagens como é o caso do Sentinel-2 (Chowdhury *et al.*, 2023).

A obtenção de imagens pode sofrer limitações por conta da presença constante de nuvens que exige metodologias para estimar a turbidez, a análise do uso de imagens em datas próximas as que utiliza. A margem dos sensores sob o equador varia entre 10 a 16 dias, justamente com o intuito de atenuar a presença das nuvens (Fensholt *et al.*, 2011). Além disso para realização de monitoramentos ambientais em larga escala no formato remoto há a necessidade do uso computacional, onde é necessário o investimento em máquinas capazes de comportar softwares de processamento de imagens, além do tempo necessário para a execução e o processamento das análises (Li *et al.*, 2020). Também é importante mencionar que, além do custo envolvido, a resolução temporal das imagens é limitada quando se utiliza a plataforma de coleta de dados (PCD), empregada pelo Sistema Integrado de Dados Ambientais (SINDA) (Brasil, 2024).

3.4 Relação entre imagens de satélite e turbidez

3.4.1 Métodos e algoritmos para estimar a turbidez a partir de imagens de satélite

Alguns métodos utilizados pelos autores estudados demonstram, principalmente, a aplicação da regressão linear para comparar quais métodos se ajustam melhor à estimativa da turbidez. Os autores Wang *et al.* (2019) analisaram

quatro algoritmos para correção atmosférica em imagens com estudo no meio aquoso: Onda Curta Infravermelho (SWIR), Extrapolação Exponencial (EXP), Ajuste de Espectro Escuro (DSF) e Modelos Matemáticos da Unidade de Gestão (MUMM). Ao comparar esses algoritmos, observaram que tanto o EXP quanto o DSF apresentaram resultados satisfatórios em todas as bandas, exceto em águas com a presença de algas e plantas aquáticas. No entanto, o algoritmo EXP se destacou ao apresentar os melhores resultados e maior precisão na estimativa da turbidez nas imagens de satélite.

Ao adaptar do DSF para os satélites Sentinel-2 e Landsat 5/7/8, o autor Vanhellefont (2019) demonstrou que o EXP apresentou uma performance superior, principalmente na banda espectral azul. De acordo com o autor, essa adaptação mostrou resultados positivos para análise de turbidez nas bandas vermelhas para todos os satélites e sensores avaliados. Mas, para as bandas NIR, apenas os sensores mais recentes forneceram resultados plausíveis.

O método *Random Forest* (RF) é um algoritmo de aprendizado de máquina, baseado em uma combinação de classificadores de múltiplos algoritmos de Árvore de Decisão (Bangira *et al.*, 2019). Os autores Leggesse *et al.* (2023), explicam o *Random Forest* como um modelo de regressão não linear, onde os dados não precisam de uma fonte de distribuição específica, não sendo afetado por multicolinearidade e funcionando bem com muitos preditores.

3.4.1.1 Aplicação do método de análise *Random Forest* (RF)

O método RF foi proposto a princípio pelo Breiman *et al.* (1984). A aplicação do RF traz otimizações para a coleta de dados, ao evitar o *overfitting* e os ruídos nas imagens, exigindo pouca demanda de treinamento de dados e rápida implementação com a linguagem *Python*. Pode-se dividir o RF em dois tipos: classificação de *Random Forest*; e regressão de *Random Forest* (Lin *et al.*, 2023).

Os pesquisadores Lin *et al.* (2023), realizaram um estudo utilizando o *Random Forest* para estimar dados de turbidez com base no sensoriamento remoto, empregando as bandas NDBI, NDWI e NDVI a partir de imagens de satélites obtidas do modelo Landsat. Primeiramente os autores aplicaram o modelo em 32 pontos de monitoramentos do ano de 2020 a 2021, os resultados foram simulados com o índice

de performance do modelo (d) e o erro quadrático médio da raiz (RMSE), com valores previamente definidos como aceitáveis para análises de regressão. Ao realizar a comparação constataram a eficiência do modelo para a estimativa da turbidez por meio de imagens de satélites com o modelo de *Random Forest*, então expandiram e aplicaram o modelo para o intervalo de tempo de 1990 a 2020, usando regressão do *Random Forest* associado a bandas do *Landsat*.

3.4.2 Estudos de casos que demonstram a eficácia desses métodos em diferentes ambientes

Os pesquisadores Silva *et al.* (2022) conduziram um estudo de caso em um reservatório em Três Marias/MG, com o objetivo de analisar a turbidez e sólidos totais por meio da aplicação de técnicas de *machine learning*. Foram aplicadas técnicas fundamentadas na regressão linear e regressão LASSO (*Least Absolute Shrinkage and Selection Operation*) em imagens de satélite Landsat 8 OLI. Os resultados indicaram que a regressão linear demonstrou uma eficácia superior na estimativa da turbidez a partir das imagens de satélite.

O uso do Landsat 8 OLI também foi utilizado nos estudos dos autores Brito *et al.* (2022), que igualmente obtiveram resultados satisfatórios. Os autores discutiram que a escolha desse satélite se mostrou mais eficiente devido à sua maior sensibilidade para detectar variações significativas nos parâmetros de água. O estudo reforça que o Landsat 8 OLI é eficiente para análise em larga escala, tendo sido utilizado no desenvolvimento do trabalho no rio Doce após o desastre do rompimento da barragem do Fundão.

Ao comparar os métodos *in situ* e a utilização da obtenção de dados de turbidez a partir de imagens de satélite usando o satélite Sentinel-2A/B, foi demonstrado que em um algoritmo multi-condicional que estima turbidez pode ser utilizado de forma regular e para monitoramento em zonas de alta turbidez. Os dados obtidos pelo modelo apresentaram resultados satisfatórios para a obtenção de dados, como evidenciado pelos valores medidos pelo satélite (15,93 FNU) e do *in situ* (13,34 FNU), isso sugere que a aplicação de imagens obtidas por satélite e associadas com *machine learning* é uma ferramenta viável e que consegue entregar resultados satisfatórios para acompanhamento da qualidade de água (Chowdhury *et al.*, 2023).

Foi apontado que o RF é um modelo que melhor estima a turbidez, além de apresentar resultados mais estáveis comparados a outros algoritmos testados para o mesmo fim, como é o caso do CART, MARS, ELM (Anmala; Turuganti, 2021). Os autores Ma *et al.* (2021) concluíram que a aplicação do RF é efetivo para a estimativa da turbidez da água em larga escala.

