



Revista Brasileira de Geografia Física

Homepage: <https://periodicos.ufpe.br/revistas/rbgfe>



Avaliação da Eficiência de Modelos de Estimativa de Clorofila-a por Sensoriamento Remoto em Reservatórios do Semiárido Brasileiro

Laisa Daiana Alcântara Costa¹, Maycon Breno Macena da Silva¹, Carlinda Raily Medeiros¹, John Elton de Brito Leite Cunha^{1,2}

¹Programa de Pós-graduação em Engenharia Civil e Ambiental (PPGECA) - Universidade Federal de Campina Grande (UFCG). Rua Aprígio Veloso, 882 - Universitário, Campina Grande (PB), CEP 58429-900. E-mails: daiana.laisa@gmail.com; sbrenomacena@gmail.com; carlindarailly@gmail.com. ORCID: <https://orcid.org/0009-0001-0073-9812>; <https://orcid.org/0000-0002-3526-5442>; <https://orcid.org/0000-0002-7332-2399>. ²Professor Adjunto do Centro de Desenvolvimento Sustentável do Semiárido (CDSA) - UFCG. Rua Luiz Grande, S/N - Frei Damião, Sumé (PB), CEP 58540-000. E-mail: john.e.cunha@gmail.com. ORCID: <https://orcid.org/0000-0002-1783-2343>.

Artigo recebido em 16/04/2024 e aceito em 19/07/2024

RESUMO

A estimativa da qualidade da água dos reservatórios do Semiárido Brasileiro (SAB) por sensoriamento remoto utilizando satélite representa uma importante ferramenta de monitoramento que pode auxiliar na gestão de recursos hídricos desses ambientes. Um parâmetro comumente estimado por satélite é a Clorofila-a (Cla-a), representando um indicador do processo de eutrofização. Portanto, este trabalho teve como objetivo avaliar o desempenho de 22 modelos espectrais disponíveis na literatura para estimativa de Cla-a em 170 reservatórios do SAB. Utilizou-se dados de campo de Órgãos Públicos responsáveis pelo monitoramento desses mananciais. As imagens de satélite foram obtidas do Sentinel 2 (S2), nível 2A e 1C. Os dados S2 - 2A contém correção atmosférica pelo algoritmo Sen2cor e as imagens S2 - 1C foram submetidas a correção pelo modelo SIAC. Os conjuntos de dados foram analisados por agrupamentos, sendo eles: por volumes dos mananciais; por concentrações de Cla-a de campo; e por reservatórios. Visando avaliar o desempenho dos modelos em diferentes cenários, foram considerados períodos distintos nas análises (2015-2022 e 2019-2022). As correlações das imagens S2 corrigidas pelo Sen2cor foram um pouco maiores, se comparado com as imagens corrigidas pelo SIAC. Observou-se uma baixa eficiência dos modelos testados quando utilizado um número grande de reservatórios e a quantidade de correlações diminuiu à medida que o período temporal aumentou, possivelmente por possuírem dependência espaço-temporal de ambientes com características semelhantes aos locais onde foram gerados.

Palavras-chave: Eutrofização, Qualidade de água, Modelos espectrais, Sentinel 2, Google Earth Engine.

Evaluation of the Efficiency of Chlorophyll-a Estimation Models by Remote Sensing in Reservoirs in the Brazilian Semi-arid

ABSTRACT

Estimating the water quality of reservoirs in the Brazilian Semi-arid Region (SAB) by remote sensing using satellite represents an important monitoring tool, helping to manage water resources in these environments. Chlorophyll-a (Cla-a) is a parameter commonly estimated by satellite, serving as an indicator of eutrophication. Therefore, this study aimed to assess the performance of 22 spectral models available in the literature for Cla-a estimation in 170 SAB reservoirs. Field data from Public Agencies responsible for monitoring these water bodies were utilized. Satellite images were obtained from Sentinel-2 (S2), both level 2A and 1C. The S2 - 2A data included atmospheric correction by the Sen2cor algorithm, while S2 - 1C images underwent correction using the SIAC model. Datasets were analyzed in typologies of groupings: by reservoir volumes, by field Cla-a concentrations, and by reservoirs. In order to evaluate the performance of the models in different scenarios, different time periods were used in the analyzes (2015-2022 and 2019-2022). Correlations of Sen2cor-corrected S2 images were slightly higher compared to SIAC-corrected images. Model efficiency was low for a significant number of reservoirs, and the quantity of correlations decreased as the temporal period increased. It was concluded that there might be spatial and temporal dependence of the tested models on environments with characteristics similar to the locations where they were generated.

Keywords: Eutrophication, Water quality, Spectral models, Sentinel 2, Google Earth Engine.

Introdução

O Semiárido Brasileiro (SAB) enfrenta desafios significativos devido aos períodos prolongados de secas que ocorrem nesta região. Dessa forma, visando contornar os efeitos decorrentes da baixa oferta de água, ao longo das décadas foram construídos reservatórios superficiais com capacidade plurianual para o acúmulo da água excedente dos meses de maiores precipitações (Pereira Neto, 2017). Há aproximadamente 2,4 mil reservatórios superficiais presentes no SAB, cadastrados no Sistema Nacional de Informações sobre Segurança de Barragens (SNISB), criado pela Lei nº 12.334/2010. Juntos, esses reservatórios possuem uma capacidade de armazenamento de água de aproximadamente 109 mil hm³ (SNISB, 2024). Contudo, longos períodos de seca, como os observados no SAB, podem desencadear alterações substanciais no volume e na qualidade da água desses corpos hídricos (Cortez et al., 2022). A diminuição do nível da água nos reservatórios eleva a concentração de nutrientes, agravando o fenômeno da eutrofização nesses ecossistemas (Rocha Junior et al., 2018). Além disso, fatores como o desmatamento, em especial a perda da mata ciliar, a precariedade do tratamento de efluentes sanitários e a disposição inadequada dos resíduos sólidos, contribuem ainda mais para a perda da qualidade destes corpos hídricos (Tundisi et al., 2015). A deterioração da qualidade da água pode ser ainda mais acentuada em reservatórios de pequeno porte, uma vez que são alimentados por rios intermitentes e possuem maior limitação em sua capacidade de autodepuração (Cirilo et al., 2010). As mudanças climáticas em curso tornam os reservatórios do SAB ainda mais vulneráveis à eutrofização (Raulino et al., 2021). Isso acontece porque os padrões globais de temperatura e precipitação estão mudando consideravelmente desde o último século, e previsões apontam para alterações ainda maiores até ao final de 2100 (IPCC, 2023). Portanto, é importante que haja o monitoramento dinâmico da qualidade da água desses sistemas em larga escala, para que medidas mais urgentes e eficazes possam ser adotadas, visando mitigar os problemas relacionados à escassez hídrica (Yang et al., 2022; Satish et al., 2023).

