

## 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*

Laura Coelho de Andrade<sup>1</sup>; Tiago Oliveira Lopes<sup>2</sup>; Nilcilene das Graças Medeiros<sup>3</sup>; Italo Oliveira Ferreira<sup>4</sup>; Afonso de Paula dos Santos<sup>5</sup>; William Rodrigo Dal Poz<sup>6</sup>

- <sup>1</sup> Universidade Federal de Viçosa/Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: [laura.andrade@ufv.br](mailto:laura.andrade@ufv.br)  
**ORCID:** <https://orcid.org/0000-0003-3693-2208>
- <sup>2</sup> Universidade Federal de Viçosa/Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: [tiago.lopes@ufv.br](mailto:tiago.lopes@ufv.br)  
**ORCID:** <https://orcid.org/0009-0007-0067-6923>
- <sup>3</sup> Universidade Federal de Viçosa/Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: [nilcilene.medeiros@ufv.br](mailto:nilcilene.medeiros@ufv.br)  
**ORCID:** <https://orcid.org/0000-0003-0839-3729>
- <sup>4</sup> Universidade Federal de Viçosa/Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: [italo.ferreira@ufv.br](mailto:italo.ferreira@ufv.br)  
**ORCID:** <https://orcid.org/0000-0002-4243-8225>
- <sup>5</sup> Universidade Federal de Viçosa/Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: [afonso.santos@ufv.br](mailto:afonso.santos@ufv.br)  
**ORCID:** <https://orcid.org/0000-0001-7248-4524>
- <sup>6</sup> Universidade Federal de Viçosa/Departamento de Engenharia Civil, Viçosa/MG, Brasil. Email: [dalpoz@gmail.com](mailto:dalpoz@gmail.com)  
**ORCID:** <https://orcid.org/0000-0001-9532-3643>

**Resumo:** A qualidade da água em reservatórios é fundamental para a preservação dos ecossistemas e da saúde humana. A turbidez, que avalia a presença de partículas suspensas, é um indicador importante, geralmente medido in loco com equipamentos onerosos. No entanto, com o avanço da Inteligência Artificial (IA), é possível estimar a turbidez usando imagens orbitais associadas a índices como o NDTI (Normalized Difference Turbidity Index). Além de sensores orbitais, outra tecnologia que vem sendo muito utilizada para vários fins são as aeronaves remotamente pilotadas (RPA's) que possibilitam a geração de produtos fotogramétricos digitais como Modelos Digitais de Elevação e Ortofotografias em grandes níveis de detalhes. Nesse sentido, este estudo visa estimar a turbidez em reservatórios usando imagens de RPA e técnicas de Machine Learning como a RNA (Redes Neurais Artificiais), SVM (Support Vector Machine), GBM (Gradient Boosting Machine) e RF (Random Forest). Assim, foram feitos levantamentos in loco com o equipamento turbidímetro e com RPA para obtenção dos dados para análise de regressão para correlacionar os dados. Por meio dos resultados obtidos, pôde-se perceber que a predição da turbidez utilizando o RF e a RNA apresentaram os melhores desempenhos.

**Palavras-chave:** Sensoriamento Remoto; Qualidade da água; Análise de dados; Inteligência Artificial.

**Abstract:** The water quality in reservoirs is crucial for the preservation of ecosystems and human health. Turbidity, which assesses the presence of suspended particles, is an important indicator typically measured on-site with expensive equipment. However, with the advancement of Artificial Intelligence (AI), it is possible to estimate turbidity using orbital images associated with indices such as NDTI (Normalized Difference Turbidity Index). In addition to orbital sensors, another technology widely used for various purposes is remotely piloted aircraft (RPA), which enables the generation of digital photogrammetric products like Digital Elevation Models and high-detail Orthophotos. In this context, this study aims to estimate turbidity in reservoirs using RPA images and Machine Learning techniques such as Artificial Neural Networks (ANN), Support Vector Machine (SVM), Gradient Boosting Machine (GBM), and Random Forest (RF). To achieve this, on-site surveys were conducted using turbidimeters and RPAs to obtain data for regression analysis to correlate the information. Based on the results obtained, it was observed that the prediction of turbidity using RF and ANN exhibited the best performance.

**Keywords:** Remote Sensing; Water quality; Data Analysis; Artificial Intelligence.

## 1. Introdução

Os reservatórios e corpos hídricos desempenham um papel fundamental na garantia do fornecimento de água para a população. Eles armazenam grande quantidade desse recurso que é utilizado em diversas atividades, como consumo humano, agricultura e geração de energia hidrelétrica (GLEICK, 2003; AWANGE, 2022). O monitoramento contínuo desses corpos hídricos é essencial para identificar possíveis problemas, como a redução do volume de água ou a contaminação por poluentes, permitindo que medidas corretivas sejam adotadas antes que ocorram problemas mais graves (O'REILLY *et al.*, 2003; WOOLWAY *et al.*, 2020). A medição de profundidade dos reservatórios é uma das principais formas de monitoramento, permitindo avaliar a quantidade de água armazenada e identificar assoreamentos ou erosões no corpo hídrico (FERREIRA; RODRIGUES; SANTOS, 2015; ANDRADE *et al.*, 2020).

Além disso, sabe-se que a turbidez também é um fator importante que pode afetar a qualidade da água, sendo definida, segundo Hossain, Mathias e Blanton (2021), como uma medida de transparência da água, derivada da dispersão da luz devido a presença de materiais particulados em suspensão em um corpo d'água. De acordo com Xiao *et al.* (2021), a avaliação das variações na turbidez é uma ferramenta essencial para compreender como os sedimentos ou partículas suspensas estão distribuídos no ambiente aquático, além de fornecer informações práticas para estudar como os poluentes se depositam, se decompõem e se difundem na água.