3.5 Validação de modelos de estimativa de turbidez

Segundo os autores Cao *et al.* (2019), que investigaram a aplicabilidade do monitoramento da qualidade da água utilizando uma câmera digital associada a uma rede neural difusa, a conclusão desta pesquisa indicou que essa combinação proporcionou resultados de turbidez mais precisos em comparação com um turbidímetro comum, sendo o erro de medição calculado de apenas $\pm 0,89\%$. Esse resultado demonstra que a estimativa de turbidez, quando realizada com tecnologias mais precisas e avançadas, podem reduzir custos, otimizar o tempo e melhorar a precisão dos resultados.

O uso do sensoriamento remoto para estimativa de turbidez é empregado de maneira a revelar e identificar tendências espaciais e temporais ao longo de um rio, proporcionando uma visão detalhada e dinâmica das variações da qualidade da água (Crioni *et al.*, 2023). Os autores Crioni *et al.* (2023), demonstraram que o Sentinel-2 (banda 8 NIR) apresentou resultados promissores para a bacia do Rio Paraopeba, no entanto, o autor destaca que a seleção do satélite e da banda apropriada é uma decisão específica para cada área de estudo, enfatizando que, há a possibilidade da utilização de uma banda única com acurácia inferior, mas que oferece a vantagem da simplicidade e viabilidade em determinados tipos de monitoramento.

As métricas associadas a validação da aplicação de imagens de satélite para a estimativa de turbidez são apresentadas e amplamente utilizadas por autores, sendo apresentadas como forma de confirmação da confiabilidade do modelo proposto e com a possibilidade de plotar em um gráfico de dispersão para melhor interpretação do comportamento dos dados, algumas métricas com aplicações recorrentes são: Erro Absoluto Médio (MAE), Raiz do Erro Quadrático Médio (RMSE), coeficiente de correlação de Pearson (r) e coeficiente de determinação (R^2) (Chowdhury *et al.*, 2023; Lin *et al.*, 2023; Ma *et al.*, 2021; Wang *et al.*, 2019).

3.5.1 Importância da validação para garantir a precisão dos modelos de estimativa

A validação dos modelos de estimativa torna-se fundamental para garantir a escolha da melhor metodologia a ser implementada, auxiliando na identificação de possíveis falhas ou limitações do modelo e assegurando que a abordagem utilizada seja a mais adequada para obtenção de resultados satisfatórios (Crioni *et al.*, 2023). Com a validação é possível obter valores padronizados e gerar maior confiabilidade nos dados. Além disso a validação torna-se um processo necessário e de extrema importância para detecção e correção de falhas no sistema que está sendo desenvolvido, ajustando assim os parâmetros do modelo.

Alguns estudos aplicaram a correlação de dados para a validação do modelo desenvolvido, como é o caso dos pesquisadores Rudorff *et al.* (2018) e Toniolo *et al.* (2018), que utilizaram do coeficiente de determinação (R^2) para a avaliação de seus modelos. Além do coeficiente de determinação ainda é possível a utilização de outros tipos de modelo de correlação, podendo ser aplicado dois tipos de modelos ou mais em uma única pesquisa (Toniolo *et al.*, 2018).

3.6 Desafios e limitações

3.6.1 Desafios associados à utilização de imagens de satélite na estimativa de turbidez

Com os avanços tecnológicos e a aplicação de estudos em diversas áreas ambientais, o uso de imagens de satélite possibilita a captação de um grande número de dados para monitoramentos, o que representa um aspecto extremamente positivo. Entretanto, o aumento na quantidade de dados exige análises mais complexas e demoradas, o que tem levado à adoção de técnicas de inteligências artificiais (IA) para processar e interpretar as imagens coletadas. Um exemplo é a aplicação de imagens de satélite com IA para a gerar alertas de incêndios florestais, como descrito pelos autores Kang *et al.* (2023). Todavia devido aos ruídos causados pela atmosfera que interferem na captura das imagens, os autores sugerem a continuidade de estudos na área para melhor desenvolvimento da IA e melhores resultados.

Além desses desafios, a qualidade das imagens pode sofrer influência pelo excesso de particulados na atmosfera, essa questão está diretamente relacionada às características sazonais do clima da região onde o estudo é realizado. Durante os períodos de estiagem, há uma maior concentração de particulados, enquanto, no período de chuva, a captura das imagens está sujeita ao maior número de interferência por nuvens e névoas. Para evitar essas falhas e garantir a qualidade das imagens e valores reais do modelo de correlação, é importante manter a calibração dos equipamentos utilizados. Além das ações de correção atmosférica já citadas ao longo do texto, é importante a integração de dados que resultam em valores próximos a realidade do local de estudo (Brasil, 2025; Yang *et al.*, 2022).

3.6.2 Limitações dos modelos existentes e áreas que necessitam de mais pesquisa

Ao revisar os estudos sobre a estimativa de turbidez por meio de imagens de satélite, nota-se que os autores destacam a importância da obtenção de imagens com o mínimo de ruídos possível, uma vez que podem comprometer a qualidade dos dados captados, um exemplo é a leitura errada de turbidez causada por fatores como a profundidade do rio, suas margens e áreas com vegetação densa. É importante ressaltar que as condições atmosféricas, como a presença de nuvens, influenciam na captura das imagens, destacando a importância de avanços nos métodos de correção atmosférica para melhorar a precisão das estimativas (Novoa *et al.*, 2017).

Os autores Yang *et al.* (2022), destacaram em sua pesquisa de revisão sobre sensoriamento remoto aplicado à qualidade da água algumas das limitações encontradas, dentre elas; as questões de correção atmosférica, a aplicabilidade espacial e a influência da sazonalidade. Uma das formas propostas no estudo para contornar esses desafios é o uso associado do sensoriamento remoto com dados aerotransportados que possuem espectros de alta resolução.

3.7 Aplicações práticas

3.7.1 Aplicações práticas e benefícios do monitoramento de turbidez por meio de imagens de satélite em diferentes contextos, como gestão de recursos hídricos e detecção de eventos extremos

As aplicações das imagens de satélite para o monitoramento de turbidez possuem relevância tanto no setor público quanto no privado. No setor privado, as empresas são obrigadas a cumprir com os padrões estabelecidos principalmente pelo CONAMA nº430/2011 e nº357/2005 (Brasil, 2025), que obriga as empresas a garantir a devolução da água aos corpos hídricos dentro dos padrões de qualidade definidos. O uso de imagens de satélite nesses casos permite que as empresas monitorem a turbidez na saída de suas áreas de forma eficiente, identificando quando necessário, possíveis desvios e auxiliando em uma análise crítica de seus processos produtivos e planejar a aplicação de medidas de controle.