Tradicionalmente, a qualidade da água é estimada através da análise de parâmetros que são amostrados em campo, o que inclui preparação de equipamentos, coleta das amostras de água, transporte e análises laboratoriais dos parâmetros não mensurados in situ. Contudo, esse método

enfrenta muitos desafios, tais como elevado custo financeiro, demora na geração dos resultados e coletas que estão sujeitas à acessibilidade dos mananciais (Gholizadeh et al., 2016). Essas limitações resultam em avaliações pontuais dos reservatórios, o que pode não refletir adequadamente a distribuição espacial e as variações temporais da qualidade da água (Aranha et al., 2022). Além disso, é comum que os órgãos gestores monitorem apenas os grandes mananciais do SAB (Coelho et al., 2017). Do total de reservatórios presentes nesta região, apenas cerca de 17% (414 mananciais) são acompanhados pela Agência Nacional de Águas e Saneamento Básico (ANA), gerando dados de qualidade de água (ANA, 2023). Esta insuficiência na cobertura de monitoramento impacta de maneira substancial a avaliação abrangente da qualidade da água, comprometendo diretamente a eficiência do planejamento racional dos recursos hídricos armazenados.

Como alternativa para complementar o monitoramento tradicional da água (Llodrà-Llabrés et al., 2023), tem-se o Sensoriamento Remoto por Satélite (SRS). O SRS vem representando uma importante ferramenta para análise da qualidade dos corpos hídricos, principalmente devido ao aumento da cobertura espacial e temporal de imagens (Lobo et al., 2021). Atualmente, há disponibilidade de dados provenientes de diversos sensores espaciais que podem ser utilizados para analisar a qualidade da água superficial com base na relação entre a concentração dos constituintes da água e os sinais de dispersão dos sensores (Yang et al., 2022).

Contudo, apesar dos satélites modernos oferecerem uma solução mais eficaz em comparação com os métodos convencionais de monitoramento de qualidade de água, o download e o processamento manual são procedimentos demorados que demandam uma elevada carga computacional (Nguyen et al., 2019). Para superar essas limitações, plataformas computacionais em nuvem de big data foram desenvolvidas, como é o caso do Google Earth Engine (GEE). O GEE é de acesso gratuito e possui um repositório online de imagens de satélite em escala global. Essa plataforma utiliza as capacidades computacionais dos servidores do Google para otimizar a análise de muitas imagens, permitindo avanços nos estudos de monitoramento da qualidade da água (Sherjah et al., 2023). As funcionalidades do GEE proporcionam aos gestores e pesquisadores de recursos hídricos meios avançados para diagnosticar e responder de forma mais eficaz aos problemas relacionados à qualidade dos corpos hídricos (Peterson et al., 2020).

Um dos parâmetros comumente empregados com sucesso para avaliar o estado trófico das águas por meio de SRS é a Clorofila-a (Cla-a) (Flores-Anderson et al., 2020; Neil et al., 2020; Ouma et al., 2020; Hajigholizadeh et al., 2021; Aranha et al., 2022; Zhao et al., 2022; Satish et al., 2023). Existem diversos modelos espectrais (Tabela A - Apêndice A) utilizados para estimar Cla-a por SRS, referentes a estudos desenvolvidos em diferentes regiões do mundo. Os trabalhos envolvendo o uso de sensoriamento remoto para mensurar a Cla-a datam desde a década de 1970, com modelos que eram desenvolvidos inicialmente para águas oceânicas (Zhao et al., 2010).

O pigmento Cla-a é um dos principais parâmetros que indicam o estado de degradação dos corpos hídricos (Markogianni et al., 2020). A Cla-a está presente em todas as espécies de algas, cujas florações são normalmente estimuladas pelo enriquecimento de nutrientes (Ex. nitrogênio e fósforo) em corpos d'água doce (Barbosa et al., 2019). Dessa forma, este pigmento representa um dos principais parâmetros para analisar o estado trófico de mananciais (Markogianni et al., 2020), servindo como um indicador da ligação entre a concentração de nutrientes e a proliferação de algas (Gholizadeh et al., 2016).

Para estimar a concentração de Cla-a a partir de dados de satélite, são gerados modelos que consideram e testam diferentes bandas espectrais, em várias combinações e razões, com o intuito de reduzir a irradiância e as influências atmosféricas e da superfície água-ar na reflectância captada pelo sensor (Hajigholizadeh et al., 2021). Embora os modelos de Cla-a não façam distinção entre florações de algas nocivas e as menos nocivas para o ambiente e a saúde da população, eles podem auxiliar os gestores de recursos hídricos a concentrarem esforços na mitigação de risco de potenciais proliferações de algas nocivas (Beck et al., 2016). Entre as abordagens metodológicas utilizadas para geração dos modelos estão as empíricas, semiempíricas, analíticas, bio-ópticas, semi-analíticas e de inteligência artificial (Sagan et al., 2020; Yang et al., 2022; Cao et al., 2023).