De acordo com Allam, Khan e Meng (2020), o sensoriamento remoto é uma técnica eficiente para monitorar o ambiente aquático, pois permite avaliar diferentes aspectos em tempo real e em grande escala. Por meio de diferentes plataformas, como satélites artificiais e RPA's (Remotely Pilot Aircrafts), é possível obter imagens e informações detalhadas do ambiente aquático, o que permite avaliar de forma mais precisa as variáveis ambientais relevantes, como a qualidade da água, a presença de poluentes, a turbidez, entre outras.

Segundo Prior *et al.* (2020), as RPA's oferecem ao usuário flexibilidade para obter informações, além de permitir um controle preciso da resolução espacial das imagens capturadas. Com essa tecnologia, é possível coletar dados em áreas perigosas ou de difícil acesso e planejar, a priori, a resolução espacial da imagem a ser adquirida. Além disso, ele pode ser controlado remotamente, garantindo a segurança do usuário e tornando a coleta de dados mais eficiente.

O progresso da tecnologia também propiciou a otimização da Inteligência Artificial e por conseguinte, da técnica de Machine Learning. O desenvolvimento dessas ferramentas associadas ao sensoriamento remoto ótico, sobretudo na área ambiental, em estudos preliminares, é capaz de proporcionar avanços e facilidades significativas no levantamento de informações. Autores, como Li *et al.* (2023), utilizaram imagens do Sentinel-3 OLCI para estimativa da turbidez da água de um lago chinês, empregando os algoritmos SR (Simple Regression), PLSR (Partial Least Squares Regression), SVR (Support Vector Regression), BP (Backpropagation neural network), KNN (K-nearest neighbor), RF (Random Forest) e o XGBoost (Extreme Gradient Boosting). Nesse estudo foi observada uma superioridade no desempenho do RF sobre os demais, obtendo um  $R^2$  de 0.92 e um RMSE de 12.65 NTU (Nephelometric Turbidity Unity). Ma *et al.* (2021) efetuaram estudos sobre a estimativa da turbidez da água com imagens Sentinel 2A e algoritmos de machine learning e encontraram o GBDT (Gradient Boosting Decision Tree) como o melhor método de regressão, apresentando melhores valores de desempenho.

Nesse sentido, o principal objetivo deste trabalho consiste em realizar a estimativa da turbidez de corpos hídricos empregando os algoritmos de Machine Learning: SVM (Support Vector Machine), GBM (Gradient Boosting Machine), RF (Random Forest) e RNA (Redes Neurais Artificiais) e imagens de RPA's.

## 2. Área de Estudo

A área de realização do estudo está localizada no município de Viçosa - MG, dentro da Universidade Federal de Viçosa e possui aproximadamente 1,16 ha (Figura 1).

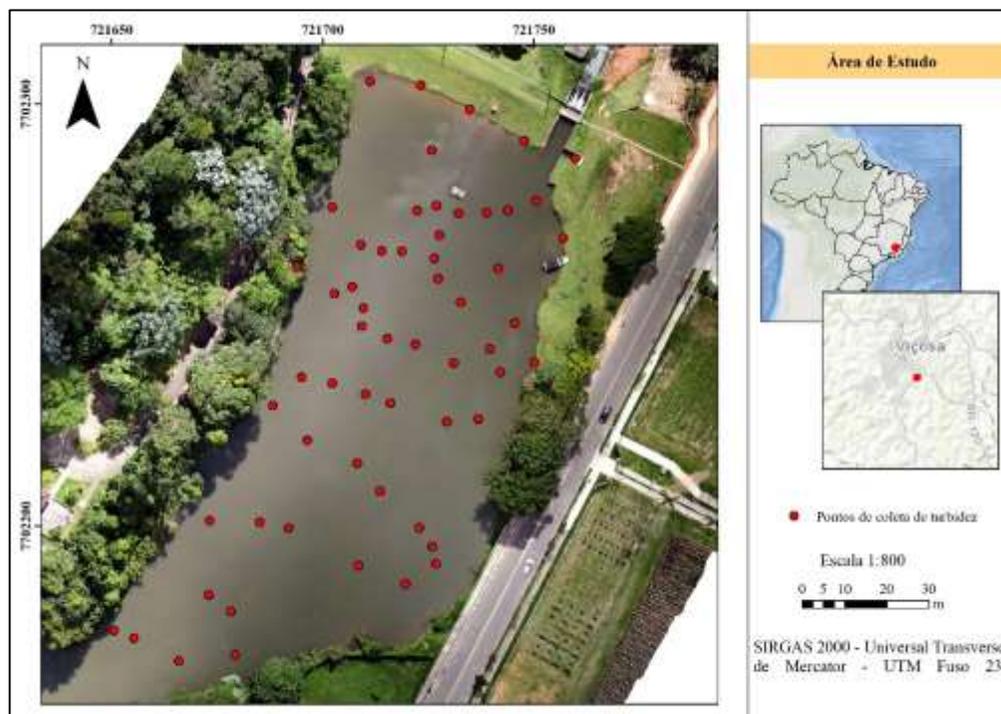


Figura 1 – Área de estudo contendo os pontos de coleta de turbidez da água.  
 Fonte: Autores (2023).

É importante ressaltar que este corpo hídrico, assim como outros reservatórios presentes na Universidade, desempenha um papel crucial no abastecimento da população de Viçosa durante o período de estiagem.

### 3. Metodologia

A metodologia adotada neste estudo pode ser observada no fluxograma apresentado na Figura 2.



Figura 2 – Fluxograma da metodologia.  
 Fonte: Autores (2023).