Já no setor público, essa ferramenta é estratégica como forma de prevenção e controle de desastres ambientais. Como o alertas de chuva em regiões de cabeceiras para evitar acidentes em cachoeiras causados por cabeças d'água. Conforme descrito pelos corpos de Bombeiros do Paraná (Paraná, 2025) e Minas Gerais (Minas Gerais, 2025), um dos indicativos do fenômeno é a água ficar mais turva, além da possibilidade de associar com as condições climatológicas da região.

A ferramenta demonstra a aplicação em ambos os setores, público e privado, contribuindo com uma vasta possibilidade de aplicação e do desenvolvimento de estudo nas áreas. A integração do uso das imagens de satélites interpretado por IA pode levar ao desenvolvimento de alertas mais precisos e eficazes, com a possibilidade de viabilizar o uso de uma IA para o monitoramento da turbidez e tornar-se ferramenta-chave para a conservação ambiental.

O Ministério Público Federal (2017) disponibilizou os mapas de diagnóstico dos danos ambientais decorrentes do rompimento da barragem Fundão na bacia do rio Doce, juntamente com outros mapas anexados ao relatório de linha-base dos danos causados. Na figura 4, estão representados pelos pontos pretos enumerados ao longo do mapa as sedes dos municípios afetadas diretamente pelo rompimento da barragem, contabilizando um total de 40 sedes. O Instituto Mineiro de Gestão de Águas (IGAM) realizou o monitoramento emergencial com a estruturação de relatórios técnicos. Os primeiros dados de turbidez obtidos após o rompimento da barragem em novembro de 2015 apresentaram valores de até 606.200 NTU. Ressalta-se que rios presentes nessa região, enquadram-se em sua maioria como rios classe 1 e classe 2, cujos limites máximos estabelecidos para turbidez são de 40 NTU e 100 NTU, respectivamente (Minas Gerais, 2017).

4.2 Coleta de dados de turbidez

Os dados de turbidez foram obtidos por meio do Programa de Monitoramento Quali-Quantitativo Sistemático de Água e Sedimento (PMQQS), gerido pela Fundação Renova sob supervisão do Grupo Técnico de Acompanhamento (GTA) e Comitê Interfederativo (CIF). Foram selecionados todos os pontos de monitoramento convencional, com os dados do parâmetro de turbidez que serviram como referência para a validação do modelo. O PMQQS monitora águas superficiais e a qualidade dos sedimentos, disponibilizando seus dados de forma pública (Abessa *et al.*, 2024). Foi realizada a extração dos dados de turbidez e a organização dos dados em planilhas do Excel.

Na tabela 1 é possível observar os pontos de monitoramento das estações convencionais, com suas respectivas cidades, coordenadas, código referente ao ponto e qual o corpo hídrico pertencente ao rio Doce. Alguns pontos do monitoramento convencional foram realocados ou inativados ao longo do tempo e de acordo com a necessidade e validade do monitoramento a depender da localização. As tabelas 1 serviu como base para o lançamento dos pontos no QGIS.

Para o desenvolvimento das tabelas com dados de turbidez, além das informações que constam na tabela 1, foram coletados dados de turbidez dos pontos

monitorados, abrangendo o período desde o primeiro registro em 07/08/2017 até o último registro em 19/12/2024.

Tabela 1 - Dados de localização do monitoramento convencional

Latitude	Longitude	Código	Local	Corpo Hídrico
-20,1783	-43,5015	RPC-01	Mariana	Rio Piracicaba
-20,1593	-43,4192	RPC-02	Mariana	Rio Piracicaba
-19,5250	-42,6442	RPC-03	Timóteo	Rio Piracicaba
-19,5058	-42,54096	RPC-03J	Ipatinga	Rio Piracicaba
-20,237	-43,4223	RVD-03	Mariana	Corrego Santarém
-20,2415	-43,4107	RVD-04	Mariana	Corrego Santarém
-20,2518	-43,37572	RGN-02M	Mariana	Rio Gualaxo do Norte
-20,2765	-43,4317	RGN-01	Mariana	Rio Gualaxo do Norte
-20,2669	-43,3071	RGN-02	Mariana	Rio Gualaxo do Norte
-20,2691	-43,3008	RGN-03	Mariana	Rio Gualaxo do Norte
-20,2897	-43,2655	RGN-04	Mariana	Rio Gualaxo do Norte
-20,2927	-43,2792	RGN-05	Mariana	Rio Gualaxo do Norte
-20,30353	-43,2493	RGN-06	Mariana	Rio Gualaxo do Norte
-20,2626	-43,12817	RGN-07M	Barra Longa	Rio Gualaxo do Norte
-20,2809	-43,0792	RGN-07	Barra Longa	Rio Gualaxo do Norte
-20,2861	-43,0658	RGN-08	Barra Longa	Rio Gualaxo do Norte
-20,3462	-43,11147	RCA-01	Barra Longa	Rio do Carmo
-20,282	-43,04401	RCA-02	Barra Longa	Rio do Carmo
-20,2817	-43,0255	RCA-03	Barra Longa	Rio do Carmo
-20,2699	-42,99406	RCA-04	Barra Longa	Rio do Carmo
-20,2588	-42,9902	RCA-05	Barra Longa	Rio do Carmo
-20,2764	-42,93856	RCA-05J	Rio Doce	Rio do Carmo
-20,268	-42,9715	RCA-06	Barra Longa	Rio do Carmo
-20,3839	-42,90241	RPG-01	Ponte Nova	Rio Piranga
-20,2556	-42,9106	RDO-01J	Rio Doce	Rio Doce
-20,2481	-42,885247	RDO-01	Rio Doce	Rio Doce
-20,20028	-42,86561	UHE-CAN	Rio Doce	Rio Doce
-20,20025	-42,83206	RDO-02J	Rio Doce	Rio Doce
-20,0144	-42,7446	RDO-03	São Domingos do Prata	Rio Doce
-19,5542	-42,5214	RDO-04	Bom Jesus do Galho	Rio Doce
-19,3207	-42,3646	RDO-05	Belo Oriente	Rio Doce
-19,0956	-42,155	RDO-06	Periquito	Rio Doce
-19,0267	-42,12755	UHE-BAG	Periquito	Rio Doce
-18,9717	-42,087895	RDO-07	Governador Valadares	Rio Doce
-18,8818	-41,95283	RDO-08	Governador Valadares	Rio Doce
-18,9732	-41,642006	RDO-09	Tumiritinga	Rio Doce
-19,1492	-41,4764	RDO-09J	Conselheiro Pena	Rio Doce
-19,3286	-41,251612	RDO-10	Resplendor	Rio Doce