A Cla-a absorve energia da luz solar em comprimentos de ondas nas regiões azul-violeta e vermelho-alaranjado, e reflete a luz em comprimentos de onda na região verde (Gholizadeh et al., 2016; Sagan et al., 2020). Dessa forma, a maior parte dos modelos de SRS utilizam como princípio o comportamento espectral da Cla-a, por meio da relação existente entre as reflectâncias: no primeiro pico de absorção na região azul com a absorção mínima na região verde; na absorção mínima na região NIR com o segundo pico de absorção na região vermelha; e

utilizando três bandas por meio da razão espectral de curvatura ou inclinação em diferentes regiões do espectro (Ha et al., 2017; Flores-Anderson et al., 2020).

Embora existam vantagens na utilização de SRS para a estimativa de Cla-a, ainda existem desafios científicos e tecnológicos a serem superados, como:

Há incertezas na eficiência dos modelos utilizados para estimar Cla-a em decorrência da diversidade de OWTs (Optical Water Types) (Tavares et al., 2021). Os OWTs estão relacionados às substâncias presentes no corpo hídrico que interagem com a radiação eletromagnética. Correspondem a essas substâncias o fitoplâncton, as NAPs (NonAlgal Particles) e a CDOM (Colored Dissolved Organic Matter) (Gonçalves-Araújo et al., 2019).

Embora os modelos específicos dos sensores para correções atmosféricas já existam há anos, ainda não há ACPs (Atmospheric Correction Processor) eficientes para calcular a reflectância da superfície da água (Sagan et al., 2020; Aranha et al., 2022; Yang et al., 2022). Essa carência é motivo de preocupação, pois há interferência da atmosfera em 80-90% da reflectância total recebida que é detectado dos corpos hídricos (Sherjah et al., 2022). Essa interferência independe da escolha do sensor, podendo variar consideravelmente de acordo com as concentrações de vapor d'água e de aerossóis presentes na atmosfera (Topp et al., 2020). Portanto, a eficiência de qualquer modelo de estimativa de qualidade de água é extremamente dependente da precisão do algoritmo de correção atmosférica empregado (Sherjah et al., 2022). Destaca-se que o ACP disponível no GEE para as imagens Landsat 8 e Sentinel 2 é o SIAC (Sensor Invariant Atmospheric Correction). No entanto, a precisão do SIAC para corpos hídricos ainda precisa ser investigada e como há muito potencial no GEE para pesquisas nesta área, torna-se necessário a obtenção de um ACP que possa ser utilizado com confiança nesta plataforma (Sherjah et al., 2023).

Muitos sensores possuem restrições quanto aos tipos de observações que conseguem realizar, devido à dificuldade na obtenção de dados com boas resoluções espectrais, espaciais e temporais simultaneamente (Yang et al., 2022). Isso contribui para a reduzida quantidade de estudos por SRS envolvendo pequenas massas de águas (área menor que 0,1 km²), embora estas representem mais de 90% dos corpos hídricos em todo o mundo (Llodrà-Llabrés et al., 2023). Contudo, o Sentinel 2, por exemplo, tem sido amplamente utilizado para estimativa de parâmetros de qualidade de água (Aranha et al.,

2022; Ciancia et al., 2023; Gernez et al., 2023). Esse satélite, embora não tendo sido projetado especificamente para monitoramento de corpos hídricos, apresenta bom desempenho para esta finalidade (Llodrà-Llabrés et al., 2023). Lançado em 2015, o Sentinel 2 proporcionou melhora nas relações sinal/ruído, na resolução radiométrica e espacial, e incluíram bandas específicas para aerossóis (Concha & Schott, 2016). O Sentinel 2 é gerenciado pela ESA (European Space Agency) em parceria com a Comissão Europeia em atendimento ao Programa Copernicus. Este satélite utiliza o MSI para medir a radiância refletida pela Terra em 13 bandas espectrais, do VNIR (Visible and Near-Infra-Red) ao SWIR (Short Wave Infra-Red), possuindo uma frequência de revisita de cinco dias (ESA, 2023).

Juntos, os desafios apresentados contribuem para a inexistência de um modelo globalmente aceito para estimar Cl_a por SRS, o que destaca a necessidade de haver aprimoramentos na compreensão desses fatores para garantir resultados mais confiáveis.

Mediante o exposto, o presente trabalho tem como objetivo avaliar o desempenho de diferentes modelos espectrais disponíveis na literatura para estimar a concentração de Cla-a em reservatórios do SAB. Para tanto, pretende-se analisar a eficiência da utilização de imagens com distintas metodologias de correções atmosféricas (Sen2cor e SIAC). Bem como verificar se diferentes condições volumétricas e de concentrações de Cla-a dos reservatórios interferem na estimativa deste parâmetro. Como a região SAB é heterogênea em muitos aspectos físicos, a hipótese inicial é de que não haja um único modelo capaz de representar o nível de Cla-a de maneira adequada em todos os reservatórios dessa região.

Material e métodos

A Figura 1 contém um fluxograma metodológico com as principais etapas empregadas nesta pesquisa, cujas descrições detalhadas estão apresentadas nos itens posteriores.




Figura 1. Fluxograma contendo as principais etapas metodológicas da pesquisa. Legenda: COGERH - Companhia de Gestão dos Recursos Hídricos do Ceará; AESA - Agência Executiva de Gestão das Águas da Paraíba; BOA - *Bottom of Atmosphere*; TOA - *Top of the Atmosphere*; R^2 - Coeficiente de correlação ao quadrado; NRMSE - *Normalized Root Mean Square Error*; e NSE - *Nash-Sutcliffe Efficiency*.

Local de estudo e obtenção dos dados de campo

Os reservatórios estudados estão inseridos no SAB. Essa região abrange cerca de 12% do território nacional e abriga uma população de aproximadamente 28 milhões de habitantes (SUDENE, 2017). A precipitação média do SAB é de 750 mm.ano⁻¹, apresentando uma distribuição espaço-temporal irregular (Paiva & Souza, 2022). O clima da região é majoritariamente quente e

seco, com temperaturas de $\pm 26^{\circ}\text{C}$ e a evapotranspiração pode chegar a 2.000 mm.ano^{-1} (Paloschi *et al.*, 2021). Há predominância de solos rasos localizados sobre formações do tipo cristalino (Araújo Filho *et al.*, 2023), o que favorece uma má penetração de água no subsolo e um rápido escoamento superficial. Os rios são majoritariamente intermitentes e há um reduzido número de aquíferos, o que não serve como

garantia hídrica durante os períodos de estiagem (Gheyi *et al.*, 2012).