### 3.1. Levantamento e processamento dos dados

Para iniciar o estudo em questão, foi necessária a execução do levantamento aerofotogramétrico. Assim, foi efetuado o plano de voo com 80% de sobreposição longitudinal e 70% lateral, e uma altitude de 80 m. O voo foi realizado com a aeronave Mavic Air 2S e ao final foram adquiridas 55 fotografias e um GSD médio de 2.66 cm/pixel. Ademais, também foram coletados 7 pontos de controle e 7 pontos de checagem com o GNSS (Global Navigation Satellite System) RTK (Real Time Kinematic) da fabricante Topomap, modelo T10.

O processamento dos dados aerofotogramétricos foi efetuado no software Agisoft Metashape (AGISOFT LCC, 2023), no qual as imagens foram importadas e alinhadas. Posteriormente, foram efetuadas as etapas de importação dos pontos de controle, geração da nuvem de pontos densa, modelagem da superfície, texturização, geração do Modelo Digital de Superfície (MDS) e por fim, o ortomosaico das fotografias empregando o MDE gerado e as informações de calibração da câmera.

Além disso, também foi realizada a coleta dos pontos de turbidez da água com o turbidímetro TU430 da AKSO (Figura 3) e para o georreferenciamento das amostras, foi utilizado o GNSS RTK T10 da Topomap (Figura 4). Destaca-se que os pontos foram coletados de forma aleatória, com uma densidade de aproximadamente 51 amostras/ha. Autores como Zhao et al (2011), Bonansea et al. (2015) e Su e Chou (2015), realizaram a coleta de amostras em corpos hídricos e concluíram que é necessário no mínimo 9 amostras/ha para correta compreensão da variabilidade da turbidez da água na área de estudo. Na Figura 1 foi apresentada a distribuição das amostras. Para verificação dos dados de turbidez, foram efetuadas análises estatísticas nas amostras.



Figura 3 – Turbidímetro Digital TU340.  
Fonte: AKSO (2023).



Figura 4 – GNSS RTK T10.  
Fonte: Topomap (2023).

O levantamento batimétrico também foi efetuado para complementar a análise, para isso foi utilizado o ecobatímetro monofeixe E20 da Teledyne Odom, com frequência de 210 kHz. Para o posicionamento horizontal da embarcação, um par de receptores GNSS RTK foi empregado. Nesse sentido, foram levantadas 06 linhas longitudinais de sondagem e 02 linhas transversais de verificação. Esses dados batimétricos foram processados no software Hypack 2021 (HYPACK, 2021) e

interpolados pelo método IDW (Inverse Distance Weighted), no software ArcGis 10.5 (ESRI, 2016), para a geração do Modelo Digital de Profundidade (MDP), em que os valores referentes a profundidade estão dispostos de forma contínua.

### 3.2. Análise dos dados

Após a criação do ortomosaico foi possível efetuar a correlação entre os valores digitais dos pixels com o MDP da batimetria e as amostras de turbidez da água. Ressalta-se que para melhor compatibilização dos dados, as amostras de turbidez também foram interpoladas utilizando o interpolador IDW, criando-se assim um Modelo Digital da Turbidez (MDT), tal como efetuado por Dezordi *et al.* (2019).

Ademais, foi efetuado o cálculo do NDTI (Normalized Difference Turbidity Index), com o intuito de utilizá-lo a posteriori para o aprimoramento do treinamento dos algoritmos de Machine Learning (Equação 1).

Equação 1 Índice da Diferença Normalizada da Turbidez (NDTI)

$$NDTI = \frac{\rho_{red} - \rho_{green}}{\rho_{red} + \rho_{green}} \quad (1)$$

Em que  $\rho_{red}$  consiste nos valores de brilho da ortofoto para a banda da luz vermelha e  $\rho_{green}$  nos valores de brilho para a banda da luz verde.

O NDTI trata-se de um índice criado por Lacaux *et al.*, (2007) e empregado por autores como Cahalane *et al.* (2019) para predição da profundidade com imagens Landsat 8, Pleiades e Rapideye. Esses autores observaram que a turbidez da água pode resultar em valores maiores de radiância para a faixa do visível e também para o NIR (Near Infra-Red), subestimando profundidades em locais mais profundos (6 m a 10 m) (CASAL *et al.*, 2019). Lacaux *et al.*, (2007) ainda afirma que, em locais de águas turvas, a radiação eletromagnética correspondente à luz vermelha pode chegar a ter uma resposta maior se comparada com a luz verde.

### 3.3. Estimativa da Turbidez com Machine Learning

De posse dos pontos gerados a partir do MDT (Modelo Digital da Turbidez), com os valores correlacionados das bandas da ortofoto, profundidade, bem como o NDTI supracitado, foi gerada uma base de dados contendo também as coordenadas UTM dos pontos para inserção nos algoritmos RF (Random Forest), GBM (Gradient Boosting Machine), SVM (Support Vector Machine) e RNA (Redes Neurais Artificiais) no software R (R CORE TEAM, 2023).

Em todos os algoritmos foram selecionados, de forma aleatória, 70% da amostra de pontos para o treinamento dos métodos empíricos a serem avaliados, e os 30% restantes para o teste da predição. Autores como Verrelst *et al.* (2012), Cahalane *et al.* (2019) e Mateo-Pérez *et al.* (2020) utilizaram esse método de separação dos dados para treinamento e teste e obtiveram resultados sem tendência, com bom desempenho.

Ressalta-se ainda que para uma avaliação coerente em relação aos algoritmos, foi definida uma semente, denominada “seed” para os algoritmos selecionarem as amostras sempre na mesma ordem, ou seja, sempre pegando o mesmo conjunto de dados.