-19.43872	-41.10055	UHE-AIM	Aimorés	Rio Doce
-19.5061	-41.0139	RDO-11	Baixo Guandu	Rio Doce
-19.50266	-40.93363	UHE-MAS	Baixo Guandu	Rio Doce
-19.500283	-40.758407	RDO-12	Colatina	Rio Doce
-19.5353	-40.6356	RDO-13	Colatina	Rio Doce
-19.513103	-40.558373	RDO-14	Colatina	Rio Doce
-19.410117	-40.058965	RDO-15	Linhares	Rio Doce
-19.644419	-39.819295	RDO-16	Linhares	Rio Doce
-20.0998	-42.4491	RMA-01	Raul Soares	Rio Matipó
-20.08813	-42.47616	RMA-01J	Raul Soares	Rio Matipó
-19.190	-42.420	RSA-01M	Belo Oriente	Rio Santo Antônio
-19.2324	-42.3271	RSA-01	Naque	Rio Santo Antônio
-18.8541	-41.7864	RSG-01	Governador Valadares	Rio Suaçuí Grande
-19.063321	-41.53216	RCR-01	Conselheiro Pena	Rio Caratinga
-19.483454	-41.09294	RMH-01	Aimores	Rio Manhuacu
-19.6247	-41.0179	RGU-01	Baixo Guandu	Rio Guandú
-19.51572	-41.01183	RGU-02	Baixo Guandu	Rio Guandú
-19.5520	-40.3751	LLM-01	Colatina	Lagoa do Limão
-19.3875	-40.1682	LNV-02	Linhares	Lagoa Nova
-19.4010	-40.1576	LNV-02R	Linhares	Lagoa Nova
-19.3940	-40.1505	LNV-03	Linhares	Lagoa Nova
-19.3880	-40.1686	LNV-03R	Linhares	Lagoa Nova
-19.4169	-40.1548	LNV-01	Linhares	Lagoa Nova
-19.3533	-40.0872	LJP-01	Linhares	Lagoa Juparana
-19.3506	-40.0844	LJP-02	Linhares	Lagoa Juparana
-19.2960	-40.1211	LJP-02R	Linhares	Lagoa Juparana
-19.2199	-40.1908	LJP-03	Linhares	Lagoa Juparana
-19.5694	-40.3886	LLM-03	Colatina	Lagoa do Limão
-19.5618	-40.3873	LLM-02	Colatina	Lagoa do Limão
-19.5574	-40.3781	LLM-03R	Colatina	Lagoa do Limão
-19.5589	-39.8014	LMN-01	Linhares	Lagoa Monsarás
-19.5543	-39.7703	LMN-02	Linhares	Lagoa Monsarás
-19.5541	-39.7711	LMN-02R	Linhares	Lagoa Monsarás
-19.3880	-40.1686	LAL-01	Linhares	Lagoa do Areal
-19.5759	-39.8417	LAO-01	Linhares	Lagoa do Areão
-19.5716	-39.8432	LAO-01R	Linhares	Lagoa do Areão
-19.5705	-39.8440	LAO-02	Linhares	Lagoa do Areão

Fonte: autoria própria (2025).

4.3 Aquisição de imagens de satélite

Para auxílio da aquisição das imagens, previamente foi utilizado o software QGIS 3.22.16. Os dados foram referenciados no sistema de coordenadas SIRGAS 2000, com base nas localizações dos pontos de amostras do PMQQS, sendo gerados

polígonos delimitando as áreas dos corpos hídricos. É importante ressaltar que a coleta das amostras foi realizada de forma a evitar a contaminação por margens, árvores ou qualquer tipo de obstáculo que pudesse interferir nos resultados e na veracidade dos dados de turbidez obtidos. Os autores Laonamsai *et al.* (2023), afirmaram em seu estudo que falsos positivos podem ser registrados em casos onde ocorrem as contaminações que são identificadas erroneamente como água.

As imagens foram obtidas utilizando-se do satélite Sentinel-2, com o *Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A (SR)* no *Google Earth Engine (GEE)* (União Europeia/ESA/Copernicus), foram empregadas 10 bandas espectrais. Está apresentado na tabela 2 a resolução espacial, representada em metros e o comprimento de onda central, representada em nanômetros, de cada banda utilizada (*Earth Engine Data Catalog, 2025; Garg et al., 2020*). Cada banda do Sentinel-2 contém um tipo de resolução e comprimento de onda, utilizou-se apenas as bandas com resolução 10m e 20m por serem as mais adequadas aos objetivos do estudo.

Tabela 2 - Descrição das bandas espectrais do Sentinel-2 utilizadas

Banda espectral	Comprimento de Onda Central (nm)	Resolução (m)
Banda 2 (B2)	443	10
Banda 3 (B3)	490	10
Banda 4 (B4)	560	10
Banda 5 (B5)	665	20
Banda 6 (B6)	705	20
Banda 7 (B7)	783	20
Banda 8 (B8)	842	10
Banda 8A (B8A)	865	20
Banda 11 (B11)	1610	20
Banda 12 (B12)	2190	20

Fonte: *Earth Engine Data Catalog, 2025*

A banda B2 trabalha utilizando o espectro azul; a banda B3 trabalha com o espectro verde; a banda B4 trabalha no espectro vermelho; as bandas B5, B6, B7 e B8A trabalham no espectro do contorno vermelho da vegetação; a B8 trabalha no espectro NIR; e as bandas 11 e 12 trabalham no espectro SWIR1 e SWIR2 respectivamente (Crioni *et al.*, 2023; Garg *et al.*, 2020). A delimitação dos polígonos, permitiu a obtenção dos espectros de cada uma das estações de monitoramento, com base em imagens do satélite Sentinel-2. O modelo de processamento do Sentinel-2 disponibilizado pelo GEE, fornece informações em *Surface Reflectance (SR)*, que

representa a reflectância real da superfície terrestre após a correção atmosférica com o algoritmo Sen2cor (*Earth Engine Data Catalog*, 2025; Ma *et al.*, 2021). O download da série histórica das imagens foi realizado com intuito de analisar o perfil da turbidez ao longo do tempo e realizar a comparação com os dados de turbidez obtidos pelo PMQSS, escolheu-se o intervalo de retorno de 6 dias (*Earth Engine Data Catalog*, 2025). Utilizou-se então da biblioteca *Geemap* para processamento no software *Python*.

4.4 Modelo de aprendizado de máquina

Para a estimativa da turbidez, utilizou-se o modelo *Random Forest* (RF), técnica robusta de aprendizado de máquina composta por múltiplas árvores de decisão, indicada para regressões não lineares e pouco sensível a problemas de multicolinearidade (Breiman *et al.*, 1984).