Para este estudo, utilizou-se dados de concentrações de Clorofila-*a* (Cla-*a*) pertencentes a 170 reservatórios do SAB, os quais estão distribuídos entre o estado do Ceará (149) e da Paraíba (21) (Figura 2). Estes dados foram obtidos da Companhia de Gestão de Recursos Hídricos do

Ceará (COGERH) e da Agência Executiva de Gestão das Águas do Estado da Paraíba (AESA) que monitoram os reservatórios do estado do Ceará e da Paraíba, respectivamente. Esses mananciais equivalem a aproximadamente 7% do total de reservatórios do SAB, considerando a quantidade cadastrada no SNISB(2024).




Figura 2. Localização geográfica dos *sites* de amostragem de campo e por SRS, nos 170 reservatórios localizados nos estados do Ceará e Paraíba.

A COGERH e a AESA realizam anualmente quatro campanhas amostrais de análises de qualidade de água dos reservatórios por elas monitorados. A Tabela 1 contém detalhes sobre o universo dos dados de campo utilizados, com informações sobre a metodologia laboratorial empregada para análise de Cla-*a*, número de amostras estudadas e período em que ocorreram as

coletas dos dados. As concentrações de Cla-*a* de campo obtidas, provenientes de análises laboratoriais, que se encontravam abaixo do Limite de Detecção (LD) do método analítico, foram substituídas por $\frac{1}{2}$ de LD para a realização do comparativo destes com as concentrações estimadas pelos modelos espectrais, conforme recomendação de Oliveira (2018).

Tabela 1. Fonte dos dados Cla-*a* de campo, metodologia utilizada para análise laboratorial, quantidade de reservatórios amostrados, número de amostras obtidas e períodos das coletas.

Fonte de dados	Metodologia laboratorial de análise de Cla- <i>a</i>	Nº de reservatórios	Nº de amostras	Período amostral
COGERH	Espectrofotométrico (10200 H) – AWWA <i>et al.</i> (2012)	149 do Ceará	3.084	2015 a 2022
AESA	Espectrofotométrico (10200 H) - AWWA <i>et al.</i> (2012); ISO (1991) e ISO (1992)	21 da Paraíba	242	2020 a 2022
Total		170	3.326	2015 a 2022

Este estudo contempla uma grande quantidade de pontos amostrais que pertencem a diferentes tipos de reservatórios em termos de

capacidade de acumulação de água(V) segundo a classificação: micro porte ($V \leq 0,5 \text{ hm}^3$); pequeno porte ($0,5 < V \leq 7,5 \text{ hm}^3$); médio porte ($7,5 < V \leq 75$

hm³); grande porte (75 < V ≤ 750 hm³); e macro porte (V > 750 hm³) (Ceará, 1994). A maioria dos reservatórios estudados possuem tamanho médio,

seguido pelos de pequeno porte e apenas uma pequena parcela são enquadrados na categoria de micro porte (Figura 3).




Figura 3. Classificação volumétrica e do estado trófico dos 170 reservatórios estudados.

Para conhecimento das classificações tróficas desses reservatórios, empregou-se o Índice de Estado Trófico (IET) proposto por Carlson (1977) e adaptado por Toledo Jr. (1990) para reservatórios localizados em climas tropicais. Considerou-se a seguinte classificação: oligotrófico (IET ≤ 44); mesotrófico (44 < IET ≤ 54); eutrófico (54 < IET ≤ 74); e hipereutrófico (IET > 74). O cálculo do IET levou em consideração a média aritmética simples entre o IET de Clorofila-*a* (Equação 01) e o IET de

Fósforo Total (PT) (Equação 02), pertencentes às amostras dos mananciais estudados. Utilizou-se a Cla-*a* e o PT pois foram os parâmetros com dados disponíveis para todas as coletas de campo.

Como resultados, as amostras apresentaram distintas classificações tróficas (Figura 3). Contudo, houve uma baixa qualidade da água desses reservatórios durante a maior parte das coletas de campo realizadas, já que 76% das amostras foram classificadas como eutróficas ou hipereutróficas.

$$IET_{Cla-a} = 10 * \left(6 - \frac{2,04 - 0,695 * \ln [Cla - a]}{\ln 2} \right) \quad \text{Equação 1}$$

$$IET_P = 10 * \left(6 - \frac{\ln (80,32 / [P])}{\ln 2} \right) \quad \text{Equação 2}$$

Onde: IET é o Índice de Estado Trófico; [Cla-*a*] é a concentração de Clorofila-*a*, em µg.L⁻¹; e [P] é a concentração de Fósforo Total, em µg.L⁻¹.

Coleta de dados de satélite

Através da plataforma do GEE foram selecionadas imagens do satélite Sentinel 2 - MSI. Foram selecionadas as imagens cujas datas de passagem do satélite eram as mais próximas possíveis dos dias das coletas dos dados de campo, levando em consideração que a janela temporal entre essas datas não poderia ultrapassar 10 dias, para mais ou para menos.

Foram extraídas imagens do Sentinel 2 de reflectância de superfície (Bottom of Atmosphere - BOA, produto de nível 2A) que utilizam o ACP Sen2cor. Como também, foram coletadas imagens do Sentinel 2 do topo da atmosfera (Top of the Atmosphere - TOA, produto de nível 1C) para sua

posterior correção atmosférica por meio do ACP SIAC, ainda no próprio GEE. Mais detalhes sobre o algoritmo SIAC podem ser obtidos em Yin et al. (2022). Utilizou-se os produtos harmonizados de todas as imagens, o que significa que os dados de cenas mais recentes mudaram para estarem no mesmo intervalo que em cenas mais antigas. Salienta-se que imagens Sentinel 2 - 2A (BOA) estão disponíveis para a região de estudo desde 2019, enquanto as imagens Sentinel 2 - 1C (TOA) estão disponíveis desde 2015.