Para o SVM foi utilizado como método de treinamento o “svmRadial” visto que esse forneceu melhores resultados para a amostra selecionada. Autores como Hong *et al.* (2016) e Harimoorthy e Thangavelu (2021) também empregaram esse método para obtenção de melhores predições.

Já para os algoritmos GBM e RF, foram utilizados os métodos “gbm” e “rf” respectivamente, visto que é o padrão para fazer a predição por esses métodos de Machine Learning. A RNA contou com uma camada escondida, quatro camadas intermediárias, correspondentes ao valor de brilho para as bandas do visível da ortofoto, bem como os valores calculados do NDTI, e uma camada de saída, correspondente a turbidez. Ademais, a RNA foi treinada e avaliada com o pacote “neuralnet”, que emprega a ferramenta do “backpropagation” no processo de aprendizado.

### 3.4. Qualidade da estimativa

Para realização de uma avaliação dos resultados obtidos, a priori foi efetuada uma análise exploratória das discrepâncias encontradas a partir dos valores de turbidez de referência em relação aos valores estimados com os algoritmos supracitados.

Para posterior análise e comparação de todos os métodos, foram armazenados os valores das discrepâncias abordadas neste trabalho por meio do RMSE (Root Mean Square Error), MAE (Mean Average Error) e  $R^2$  (coeficiente de correlação) (Equações 2, 3 e 4).

Equação 2 Erro Médio Absoluto (MAE)

$$MAE = \frac{1}{n} \sum_{j=1}^n |t_i - tpredi| \quad (2)$$

Equação 3 Raiz do Erro Médio Quadrático (RMSE)

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (t_i - tpredi)^2} \quad (3)$$

Equação 4 Coeficiente de correlação ( $R^2$ )

$$R^2 = \frac{\sum_{i=1}^n (tpredi - tmedia)^2}{\sum_{i=1}^n (t_i - tmedia)^2} \quad (4)$$

Em que  $t_i$  corresponde aos valores das amostras observadas (coletadas com o turbidímetro);  $tpredi$ , o valor das amostras preditas (obtidas pelos métodos de ML);  $tmedia$ , média dos valores observados e  $n$  o número de amostras.

O RMSE e MAE são indicadores da precisão do valor predito, dessa forma, quando a turbidez estimada e a turbidez predita possuem valores próximos, esses indicadores se aproximaram de zero, ou seja, quanto menor os valores de RMSE e MAE, maior a precisão encontrada pelo método (YANG *et al.*, 2020).

Além disso, para espacialização e melhor visualização dos dados, foram gerados modelos digitais de turbidez com os métodos empregados, no software ArcGIS 10.5 (ESRI, 2016).

#### 4. Resultados e discussão

A primeira etapa na execução da metodologia adotada foi efetuar uma análise estatística dos dados de turbidez coletados in loco através do turbidímetro (Tabela 1).

*Tabela 1 – Análise estatística dos pontos de turbidez.*

	<b>Média</b>	<b>Erro padrão</b>	<b>Desvio padrão</b>	<b>Variância da amostra</b>	<b>Curtose</b>	<b>Assimetria</b>	<b>Mínimo</b>	<b>Máximo</b>
<b>Turbidez (NTU)</b>	5.4	0.11	0.84	0.7	0.87	0.02	3.64	8

*Fonte: Autores (2023).*

Pode-se verificar na Tabela 1, a partir dos valores mostrados, uma baixa variabilidade da amostra dos dados de turbidez, com uma diferença do maior para o menor valor de 4,36 NTU. Em seguida, com o treinamento e predição pelos algoritmos de Machine Learning, foi possível obter os valores das discrepâncias entre a turbidez observada e a predita, apresentadas por cada método. Assim, foi efetuada uma análise estatística exploratória das discrepâncias (Tabela 2).

Tabela 2 – Análise exploratória das discrepâncias da turbidez para cada algoritmo de Machine Learning

	RF (Random Forest)	RNA (Rede Neural Artificial)	SVM (Support Vector Machine)	GBM (Gradient Boosting Machine)
Média (NTU)	-0.002	-0.003	-0.007	-0.004
Erro padrão (NTU)	0.001	0.002	0.002	0.002
Mediana (NTU)	0.000	0.006	-0.003	0.010
Desvio padrão (NTU)	0.143	0.254	0.241	0.238
Variância da amostra (NTU <sup>2</sup> )	0.020	0.065	0.058	0.057
Curtose	19.195	2.823	5.594	4.133
Assimetria	-0.527	-0.049	-0.595	-0.527

Fonte: Autores (2023).

A partir dos valores ilustrados na Tabela 2, pode-se perceber que o RF apresentou menores valores para média, erro padrão, mediana, desvio padrão e para a variância das discrepâncias, indicando um melhor desempenho. Dentre os demais algoritmos, a RNA apresentou a menor média, no entanto, o desvio padrão, variância e a mediana foram relativamente superiores ao SVM e GBM. Ma et al. (2021) também testou os algoritmos de Machine Learning, onde o RF e o GBDT, similar ao GBM, apresentaram o melhor desempenho para o RMSE e R<sup>2</sup>, diante aos modelos de SVM, KNN, ELM (Extreme Learning Machine).

De forma a complementar as análises exploratórias, foram confeccionados os gráficos de dispersão para os valores preditos e observados (Figura 5).