Os dados espectrais obtidos pelas bandas do Sentinel-2 foram inseridos como variáveis preditoras no modelo RF, que foi treinado com os dados de turbidez obtidos *in situ* entre 07/08/2017 e 19/12/2024. Os dados foram divididos em treinamento (70%) e teste (30%). Para otimização dos hiperparâmetros do RF, foi utilizada validação cruzada com diferentes números de árvores, profundidades máximas e quantidade mínima de amostras por nó. O modelo treinado foi salvo para as demais análises e uso operacional na predição da estimativa de turbidez.

Todo o processo de treinamento e validação do modelo foi conduzido utilizando a linguagem de programação *Python*, com o suporte das bibliotecas *Pandas*, para manipulação e análise de dados, *Scikit-Learn*, para a implementação dos algoritmos de aprendizado de máquina, e *Joblib*, empregada para o armazenamento do modelo treinado.

4.5 Validação e avaliação do modelo

Para verificar o desempenho do modelo de *Random Forest* durante as fases de treinamento e validação, foram empregadas diversas métricas de precisão e acurácia, incluindo: Erro Absoluto Médio (MAE) (Equação 1), Erro Quadrático Médio (MSE) (Equação 2), Raiz do Erro Quadrático Médio (RMSE) (Equação 3), viés (*bias*)

(Equação 4), coeficiente de Eficiência de Nash-Sutcliffe (NSE) (Equação 5), coeficiente de correlação de Pearson (r) (Equação 6) e coeficiente de determinação (R^2) (Equação 7):

$$MAE = \frac{1}{n} \sum_{i=1}^n |O_i - P_i| \quad (1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2 \quad (2)$$

$$RMSE = \sqrt{MSE} \quad (3)$$

$$bias = \frac{1}{n} \sum_{i=1}^n (P_i - O_i) \quad (4)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - O)^2} \quad (5)$$

$$r = \frac{\sum_{i=1}^n (O_i - O) \cdot (P_i - P)}{\sqrt{\sum_{i=1}^n (O_i - O)^2} \cdot \sqrt{\sum_{i=1}^n (P_i - P)^2}} \quad (6)$$

$$R^2 = (r)^2 \quad (7)$$

Onde P_i é o valor simulado, O_i é o valor observado e N é a quantidade de comparações que foi realizada.

5 RESULTADOS E DISCUSSÃO

Para verificar a eficácia do *Random Forest* na estimativa da turbidez, aplicou-se as equações: [(1)-(7)] em um modelo de dispersão, a fim de realizar uma análise comparativa abrangente entre os dados de treinamento e teste desenvolvidos com a modelagem do sistema. Os resultados foram sistematizados na Tabela 3 e

representados graficamente Figura 5 com os resultados da dispersão. Para evitar resultados tendenciosos, o teste foi aplicado após o treinamento. As métricas utilizadas na avaliação do desempenho do modelo indicaram que o método empregado é altamente satisfatório tanto na etapa de treinamento quanto na etapa de teste.

Tabela 3 - Verificação do desempenho do modelo com aplicação de diferentes métricas

Etapa	MSE	MAE	RMSE	<i>bias</i>	NSE	<i>r</i>	R ²
Treinamento	2327,86	22,67	48,25	2,04	0,90	0,97	0,93
Teste	2659,31	24,62	51,57	-0,27	0,91	0,97	0,94

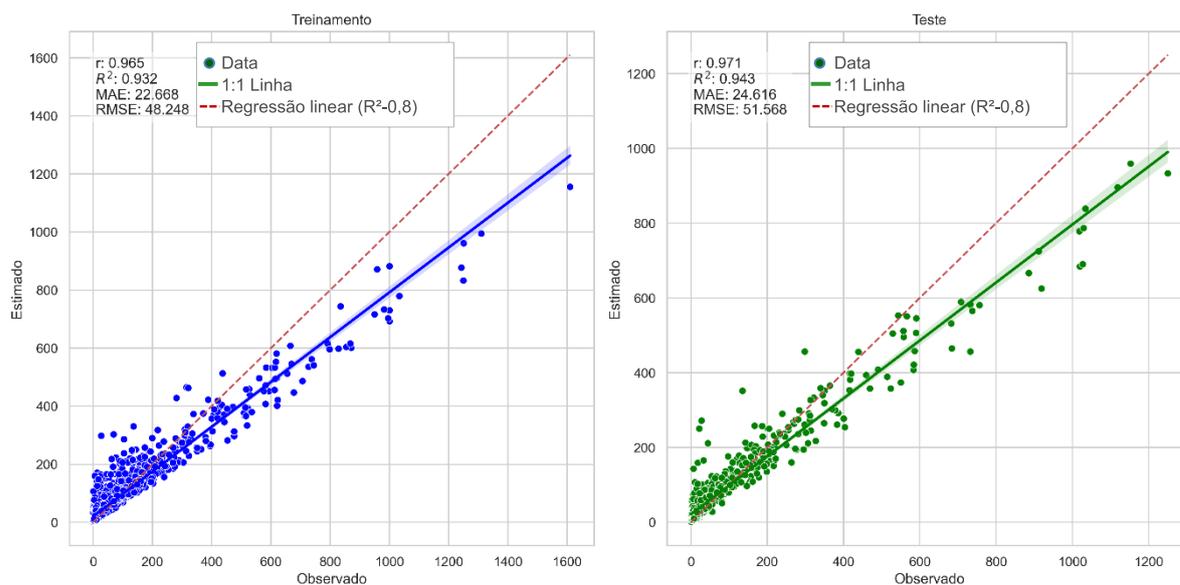
Fonte: autoria própria.

Na análise de treinamento, o modelo RF apresentou um baixo erro absoluto médio (MAE = 22,67 NTU) e uma reduzida raiz do erro quadrático médio (RMSE = 48,25 NTU). O coeficiente de correlação de Pearson (*r*) foi de 0,97, e o coeficiente de determinação (R²) alcançou 0,93. Além disso, o coeficiente de Nash-Sutcliffe (NSE) obtido foi 0,90, e o viés (*bias*) apresentou valor positivo (2,04 NTU), indicando uma pequena tendência de superestimação das previsões na etapa de treinamento, em especial nas faixas inferiores de turbidez.

Na fase de teste, os resultados apresentaram valores próximos aos da etapa de treinamento, com um MAE de 24,62 NTU, RMSE de 51,57 NTU, coeficiente de correlação de Pearson (*r*) de 0,97 e R² de 0,94. O NSE aumentou para 0,91, reforçando a eficácia preditiva do modelo. O viés na fase de teste foi de -0,27 NTU, sugerindo uma leve tendência de subestimação, porém sem relevância estatística significativa. Estes resultados sugerem que o modelo não apresentou *overfitting*, mantendo uma boa capacidade de generalização.