Para garantir a confiabilidade das informações extraídas das imagens de satélite, utilizou-se buffers de 50 m² ao redor dos pontos de coleta das amostras de água de campo.

Posteriormente, calculou-se a concentração média de Cla-a para essas áreas, visando reduzir o ruído dos pixels nos dados obtidos. O NDWI (Normalized Difference Water Index) elaborado por McFeeters (1996) foi empregado para garantir que as áreas presentes nos buffers correspondiam às alagadas pelos corpos hídricos estudados, evitando erros resultantes da presença de solo nas estimativas de Cla-a. O NDWI utiliza a banda 3 (Green) e a banda 8 (NIR) do Sentinel 2, conforme pode ser verificada na Equação 3.

$$\text{NDWI} = \frac{B3 - B8}{B3 + B8} \quad \text{Equação 3}$$

Seleção e avaliação dos modelos espectrais

Realizou-se um levantamento bibliográfico dos modelos espectrais disponíveis na literatura para estimativa da concentração de Cla-a. A busca foi conduzida no Google Acadêmico e no Portal de Periódicos da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior). O Portal CAPES mantém 299 bases de dados, entre elas: SciELO; Web of Science; PubMed; e IEEE

Xplore Digital Library. Utilizou-se para a pesquisa as palavras-chave: algal bloom; algorithm/index; chlorophyll-a; remote estimation; remote sensing; trophic state; e water quality. Posteriormente, foram selecionados os modelos que apresentaram bons desempenhos nos artigos de origem (coeficiente de correlação maior ou igual a 0,6) e que possuíam bandas espectrais compatíveis com as do Sentinel 2 - MSI, sensor utilizado neste estudo. Um total de 22 modelos foram selecionados para testar as suas eficiências em estimar Cla-a nos reservatórios do SAB (Tabela 2). Destes, o 2BDA-2, 2BDA-3, 2BDA-4, 2BDA-5, 2BDA-6, 2BDA-10, 3BDA-3, 3BDA-4, 3BDA-5, 4BDA e o índice SABI (Surface Algal Bloom Index), foram adaptados para esta pesquisa, aproveitando as características espectrais compatíveis com as bandas do sensor MSI. O modelo 3BDA-5 foi desenvolvido para aplicação durante o período seco do ano (Hajigholizadeh et al., 2021). Então, para avaliação deste modelo, considerou-se apenas os dados referentes aos meses de junho a janeiro, por representar o período mais seco no semiárido brasileiro (Nogueira et al., 2023).

Tabela 2. Modelos espectrais testados, com suas respectivas abordagens metodológicas e autorias.

Modelo	Abordagem metodológica	Equação	Fonte
1BDA	Empírica	$378524,04 * B3^2 - 30345,60 * B3 + 616,37$	(1)
2BDA-1	Empírica	$70,75 * \left(\frac{B5}{B4}\right) - 58,45$	(2)
2BDA-2	Empírica	$28,1 * e^{0,72 * \left(\frac{B3}{B2}\right)}$	(3)
2BDA-3	Semiempírica	$-13,793 * \left[\log\left(\frac{B2}{B3}\right)\right]^3 - 17,957 * \left[\log\left(\frac{B2}{B3}\right)\right]^2 - 6,7982 * \log\left(\frac{B2}{B3}\right) + 0,0347$	(4)
2BDA-4	Semiempírica	$-11,648 * \left[\log\left(\frac{B2}{B3}\right)\right]^3 - 16,144 * \left[\log\left(\frac{B2}{B3}\right)\right]^2 - 6,5509 * \log\left(\frac{B2}{B3}\right) + 0,0229$	(4)
2BDA-5	Empírica	$\left[35,75 * \left(\frac{B5}{B4}\right) - 19,30\right]^{1,124}$	(5)
2BDA-6	Empírica	$25,28 * \left(\frac{B5}{B4}\right)^2 + 14,85 * \left(\frac{B5}{B4}\right) - 15,18$	(6)
2BDA-7	Empírica	$395763 * (B2 - B11)^2 - 44991 * (B2 - B11) + 1288,2$	(1)

Modelo	Abordagem metodológica	Equação	Fonte
2BDA-8	Empírica	$246622 * \left(\frac{B2 + B12}{2}\right)^2 - 38346 * \left(\frac{B2 + B12}{2}\right) + 1497,6$	(1)
2BDA-9	Empírica	$1748431,97 * \left(\frac{B2 - B11}{2}\right)^2 - 126132,79 * \left(\frac{B2 - B11}{2}\right) + 2289,87$	(1)
2BDA-10	Analítica - Regressão múltipla	$735,98 * B2 - 425,88 * B3 - 60,20$	(7)
3BDA-1	Empírica	$279,95 * \left(\frac{B6}{B4 - B5}\right) + 38,06$	(8)
3BDA-2	Empírica	$466683 * [B3 + (B12 - B11)]^2 - 39497 * [B3 + (B12 - B11)] + 835,87$	(1)
3BDA-3	Empírica	$\left[113,36 * \left(\frac{B6}{B4 - B5}\right) + 16,45\right]^{1,124}$	(5)
3BDA-4	Empírica	$315,5 * \left(\frac{B6}{B4 - B5}\right)^2 + 215,95 * \left(\frac{B6}{B4 - B5}\right) + 25,66$	(6)
3BDA-5	Analítica - Regressão múltipla	$\text{Período seco} = 881,1 * \left(\frac{B2}{B4}\right) - 1784,7 * \left(\frac{B3}{B4}\right) + 5331,5 * \left(\frac{B4}{B2}\right) - 3096,2 * \left(\frac{B4}{B3}\right) + 1167 * B2 + 525,5$	(9)
4BDA	Analítica - Regressão múltipla	$44,7869 - 0,2908 * B2 - 0,6905 * B3 + 0,1019 * B4 + 0,4843 * B8$	(10)
FLH	Semianalítica	$-264,74 * \left[B3 - B4 - \left(\frac{559,5 - 664,75}{664,75 - 834,05}\right) * (B4 - B8)\right] + 2,32$	(11)
NDCI	Empírica	$179,18 * \left(\frac{B5 - B4}{B5 + B4}\right) + 10,82$	(12)
SABI	Empírica	$\frac{(B8 - B4)}{(B2 + B3)}$	(13)
OC2V4	Empírica	$10^{0,2975 - 21,502 * \log\left(\frac{B2}{B3}\right) - 215,53 * \left[\log\left(\frac{B2}{B3}\right)\right]^2 - 784,5 * \left[\log\left(\frac{B2}{B3}\right)\right]^3 - 859,7 * \left[\log\left(\frac{B2}{B3}\right)\right]^4}$	(14)
OC4V4	Empírica	$10^{-0,599 - 50,54 * \log\left(\frac{B2}{B3}\right) - 578,38 * \left[\log\left(\frac{B2}{B3}\right)\right]^2 - 2525,7 * \left[\log\left(\frac{B2}{B3}\right)\right]^3 - 376,2 * \left[\log\left(\frac{B2}{B3}\right)\right]^4}$	(14)