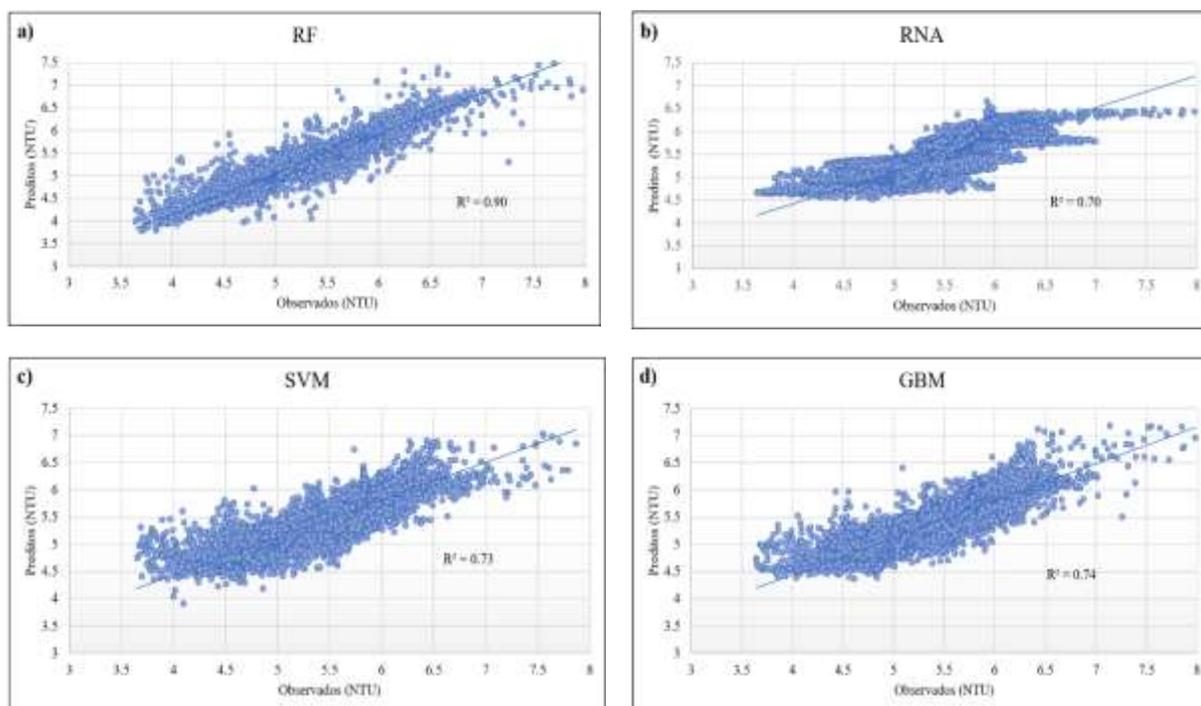


Figura 5 – Gráficos de dispersão entre os valores preditos e observados. a) RF (Random Forest; b) RNA (Redes Neurais Artificiais; c) SVM (Support Vector Machine e d) GBM (Gradient Boosting Machine).

Fonte: Autores (2023).

Nota-se (Figura 5) uma menor dispersão da amostra para os algoritmos RF e GBM, os quais também apresentam valores maiores para o  $R^2$ , de 0.90 e 0.74, respectivamente. Indicando, que o RF evidenciou valores menos dispersos e mais coerentes com aqueles observados. A RNA não efetuou previsões corretas para turbidez menores que 4.5 NTU, nem mesmo para aquelas maiores que 6.5 NTU. Já o SVM apresentou maior dificuldade na previsão da turbidez para valores a partir de 7.0 NTU.

O cálculo da incerteza foi realizado por meio do RMSE, MAE para análise do desempenho e  $R^2$  para avaliação da correlação de cada algoritmo (Tabela 3).

*Tabela 3 – Avaliação do desempenho para cada algoritmo de Machine Learning de acordo com os parâmetros RMSE*

	<b>RMSE (NTU)</b>	<b>MAE (NTU)</b>	<b><math>R^2</math></b>
<b>RNA</b>	0.25	0.18	0.70
<b>SVM</b>	0.60	0.46	0.73
<b>GBM</b>	0.24	0.17	0.74
<b>RF</b>	0.14	0.07	0.90

(*Root Mean Square Error*), *MAE (Mean Absolut Error)* e  *$R^2$  (Coeficiente de Correlação)*.

*Fonte: Autores (2023).*

Ressalta-se que também nessa análise de incerteza (Tabela 3), o RF apresentou o melhor desempenho, com valores de RMSE de 0.14 NTU e MAE de 0.07 NTU. Seguido pelo GBM com um RMSE de 0.24 NTU e 0.17 NTU para o MAE. Apesar da RNA ter apresentado valores próximos ao GBM, por meio da análise do gráfico da dispersão realizada previamente, pode-se afirmar que a mesma não se encaixa como um modelo adequado para os dados em questão. Ma et al. (2021) também encontrou um baixo desempenho utilizando a RNA e SVM para estimativa da turbidez com imagens Sentinel 2A no nordeste da China. Li et al. (2023) obteve a melhor previsão da turbidez da água utilizando o algoritmo do RF para imagens Sentinel 3, com os melhores valores de RMSE e  $R^2$ .

Posteriormente, foram gerados os Modelos Digitais de Turbidez, com auxílio do interpolador IDW para cada método de Machine Learning (Figura 6).