Na Figura 5 são apresentados os gráficos de dispersão entre os valores observados e estimados pelo RF para os conjuntos de treinamento (Figura 5A) e teste (Figura 5B). Pode-se observar uma forte proximidade dos pontos em relação à linha 1:1, o que confirma visualmente a alta precisão e acurácia do modelo nas duas etapas. Observa-se ainda a pequena tendência da fase de testes de subestimar os valores de turbidez por meio da linha de tendência. Pode-se observar ainda que a acurácia se tende a diminuir para pontos superiores a 600 NTU.

Figura 5 - Gráfico de dispersão resultante da aplicação do modelo Random Forest na estimativa da turbidez



Fonte: autoria própria.

Os resultados obtidos demonstram que a implementação do RF desenvolvido apresenta características robustas e precisas, mostrando-se adequado para a estimativa da turbidez. Com base nas variáveis preditoras constituídas pelos valores de reflectância de superfície das bandas espectrais descritas na Tabela 2 do Sentinel-2, o modelo demonstrou alta acurácia e boa capacidade preditiva, o que confirma a sua confiabilidade para aplicação na estimativa da turbidez dentro da faixa de variação dos dados utilizados no treinamento.

Para aprimorar a capacidade preditiva e a generalização do modelo proposto, sugere-se utilização de um conjunto de dados maior e que apresente distribuição equilibrada de resultados. Observou-se que os valores baixos e médios de turbidez correspondiam a maior parcela de dados para treino e teste. Tais implementos poderão minimizar ainda mais a tendência observada de subestimação, o que aumentaria a precisão das estimativas para valores extremos e ampliaria a aplicabilidade prática do método.

A combinação de técnicas de aprendizado de máquina e sensoriamento remoto tem se mostrado eficaz na estimativa da turbidez em corpos hídricos. No estudo conduzido por Andrade *et al.* (2024), foram utilizadas imagens de Aeronaves Remotamente Pilotadas associadas a algoritmos de diversos modelos de aprendizado de máquina, para estimar a turbidez em reservatórios. Os resultados indicaram que os modelos *Random Forest* e *Redes Neurais Artificiais* apresentaram os melhores

desempenhos na predição da turbidez, o que reforça a viabilidade dessas técnicas para o monitoramento da qualidade da água

Conforme descrito pelos autores Lin *et al.* (2023), a turbidez apresenta influência significativa na manutenção da biota aquática, afetando diretamente a sustentabilidade desses ecossistemas. Os autores mostram que o uso do sensoriamento remoto por satélites oferece vantagens sobre os métodos tradicionais de medição da turbidez e um avanço na metodologia para o levantamento hidrológico em escalas maiores, destacando-se: (i) maior eficiência econômica, com redução de custo e do tempo de análise; (ii) capacidade de aquisição simultâneo de dados em áreas territoriais maiores; (iii) possibilidade de sistematizar o monitoramento.

Os pesquisadores Crioni *et al.* (2023) realizaram um estudo no rio Paraopeba, realizando o monitoramento da turbidez usando um modelo empírico aplicando as imagens do satélite Sentinel-2 após o rompimento da barragem em Brumadinho-MG, onde concluiu-se que ao comparar 87 medidas de valores de turbidez com valores espectrais do satélite e desenvolver um modelo exponencial, obtiveram excelentes resultados

Com base nos trabalhos aqui estudados e no desenvolvimento do modelo apresentado com o RF, comparados com os dados do monitoramento convencional de turbidez obtidos pelo PMQQS no estudo da bacia do rio Doce com pontos ao longo do Estado de Minas Gerais e do Espírito Santo, ressalta-se que o emprego do Sentinel-2 para o monitoramento de turbidez mostrou-se eficaz no estudo, com um bom desempenho conforme evidenciado na Tabela 3. A Figura 5 mostra o gráfico de dispersão aplicado a Tabela 3, onde nota-se a precisão do modelo aplicado e que há uma leve tendência da subestimativa dos valores, conforme discutido nos valores do viés.

6 CONCLUSÃO

Os resultados obtidos nessa pesquisa certificam um potencial para o uso combinado das imagens do Sentinel-2 e o modelo *Random Forest* para a estimativa da turbidez em corpos hídricos. O modelo foi aplicado na Bacia do Rio Doce utilizando das bandas espectrais descritas na tabela 2, que demonstrou capacidade em avaliar a distribuição espaço-temporal da turbidez. Essa abordagem permite uma análise

rápida da dinâmica sedimentar dos rios e seus afluentes e se consolida como um possível indicador para determinados tipos de contaminações, a agilidade para obtenção dos dados de turbidez, contribuem para que aja intervenções rápidas e direcionadas para a contenção de sedimentos e mitigação dos impactos ambientais.

Com esses resultados, o modelo de inteligência artificial para estimativa de turbidez, mostra-se uma ferramenta promissora e estratégica para o monitoramento e controle da qualidade das águas, combinando precisão analítica com eficiência temporal. O estudo mostra viabilidade técnica de implementação da abordagem proposta e um modelo de gestão inteligente dos recursos hídricos ao mesclar tecnologia e sustentabilidade.