Legenda: BDA - Band Algorithm; FLH - Fluorescence Line Height; NDCI - Normalized Difference Chlorophyll Index; e SABI - Surface Algal Bloom Index; 1 - Ouma *et al.* (2020); 2 - Xu *et al.* (2018); 3 - Adaptado de Ha *et al.* (2017); 4 - Adaptado de Flores-Anderson *et al.* (2020); 5 - Adaptado de Gilerson *et al.* (2010); 6 - Adaptado de Gurlin *et al.* (2011); 7 - Adaptado de Martini *et al.* (2006); 8 - Aranha *et al.* (2022); 9 - Adaptado de Hajigholizadeh *et al.* (2021); 10 - Adaptado de Alparslan *et al.* (2007); 11 - Satish *et al.* (2023); 12 - Mishra e Mishra (2012), adaptado por Xu *et al.* (2018); 13 - Adaptado de Alawadi (2010); 14 - O'Reilly *et al.* (1998), adaptado por Ma *et al.* (2022).

Após a seleção dos modelos para a estimativa de Cla-a, foram processados dois conjuntos de dados distintos, um utilizando imagens Sentinel 2 - 2A, com correção atmosférica realizada pelo ACP Sen2cor e o outro com imagens do Sentinel 2 - 1C, corrigidas com o algoritmo SIAC. Esses conjuntos de dados foram então separados e analisados em três tipologias de agrupamentos: por volume dos mananciais nos dias das coletas de campo; por concentrações de Cla-a de campo; e por reservatórios individualmente. Para as tipologias de volumes e concentrações de Cla-a, os dados foram classificados em quartis, permitindo uma análise detalhada dos resultados. Salienta-se que a quantidade de dados presentes em cada quartil variou em função do modelo espectral utilizado. Para as imagens Sentinel 2 - 2A, utilizou-se agrupamentos formados para o período compreendido entre 2019 e 2022. Como a disponibilidade de dados temporais das imagens Sentinel 2 (2A e 1C) era distinta, para o produto 1C foram formados agrupamentos com os dados de 2015 a 2022. Também foram criados agrupamentos com as imagens do Sentinel 2 - 1C, para os anos de 2019 a 2022, visando efetuar um comparativo dos resultados com os obtidos pelas imagens de nível 2A.

Posteriormente, foi realizada uma análise estatística para identificar os outliers nos resultados. Para isso, utilizou-se o método da variação

interquartil (IQR) multiplicada por 1,5. A identificação desses outliers pode ser um importante mecanismo de detecção de erros oriundos do ruído de pixels nos buffers das imagens utilizadas. Foram aplicados testes de normalidade, sendo estes: Shapiro-Wilk, para um número de dados menor ou igual a 50 (Shapiro & Wilk, 1965); e o Kolmogorov-Smirnov, quando o número de dados era maior que 50.

Para os agrupamentos que apresentaram uma distribuição normal dos dados, analisou-se a existência de correlações, entre as concentrações de Cla-a estimadas e os dados de campo, através do coeficiente de correlação ao quadrado (R^2) pelo método de Pearson. Para os agrupamentos que não apresentaram uma distribuição normal, verificou-se os valores de R^2 através da metodologia de Spearman. Para todos os testes foi considerado um nível de significância de 5% (Gotelli & Ellison, 2011). A Tabela 3 contém as métricas de desempenho utilizadas para analisar a eficiência dos modelos espectrais testados. Salienta-se que o SABI foi avaliado apenas pelo R^2 , por ser um índice e não um modelo como os demais. Para todos os agrupamentos que não apresentaram um número de dados (n) maior ou igual a seis, estes foram retirados das análises para não comprometer a confiabilidade dos resultados das métricas de desempenho.

Tabela 3. Métricas de desempenho utilizadas para análise da eficiência dos modelos espectrais testados.

Métrica	Equação
Coeficiente de correlação de Pearson ao quadrado	$R^2 = \left[\frac{\sum_{i=1}^n (y_i - \bar{y}) * (x_i - \bar{x})}{\sqrt{\left[\sum_{i=1}^n (y_i - \bar{y})^2 \right] * \left[\sum_{i=1}^n (x_i - \bar{x})^2 \right]}} \right]^2$
Coeficiente de correlação de Spearman ao quadrado	$R^2 = \left[1 - \frac{6 * \sum_{i=1}^n d_i^2}{n * (n^2 - 1)} \right]^2$
Eficiência de Nash-Sutcliffe (<i>Nash-Sutcliffe Efficiency</i> - NSE)	$NSE = 1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$
Raiz do Erro Quadrático Médio Normalizada (<i>Normalized Root Mean Square Error</i> - NRMSE)	$NRMSE_{\%} = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}} * \frac{100}{\bar{x}}$

Legenda: n é o número total de observações; x_i é o valor observado para a i -ésima observação no conjunto de dados; y_i é o valor previsto para a i -ésima previsão no conjunto de dados; $\bar{x}$ e $\bar{y}$ são as médias das variáveis x e y , respectivamente; e d_i são as diferenças entre os postos das variáveis nas duas amostras.