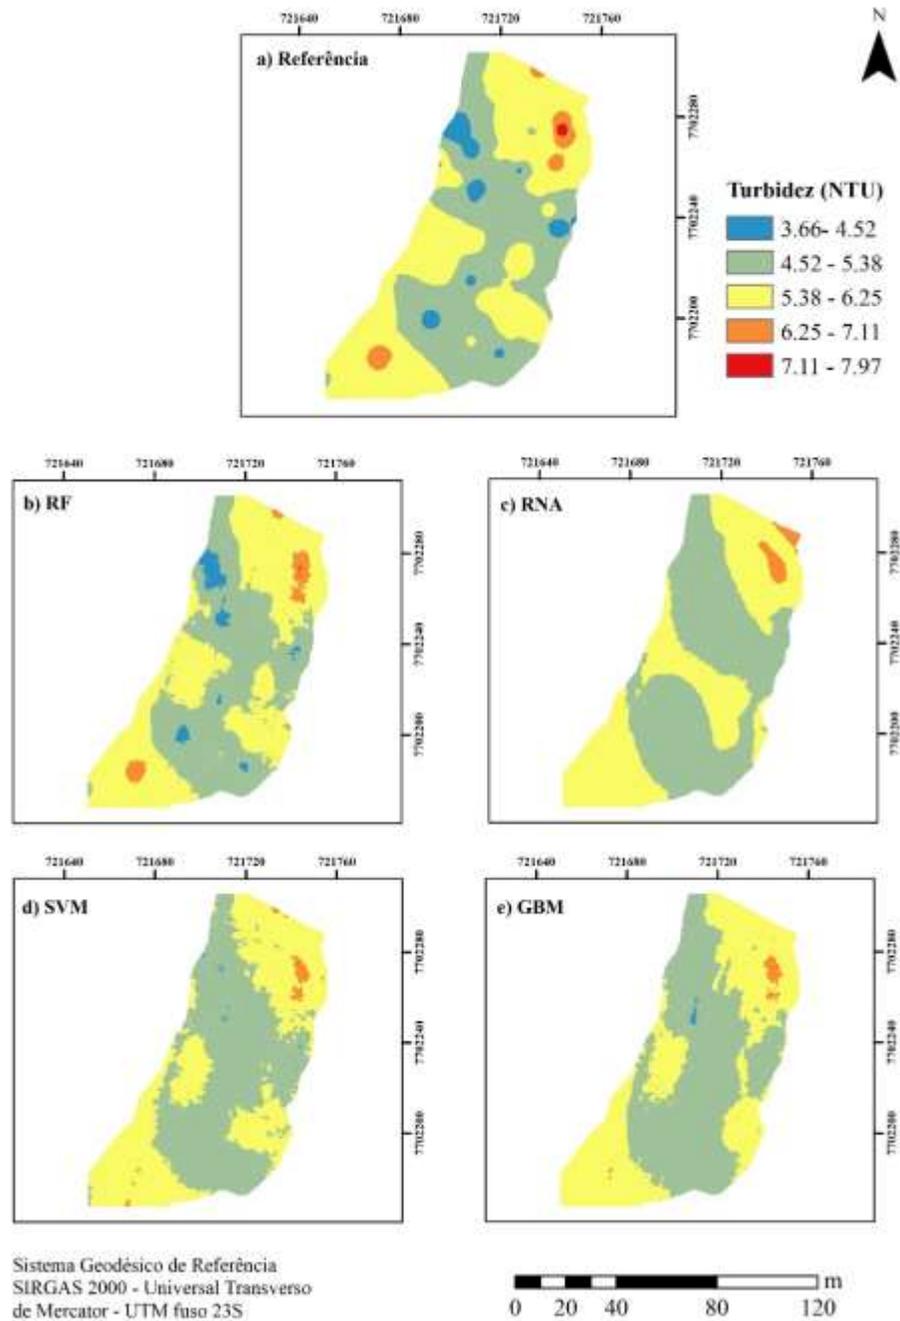


Figura 6 – MDTs para os métodos de Machine Learning a) Referência; b) RF (Random Forest; c) RNA (Redes Neurais Artificiais; d) SVM (Support Vector Machine e) GBM (Gradient Boosting Machine).  
 Fonte: Autores (2023).

Os MDTs auxiliam de forma significativa na visualização espacializada da turbidez estimada para cada algoritmo. Nesse sentido, analisando a Figura 4, pode-se verificar que o RF consiste no método que mais se aproximou com o MDT de referência do reservatório, apresentando pontos similares com valores altos e baixos de turbidez. Por outro lado, os

demais algoritmos apresentam uma modelagem com menos similaridade em relação ao MDT de referência, sobretudo a RNA, em que os valores de turbidez foram suavizados. Autores como Keller et al. (2018), também obtiveram um pior desempenho dos modelos com a RNA, empregando o algoritmo de Backpropagation em imagens hiperespectrais.

Acredita-se que o RF apresentou o melhor desempenho em todas as análises devido ao fato de ser um algoritmo mais robusto e menos sensível a possíveis outliers que eventualmente possam existir no conjunto de dados. Além disso, o RF também é capaz de construir árvores de decisão independentes, o que o torna mais efetivo em dados ruidosos. Geralmente a RNA não é muito eficaz em amostras contaminadas de outliers e em casos de grande complexidade nos dados; a arquitetura da rede deve ser modificada inúmeras vezes para obtenção do melhor resultado, podendo gerar grande esforço computacional (RAUDYS; JAIN, 1990; YEO; JOHNSON, 2000; BISHOP, 2006).

#### 4. Considerações finais

O estudo e monitoramento contínuo de rios e reservatórios configura-se como uma tarefa importante para a manutenção eficaz dos recursos hídricos disponíveis no mundo. A turbidez é um parâmetro essencial para subsidiar conclusões a respeito da qualidade de um corpo d'água. Nesse contexto, os resultados apresentados destacam a eficácia do uso de imagens de RPA, associadas as técnicas de Machine Learning para estimar a turbidez da água em reservatórios. Esta abordagem proposta pode ser aplicada em larga escala para monitorar a qualidade da água em reservatórios, fornecendo informações valiosas para órgãos responsáveis pela gestão dos recursos hídricos.

O emprego de técnicas de Machine Learning, sobretudo do RF, pode auxiliar de forma significativa na predição da turbidez da água de reservatórios de forma precisa, rápida e com baixo custo. É possível afirmar também que o GBM é um algoritmo em potencial para ser utilizado nesse âmbito, no entanto, novos testes em áreas de estudo distintas, com diferentes valores de hiperparâmetros devem ser testados para tal constatação.