A partir da metodologia aplicada nesse trabalho, recomenda-se a continuidade de estudos nessa área de pesquisa para outras bacias e com a incorporação de novas variáveis, com refinamento contínuo dos algoritmos. Tais iniciativas poderão contribuir de forma significativa para o desenvolvimento de soluções inovadoras no campo do monitoramento ambiental.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABESSA, D. *et al.* Has the Rio Doce “time bomb” been defused? Using a weight-of-evidence approach to determine sediment quality. ***Integrated Environmental Assessment and Management***, v.20, n.1, p.148-158, 2024.
- ANDRADE, L. C. *et al.* Estimativa da turbidez da água utilizando imagens de RPA's associadas às técnicas de *Machine Learning* / *Water turbidity estimation using RPA's images and Machine Learning techniques*. ***Revista de Geociências do Nordeste***, v. 10 n. 1, p. 506-517, 2024.
- ANMALA, J. TURUGANTI, V. *Comparison of the performance of decision tree (DT) algorithms and extreme learning machine (ELM) model in the prediction of water quality of the Upper Green River watershed*. ***Water Environment Research***, v. 93, p. 2360-2373, 2021.
- BRASIL. Agência Nacional de Águas e Saneamento Básico (ANA). **Qualidade de Água**. [Brasília]: ANA, 2024. Disponível em: <<https://www.gov.br/ana/pt-br/assuntos/monitoramento-e-eventos-criticos/qualidade-da-agua>>. Acesso em: 13 jan. 2024.
- BRASIL. Agência Nacional de Águas e Saneamento Básico (ANA). **Rio Doce**. [Brasília]: ANA, 2025. Disponível em: <<https://www.gov.br/ana/pt-br/sala-de-situacao/rio-doce/rio-doce-saiba-mais>>.
- BRASIL. Agência Espacial Brasileira. **Dados ambientais**. [Brasília]: Agência Espacial Brasileira, 10 out. 2023. Disponível em: <<https://www.gov.br/aeb/pt-br/acoes-e-programas/aplicacoes-espaciais/dados-ambientais>>. Acesso em: 15 jan. 2024.
- BRASIL. Fundação Nacional de Saúde. **Manual de controle da qualidade da água para técnicos que trabalham em ETAS**. 1. ed. Brasília, DF. 2014.
- BRASIL. Fundação Nacional de Saúde. **Manual prático de análise de água**. 4. ed. Brasília, DF. 2013.
- BRASIL. Mapeamento e Análise Espectro-Temporal das Unidades de Conservação de Proteção Integral da Administração Federal no Bioma Caatinga. **Relatório Parcial da Pesquisa**. Recife, PE. 2015.
- BRASIL. Instituto Nacional de Pesquisas Espaciais. **CBERS**. [Brasília]: INPE, 2024. Disponível em: <<https://www.gov.br/inpe/pt-br/area-conhecimento/engenharia-e-ciencias-espaciais/cgce/tecnologia-espacial/cbers>>. Acesso em: 13 jan. 2024.

BRASIL. Lei nº14.026, de 15 de julho de 2020. Atualiza o marco legal do saneamento básico e altera a Lei nº 9.984, de 17 de julho de 2000, para atribuir a Agência Nacional de Águas e Saneamento Básico (ANA) competência para editar normas de referência sobre o serviço de saneamento, a Lei nº10.768, de 19 de dezembro de 2003, para alterar o nome e as atribuições do cargo de Especialista em Recursos Hídricos, a Lei nº 11.107, de 6 de abril de 2005, para vedar a prestação por contrato de programa dos serviços públicos de que trata o art. 175 da Constituição Federal, a Lei nº 11.445, de 5 de janeiro de 2007, para aprimorar as condições estruturais do saneamento básico no País, a Lei nº 12.305, de 2 de agosto de 2010, para tratar dos prazos para a disposição final ambientalmente adequado dos rejeitos, a Lei nº 13.089, de 12 de janeiro de 2015 (Estatuto da Metrópole), União a participar de fundo com a finalidade exclusiva de financiar serviços técnicos especializados. **Diário Oficial da União**: 16/07/2020. Disponível em: <https://www.planalto.gov.br/ccivil_03/_ato2019-2022/2020/lei/l14026.htm>. Acesso em: 25 mar. 2025.

BRASIL. Ministério Público Federal. **MPF**. [Brasília]: MPF, 2017. Disponível em: <<https://www.mpf.mp.br/grandes-casos/caso-samarco/atuacao-do-mpf/pareceres-e-relatorios/instituto-lactec>>. Acesso em: 15 mar. 2025.

BANGIRA, T. *et al.* *Comparing Thresholding with Machine Learning Classifiers for Mapping Complex Water*. **Remote Sensing**, v. 1351, n.11, 2019.

BREIMAN, L. *et al.* *Classification and Regression Trees*. 1ª Ed. **New York: Chapman and Hall/CRC**, 1984.

BRITO, H. C. *et al.* *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.

CAO, P. *et al.* *Using a Digital Camera Combined With Fitting Algorithm and T-S Fuzzy Neural Network to Determine the Turbidity in Water*. **IEEE Access**, 2019.

CHOWDHURY, M. *Monitoring turbidity in a highly variable estuary using Sentinel 2-A /B for ecosystem management applications*. **Frontiers in Marine Science**, 2023.

COUTINHO, J. V. S. *Análise dos parâmetros físico-químicos no controle de qualidade de amostras hídricas tratadas em ETAs, e a relação entre saúde e desregulações ambientais*. **Brazilian Journal of Animal and Environmental Research**, v. 5, n. 4, p. 4332-4341, 2022.

CRIONI, P. L. B.; TERAMOTO, E. H.; CHANG, H. K. *Monitoring River turbidity after a mine tailing dam failure using an empirical model derived from Sentinel-2 imagery. Anais da Academia Brasileira de Ciências*, v. 95, n. 1, 2023.

UNIÃO EUROPEIA/ESA/COPERNICUS. *Harmonized Sentinel-2 MSI: MultiSpectral Instrument, Level-2A (SR). Earth Engine Data Catalog*. Disponível em: <https://developers.google.com/earth-engine/datasets/catalog/COPERNICUS_S2_SR_HARMONIZED?hl=pt-br#bands>. Acesso em: 26 jan. 2025.

FENSHOLT, R. *Analysing the advantages of high temporal resolution geostationary MSG SEVIRI data compared to Polar Operational Environmental Satellite data for land surface monitoring in Africa. International Journal of Applied Earth Observation and Geoinformation*, 2011.

FUNG, C. H.; WONG, M. S.; CHAN, P. W. *Spatio-Temporal Data Fusion for Satellite Images Using Hopfield Neural Network. Remote Sensing*, v. 11, 2019.

GAIDA, W. *et al.* Correção Atmosférica em Sensoriamento Remoto: Uma Revisão. *Revista Brasileira de Geografia Física*, v. 13, n. 1, p. 229-258, 2020.

GARG, V.; AGGARWAL, S. P.; CHAUHAN, P. *Changes in turbidity along Ganga River using Sentinel-2 satellite data during lockdown associated with COVID-19. Geomatics, Natural Hazards and Risk*, v.11, n. 1, p. 1175-1195, 2020.

KABIR, S. *et al.* *An integrated approach of Belief Rule Base and Convolutional Neural Network to monitor air quality in Shanghai. Expert Systems With Applications*, v. 206, 2022.

KANG, Y.; SUNG, T.; IM, J. *Toward an adaptable deep-learning model for satellite-based wildfire monitoring with consideration of environmental conditions. Remote Sensing of Environmental*, v.298, 2023.

LAONAMSAI, J. *et al.* *Utilizing NDWI, MNDWI, SAVI, WRI, and AWEI for Estimating Erosion and Deposition in Ping River in Thailand. Hydrology*, v. 10, n. 70, 2023.

LEÃO, P. L. F.; SOUZA, P. V. N. C. S. *Desenvolvimento sustentável e o Novo Marco Legal do Saneamento Básico (Lei 14.026/2020) com foco no ODS nº 6. Revista do Instituto de Direito Constitucional e Cidadania*, v. 7, n. 1, p. e055, 2023.