Neste trabalho, considerou-se a seguinte classificação para a magnitude do valor de R^2 : muito fraca entre 0 e 0,19; fraca entre 0,20 e 0,39; moderada entre 0,40 e 0,59; forte entre 0,60 e 0,79; e muito forte entre 0,80 e 1,00 (Evans, 1996). O NSE varia de $-\infty$ a um e a interpretação dos valores é a seguinte: NSE maior que zero, indica um desempenho aceitável, sendo que quanto mais próximo de um, melhor é a eficiência do modelo; NSE igual a zero, representa um modelo que tem um desempenho igual a utilização da simples média dos dados observados; e NSE menor que zero, aponta que o modelo é considerado inadequado, onde a utilização da média dos dados observados seria uma melhor estimativa (Schaeffli & Gupta, 2007). A interpretação do NRMSE é feita considerando o contexto específico da aplicação e as metas do estudo, sendo que quanto mais próximo de 0% menor é o erro.

Resultados

Eficiência dos modelos espectrais considerando os reservatórios individualmente

Ao considerar tanto as imagens Sentinel 2 com correção atmosférica pelo algoritmo Sen2cor, quanto pelo SIAC, para todos os modelos espectrais testados a maior parte dos reservatórios (93,47%) apresentaram correlações fracas ou muito fracas entre as concentrações de Cla-a de campo e as estimadas pelas equações. Contudo, todos os modelos apresentaram correlação forte ou muito forte ($R^2 \geq 0,6$) com pelo menos um reservatório dos 170 estudados. Percebeu-se ainda, que ao utilizar as imagens corrigidas pelo Sen2cor as correlações foram maiores do que as imagens corrigidas pelo SIAC, principalmente quando o período temporal das imagens SIAC foi maior, ou seja, de 2015 a 2022. Para a maior parte dos

mananciais houve pelo menos um modelo que apresentou correlação de magnitude moderada a muito forte. A Tabela B.1, presente no Apêndice B, contém as maiores correlações para cada reservatório, bem como, os modelos responsáveis por tais correlações. Três mananciais tiveram um número de dados inferior a seis e, portanto, não estão presentes na Tabela B.1.

Tratando-se especificamente dos agrupamentos que utilizaram imagens Sen2cor, ao considerar o emprego de todos os modelos, houve 17 agrupamentos (0,5% do total) com valores de R^2 de magnitude muito forte e 70 (2,08% do total) de magnitude forte (Tabela B.2 - Apêndice B). Ao analisar os modelos de forma individual, o 2BDA-6, 2BDA-1, 2BDA-5, NDCI e 1BDA apresentaram os maiores valores de R^2 ($\geq 0,6$) para nove, oito, oito, sete e seis reservatórios, respectivamente. Todavia, ainda que os resultados de R^2 tenham sido bons para alguns agrupamentos, a maior parte dos valores de NRMSE foram altos e os de NSE baixos, demonstrando desempenho insatisfatório dos modelos diante das métricas analisadas. Como exceção, há a utilização do modelo 2BDA-1 no reservatório Santa Maria de Aracatiaçu, onde o R^2 foi 0,71, o NRMSE foi 15,43% e o NSE foi 0,69 (Figura 4a). O NDCI também apresentou bom desempenho neste reservatório, com R^2 de 0,69, NRMSE de 15,66% e o NSE de 0,68. O desempenho do modelo 2BDA-6 foi bom quando empregado no reservatório Quandú (Figura 4b), embora, nesse caso, não tenham sido representados tão bem os picos de Cla-a observados nas coletas de campo. O valor de R^2 para o 2BDA-6 foi de 0,67 no Quandú, o NRMSE de 29,76% e o NSE de 0,48.




Figura 4. Comportamento das concentrações de Clorofila-a para os reservatórios: (a) Santa Maria de Aracatiaçu utilizando os modelos 2BDA-1 e NDCI; e (b) Quandú empregado o modelo e 2BDA-6.

Os resultados obtidos com as imagens Sentinel 2 - 1C, aplicando o SIAC e considerando o período de dados entre 2019 e 2022, apontaram apenas nove agrupamentos com valores de R^2 muito forte e 64 fortes (Tabela B.3 - Apêndice B). Os modelos que apresentaram os maiores valores de R^2 foram 3BDA-5, 2BDA-6, 2BDA-1 e NDCI, cujo somatório dos reservatórios com correlações, entre 0,6 e 1, foi de sete, seis, cinco e cinco, respectivamente. Já considerando as imagens SIAC para o período de 2015 a 2022, somente 35 grupos tiveram fortes correlações e quatro apresentaram valores de R^2 com magnitude muito forte. Para esse intervalo temporal o modelo que apresentou maiores correlações entre os demais foi o 3BDA-3, com seis reservatórios em que os valores de R^2 acima de 0,6 (Tabela B.4 - Apêndice B). Para as imagens com correção SIAC, considerando os dois períodos temporais de análises, não houve nenhum agrupamento onde todas as métricas tenham sido simultaneamente boas, logo nenhum reservatório foi destacado.

Eficiência dos modelos espectrais considerando as concentrações de Clorofila-a de campo

Para todos os agrupamentos, tanto utilizando imagens com correções Sen2cor, quanto imagens com SIAC, não houve correlações significativas entre os dados de Cla-a de campo e os estimados pelos modelos espectrais. Contudo, percebeu-se que, ainda que elevados, os erros (NRMSE e NSE) tenderam a diminuir com o aumento da concentração de Cla-a para os modelos: 1BDA; 2BDA-7; 2BDA-8; 2BDA-10; 3BDA-1; 3BDA-2; 3BDA-4; e 3BDA-5 (Tabelas C.1 a C.3, Apêndice C). Portanto, os maiores erros foram observados no quartil I (menores concentrações de Cla-a) e os menores no quartil IV (maiores concentrações de Cla-a). Para o modelo 2BDA-9, um comportamento semelhante foi verificado, com exceção de quando se utilizou as imagens Sentinel 2 com correção SIAC, para o período de dados de 2019 a 2022. Os resultados das métricas NRMSE e NSE para o modelo 3BDA-3 obtiveram o mesmo padrão comportamental, porém somente para as imagens com o ACP SIAC, tanto para o período de 2019 a 2022, como de 2015 a 2022. Para os modelos que não foram mencionados, não foi visualizada nenhuma tendência de comportamento com o aumento ou redução da concentração de Cla-a de campo.