Assim, recomenda-se, para trabalhos futuros, a execução do estudo em áreas diferentes e também alternando os hiperparâmetros da RNA, de modo que não exija muito esforço computacional. O algoritmo do SVM também pode ser aprimorado com a alteração nos hiperparâmetros e com a troca da área de estudo. Além disso, a execução de uma análise de detecção de outliers no conjunto de dados original também pode fornecer predições ainda mais otimizadas para os algoritmos de *Machine Learning*.

#### Agradecimentos

O presente trabalho foi realizado com apoio ao CNPq – Conselho Nacional de Desenvolvimento Científico e Tecnológico.

#### Referências

- AGISOFT LLC. Agisoft Metashape 1.8.0—Professional edition: Agisoft LLC software.2023
- AKSO. Turbidímetro Digital TU340. Disponível em: <https://akso.com.br/product/turbidimetro-digital-tu430/>
- ALLAM, M.; YAWAR ALI KHAN, M.; MENG, Q. Retrieval of turbidity on a spatio-temporal scale using Landsat 8 SR: a case study of the Ramganga River in the Ganges Basin, India. **Applied Sciences**, v. 10, n. 11, p. 3702, 2020. DOI: <https://doi.org/10.3390/app10113702>
- ANDRADE, L. C.; FERREIRA, I. O.; SANTOS, F. C. M.; TEIXEIRA, V. G. Estimativa do grau de assoreamento de reservatórios de captação de água: estudo de caso: reservatório da hidráulica, Universidade Federal de Viçosa, Viçosa, Minas Gerais. *Revista Brasileira de Geomática*, 8(1), 040-055.2020. DOI: 10.3895/rbgeo.v8n1.10074
- AWANGE, K. Global freshwater resources. In *Food Insecurity & Hydroclimate in Greater Horn of Africa: Potential for Agriculture Amidst Extremes* (pp.67-83). Cham: Springer International Publishing.2022. DOI: <https://doi.org/10.1007/978-3-030-91002-0>
- BISHOP, C. M. *Pattern Recognition and Machine Learning*. Springer. Capítulo 5: Neural Networks. 2006. ISSN: 1613-9011.

- BONANSEA, M.; RODRIGUEZ, M. C.; PINOTTI, L.; FERRERO, S. Using multi-temporal Landsat imagery and linear mixed models for assessing water quality parameters in Rio Tercero reservoir (Argentina). *Remote Sensing of Environment*, v.158, p.28-41.2015. DOI: <https://doi.org/10.1016/j.rse.2014.10.032>
- CAHALANE, C.; MAGEE, A.; MONTEYS, X.; CASAL, G.; HANAFIN, J.; HARRIS, P. A comparison of Landsat 8, RapidEye and Pleiades products for improving empirical predictions of satellite-derived bathymetry. *Remote sensing of environment*, v. 233, p. 111414, 2019. DOI: <https://doi.org/10.1016/j.rse.2019.111414>
- CASAL, G.; MONTEYS, X.; HEDLEY, J.; HARRIS, P.; CAHALANE, C.; MCCARTHY, T. Assessment of empirical algorithms for bathymetry extraction using Sentinel-2 data. *International Journal of Remote Sensing*, 40(8), 2855-2879.2019. DOI: <https://doi.org/10.1080/01431161.2018.1533660>
- DEZORDI, R.; KRAMER, G.; DA ROSA, C. N.; DAL OSTO, J. & FILHO, W. P. Análise Da Turbidez Superficial A Partir De Imagens Do Landsat-8 (Sensor OLI) Em Compartimento Aquático Do Reservatório De Itaipu-Pr, Brasil. Anais do XIX Simpósio Brasileiro de Sensoriamento Remoto. 14 a 17 de Abril de 2019. INPE – Santos – SP, Brasil. ISBN: 978-85-17-00097-3.2019.
- ESRI. ArcGIS Desktop: Release 10.5 [Software de computador]. Esri. 2016. <https://www.esri.com/>
- FERREIRA, Í. O.; RODRIGUES, D. D.; SANTOS, G. R.; Coleta, processamento e análise de dados batimétricos: Representação computacional do relevo submerso utilizando interpoladores determinísticos e probabilísticos. 1 ed. Alemanha: Saarbrücken, 2015. 100p.
- FUNASA. Fundação Nacional de Saúde. Manual de Controle da Qualidade da Água para Técnicos que Trabalham com ETAS. 2015.
- GLEICK, P.H. Global freshwater resources: soft-path solutions for the 21st century. *Science*, 302(5650), 1524-1528. 2003. DOI: 10.1126/science.1089967
- HARIMOORTHY, K.; THANGAVELU, M. Multi-disease prediction model using improved SVM-radial bias technique in healthcare monitoring system. *Journal of Ambient Intelligence and Humanized Computing*, v. 12, n. 3, p. 3715-3723, 2021. DOI: <https://doi.org/10.1007/s12652-019-01652-0>
- HONG, H.; PRADHAN, B.; JEBUR, M. N.; BUI, D. T.; XU, C. & AKGUN, A. Spatial prediction of landslide hazard at the Luxi area (China) using support vector machines. *Environmental Earth Sciences*, 75(1), 1-14.2016. DOI: <https://doi.org/10.1007/s12665-015-4866-9>
- HOSSAIN, A. A.; MATHIAS, C.; BLANTON, R. Remote sensing of turbidity in the Tennessee River using Landsat 8 satellite. *Remote Sensing*, v. 13, n. 18, p. 3785, 2021. DOI: <https://doi.org/10.3390/rs13183785>
- HYPACK. HYPACK® (Versão 2021) [Software de computador]. HYPACK - A Xylem Brand. 2021. <https://www.hypack.com/>
- KELLER, S.; MAIER, P. M.; RIESE, F. M.; NORRA, S.; HOLBACH, A.; BÖRSIG, N. & HINZ, S. Hyperspectral data and machine learning for estimating CDOM, chlorophyll a, diatoms, green algae and turbidity. *International journal of environmental research and public health*, 15(9), 1881. 2018. DOI: <https://doi.org/10.3390/ijerph15091881>
- LACAUX, J. P.; TOURRE, Y. M.; VIGNOLLES, C.; NDIONE, J. A.; LAFAYE, M. Classification of ponds from high-spatial resolution remote sensing: Application to Rift Valley Fever epidemics in Senegal. *Remote Sensing of Environment*, 106(1), 66-74.2007. DOI: <https://doi.org/10.1016/j.rse.2006.07.012>
- LI, Y.; LI, S.; SONG, K.; LIU, G.; WEN, Z.; FANG, C.; ZHANG, L. Sentinel-3 OLCI observations of Chinese lake turbidity using machine learning algorithms. *Journal of Hydrology*, 622, 129668.2023. DOI: <https://doi.org/10.1016/j.jhydrol.2023.129668>