LEGGESSE, E. S. *et al.* *Predicting Optical Water Quality Indicators from Remote Sensing Using Machine Learning Algorithms in Tropical Highlands of Ethiopia. Hydrology*, n. 10, v. 110, 2023.

- LEUZINGER, M. D. *et al.* Desastres humanos? Uma análise de Mariana a Brumadinho tendo em vista seus impactos ambientais / *Human disasters? an analysis from Mariana to Brumadinho in view of its environmental impacts*. **Revista de Direito da Cidade**, v. 14, n. 3, p. 1965–1992, 2022.
- LI, J. *et al.* *A Review of Remote Sensing for Environmental Monitoring in China*. **Remote Sensing**, v. 12, 2020.
- LIMA, D. L. *et al.* Revisão Bibliométrica sobre Turbidez e Sólidos Suspensos por Sensoriamento Remoto. **Anuário do Instituto de Geociências**, v. 42, n. 1, p. 107–116, 2019.
- LIN, X. *et al.* *Water turbidity dynamics using random forest in the Yangtze River Delta Region, China*. **Science of the Total Environment**, v. 903, 2023.
- MA, Y. *et al.* *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.
- MACHADO, M. T. S.; BAPTISTA, G. M. M. Sensoriamento remoto como ferramenta de monitoramento da qualidade da água do Lago Paranoá (DF). **Engenharia Sanitaria e Ambiental**, v. 21, n. 2, p. 357–365, 2016.
- MENEZES, J. F. F. *et al.* Contaminação de águas superficiais por agrotóxicos: análise dos impactos causados na saúde humana e ambiental. **Biológicas & Saúde**, v. 11, n. 37, p. 19–35, 2021.
- MINAS GERAIS. CBMMG alerta para o risco de cabeça d'água no verão, **Corpo de Bombeiros Militar de Minas Gerais**. Minas Gerais, 2025.
- MINAS GERAIS (Belo Horizonte). Deliberação nº04 de 09 de agosto de 2017. Aprova o Zoneamento Ambiental Produtivo da sub-bacia do rio Gualaxo do Norte. **Comitê Gestor do Zoneamento Ambiental e Produtivo – ZAP**, 2017.
- MINAS GERAIS. Sistema Integrado de Informação Ambiental. Relatório de Avaliação do Desempenho Ambiental. [Belo Horizonte]: **SIAM**, 2013. Disponível em: <<https://www.siam.mg.gov.br/siam/lc/2013/0001519840952013/7086862013.pdf>>. Acesso em: 15 mar. 2025.
- MONTOYA, M. A. A pegada hídrica da economia brasileira e a balança comercial de água virtual: uma análise insumo-produto. **Economia Aplicada**, v. 24, n. 2, p. 215–248, 2020.

NAKANO, N. M. *et al.* Saúde e meio ambiente: um estudo sobre a qualidade da água em um Assentamento Rural em Ribeirão Preto, SP. **Enfermagem Brasil**, v. 21, n. 6, p.740-752, 2022.

NOVOA, S. *et al.* *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. 61, n. 9, 2017.

PARANÁ. Banho de rio seguro: 10 dicas dos Bombeiros para evitar cabeça d'água e outros riscos, **Corpo de Bombeiros Militar do Paraná**. Paraná, 2025.

RASPOLINI, P. *et al.* *Level 2 processor and auxiliary data for ESA Version 8 final full mission analysis of MIPAS measurements on ENVISAT.* **Atmospheric Measurement Techniques**, v. 15, p.1871-1901, 2022.

RODRIGUES, G. A.; MACHADO, G. E. M. Estado de ocupação das margens do Rio Macacu – Rio de Janeiro (Brasil): diagnóstico preliminar. **Pesquisa e Ensino em Ciências Exatas e da Natureza**, 2020.

RUDORFF, N. *et al.* *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 Journal of Photogrammetry and Remote Sensing**, v. 145, p. 349-361, 2018.

SANTOS, A. B. L. P. *et al.* Saneamento e Qualidade de Água: uma análise sob as perspectivas dos bairros incluídos no percurso do riacho das Piabas em Campina Grande - PB. **Revista Contemporânea**, v.4, n.1, 2024.

SANTOS, G. D.; SANTOS, J. L. O; LEITE, O. D. Variação espaço-temporal da qualidade da água nos canais de irrigação do Projeto Formoso em Bom Jesus da Lapa – Bahia. **Revista de Gestão de Água da América Latina**, v.16, n.3, 2019.

SANTOS, G. P. *et al.* Efeitos da integridade ambiental da zona ciliar e sua influência na qualidade da água de igarapés urbanos em Santarém-PA, Amazônia, Brasil. **Revista Brasileira de Geografia Física**, v. 14, n. 7, p. 4035-4055, 2021.

SILVA, M. G. G.; ROCHA, D. A.; PEIXOTO, Z. M. A. Metodologia para análise limnológica: estudo de caso em Três Marias – MG – Brasil. **Revista Científica Multidisciplinar Núcleo do Conhecimento**, v.8, n.12, p. 55-80, 2022.

SÃO PAULO. Companhia Ambiental do Estado de São Paulo. **Qualidade das águas interiores no estado de São Paulo**. São Paulo: CETESB, 2023.

SOUZA, M. E. V.; ELMIRO; M. A. T.; CARVALHO, L. A. S. A Influência da Cortina Retentora de Resíduos na Qualidade da Água da Lagoa da Pampulha – Belo Horizonte/MG. **Anuário do Instituto de Geociências – UFRJ**, v. 12, n. 4, p. 259-266, 2019.

TONIOLO, G. R. *et al.* Identificação de constituintes opticamente ativos na água do Lago Guaíba a partir de dados de sensores orbitais e espectrorradiometria de campo. **Pesquisas em Geociências**, v. 45, 2018.

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.

WANG, *et al.* *The Assessment of Landsat-8 OLI Atmospheric Correction Algorithms for Inland Waters.* **Remote Sensing**, 2019.

ZHANG, P. *et al.* *A method for remote sensing image restoration based on the system degradation model.* **Results in Physics**, v. 56, 2024.

ZHANG, X.; HAN, L. *A Generic Self-Supervised Learning (SSL) Framework for Representation Learning from Spectral-Spatial Features of Unlabeled Remote Sensing Imagery.* **Remote Sensing**, v. 15, 2023.

ZHU, Y. *et al.* *Development of a New Method for Turbidity Measurement Using Two NIR Digital Cameras.* **ACS Omega 2020**, v. 5, p. 5421–5428, 2020.