- MA, Y.; SONG, K.; WEN, Z.; LIU, G.; SHANG, Y.; LYU, L.; 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*, 14, 9132-9146.2021. DOI: 10.1109/JSTARS.2021.3109292
- MATEO-PÉREZ, V.; CORRAL-BOBADILLA, M.; ORTEGA-FERNÁNDEZ, F.; VERGARA-GONZÁLEZ, E. P. Port bathymetry mapping using support vector machine technique and sentinel-2 satellite imagery. *Remote sensing*, 12(13), 2069.2020. DOI: <https://doi.org/10.3390/rs12132069>
- O'REILLY, C. M.; ALIN, S. R.; PLISNIER, P. D.; COHEN, A. S.; MCKEE, B. A. Climate change decreases aquatic ecosystem productivity of Lake Tanganyika, Africa. *Nature*, 424(6950), 766-768. 2003.
- PRIOR, Elizabeth M.; O'DONNELL, F. C.; BRODBECK, C.; DONALD, W. N.; RUNION, G. B.; SHEPHERD, S. L. Measuring high levels of total suspended solids and turbidity using small unoccupied aerial systems (sUAS) multispectral imagery. *Drones*, v. 4, n. 3, p. 54, 2020. DOI: <https://doi.org/10.3390/drones4030054>
- R CORE TEAM. R: A language and environment for statistical computing (Version 4.3.1) [Software]. R Foundation for Statistical Computing.2023. <https://www.R-project.org/>
- RAUDYS, S. J.; JAIN, A. K. Small sample size effects in statistical pattern recognition: Recommendations for practitioners. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 13(3), 252-264.1990. DOI: 10.1109/ICPR.1990.118138
- SU, T.C.; CHOU, H.T. Application of multispectral sensors carried on unmanned aerial vehicle (UAV) to trophic state mapping of small reservoirs: A case study of Tain-Pu reservoir in Kinmen, Taiwan. *Remote Sensing*, v.7, n.8, p.10078-10097.2015. DOI: <https://doi.org/10.3390/rs70810078>
- TOPOMAP. GNSS RTK T10. Disponível em: <https://topomap.com.br/>
- VERRELST, J.; MUÑOZ, J.; ALONSO, L.; DELEGIDO, J.; RIVERA, J.P.; CAMPSVALLS, G.; MORENO, J. Machine learning regression algorithms for biophysical parameter retrieval: Opportunities for Sentinel-2 and -3. *Remote Sens. Environ.* 2012, 118, 127–139. DOI: <https://doi.org/10.1016/j.rse.2011.11.002>
- WOOLWAY, R. I.; KRAEMER, B. M.; LENTERS, J. D., MERCHANT, C. J., O'REILLY, C. M., & Sharma, S. Global lake responses to climate change. *Nature Reviews Earth & Environment*, 1.8:388-403.2020. DOI: <https://doi.org/10.1038/s43017-020-0067-5>
- XIAO, X.; I. A. O.; JIAN, X. U.; DENG-ZHONG, Z. H. A. O.; BAO-CHENG, Z. H. A. O.; JIAN, X. U.; XUE-JUN, C. H. E. N. G.; GUO-ZHONG, L. I. Research on Combined Remote Sensing Retrieval of Turbidity for River Based on Domestic Satellite data. *Journal of Changjiang River Sci. Res. Inst*, v. 38, p. 128, 2021. DOI: 10.11988/ckyyb.20200337
- YANG, W.; ZHAO, Y.; WANG, D.; WU, H.; LIN, A.; HE, L. Using Principal Components Analysis and IDW Interpolation to Determine Spatial and Temporal Changes of Surface Water Quality of Xin'anjiang River in Huangshan, China. *Int. J. Environ. Res. Public Health*, 17, 2942.2020. <https://doi.org/10.3390/ijerph17082942>
- YEO, I. K.; JOHNSON, R. A. A new family of power transformations to improve normality or symmetry. *Biometrika*, 87(4), 954-959.2000. DOI: <https://doi.org/10.1093/biomet/87.4.954>
- ZHAO, D.; CAI, Y.; JIANG, H.; XU, D.; ZHANG, W.; An, S. Estimation of water clarity in Taihu Lake and surrounding rivers using Landsat imagery. *Advances in Water Resources*, v.34, n.2, p. 165-173, 2011. DOI: <https://doi.org/10.1016/j.advwatres.2010.08.010>