Ao analisar apenas as imagens com Sen2cor (Tabela C.1 - Apêndice C), o modelo 3BDA-3 apresentou um número de dados no quartil IV igual a três, logo não foi verificada a eficiência deste modelo em estimar Cla-a neste quartil. Os menores valores de NRMSE para as

imagens com Sen2cor, foram obtidos através dos modelos 2BDA-1, 2BDA-5 e NDCI, os quais foram 33,89%, 31,23% e 34,82%, respectivamente. Todos os valores descritos estavam presentes no quartil III (Cla-a entre 18,65 a 38,87 $\mu\text{g.L}^{-1}$). Contudo os resultados de NSE nesses agrupamentos foram insatisfatórios: -1,65 para 2BDA-1; -1,25 para 2BDA-5; e -1,80 para NDCI.

Ao se trabalhar com as imagens Sentinel 2, com correção pelo SIAC, período de dados entre 2019 e 2022 (Tabela C.2 - Apêndice C), os valores mais baixos de NRMSE foram observados também no quartil III (Cla-a entre 18,65 e 38,87 $\mu\text{g.L}^{-1}$), ao empregar os modelos 2BDA-5 (27,34%) e 2BDA-6 (24,91%). Contudo o NSE foi de -0,72 e -0,43 para o 2BDA-5 e 2BDA-6, respectivamente. Considerando as imagens SIAC cujo período temporal era de 2015 a 2022 (Tabela C.3 - Apêndice C), os menores valores de NRMSE foram dos modelos 2BDA-5 (37,52%) e 2BDA-6 (33,91%), também para o quartil III (Cla-a entre 21,73 e 48,20 $\mu\text{g.L}^{-1}$). Porém, os resultados do NSE foram inferiores a zero em todos os agrupamentos.

Eficiência dos modelos espectrais considerando os volumes armazenados nos reservatórios

Assim como ocorreu com os agrupamentos formados pelas concentrações de Cla-a, os quartis gerados com os dados dos volumes não apresentaram correlações entre os teores de Cla-a de campo e os estimados nos modelos (Tabelas D.1 a D.3). Os valores de NRMSE e NSE também exibiram um baixo desempenho das equações de estimativa de Cla-a, contudo alguns comportamentos foram observados. O primeiro diz respeito às imagens com correção Sen2cor (Tabela D.1 - Apêndice D), onde os maiores valores de NRMSE foram visualizados nos menores volumes (entre 0 e 2,29 hm^3 , referentes ao quartil I), com exceção dos modelos 3BDA-1, 3BDA-3, 3BDA-4 e 3BDA-5, cujos maiores erros medidos pelo NRMSE estiveram nos maiores volumes (quartis III e IV, volumes entre 7,38 e 1054,38 hm^3). Porém com os valores de NSE ocorreu o contrário, os maiores erros estavam presentes nos quartis III e IV e os menores no quartil I, com exceção dos modelos 2BDA-1, 2BDA-5, 2BDA-6, 3BDA-3 e NDCI.

Em se tratando das imagens com correção SIAC, para o período de dados entre 2019 e 2022 (Tabela D.2 - Apêndice D), os erros (NRMSE e NSE) dos modelos 1BDA, 2BDA-8, 3BDA-2 e 3BDA-5 tiveram crescimento com o aumento do volume. Para os modelos 2BDA-1, 2BDA-3, 2BDA-4, 2BDA-5, 2BDA-6, FLH, NDCI, OC2V4

e OC4V4, os maiores valores de NRMSE foram observados nos quartis I e II (volumes entre 0 e 7,38 hm³) e os menores nos quartis III e IV (volumes entre 7,38 e 1054,38 hm³). O contrário aconteceu para os valores de NRMSE dos modelos 3BDA-1 e 3BDA-4. Tratando-se do NSE, os menores erros (maiores valores) foram observados nos quartis I e II e os maiores erros (menores valores) nos quartis III e IV, exceto para os modelos: 2BDA-1, 2BDA-5, 2BDA-6, 3BDA-3, NDCI e OC2V4. Os modelos 2BDA-5 e 2BDA-6 apresentaram uma redução do erro medido pelo NSE com o aumento do volume. Para os demais modelos não se observou tendência de aumento ou redução dos erros com a variação da quantidade de água presente nos mananciais.

Considerando as imagens SIAC para o intervalo temporal de 2015 a 2022 (Tabela D.3 - Apêndice D), os modelos 2BDA-1, 2BDA-3, 2BDA-4, 2BDA-5, 2BDA-6, 4BDA, FLH, NDCI, OC2V4 e OC4V4, apresentaram os maiores NRMSEs% nos quartis I e II (volumes entre 0 e 5,15 hm³) e menores no quartis III e IV (volumes entre 5,15 e 1054,38 hm³). O contrário aconteceu com os modelos 1BDA, 2BDA-8, 2BDA-10, 3BDA-1, 3BDA-2, 3BDA-4 e 3BDA-5, onde os menores erros em NRMSE foram visualizados nos volumes mais baixos (quartis I e II). Avaliando o NSE, os menores erros, ou seja, maiores valores, foram observados para os quartis I e II, com exceção dos modelos: 2BDA-5; 2BDA-6; 2BDA-7; e 2BDA-9. O oposto ocorreu com 2BDA-5 e 2BDA-6, em que os maiores erros estavam presentes nos volumes menores (quartis I e II). Para os modelos não citados, não se observou tendência de alterações nas estimativas de Cla-a com a variação dos volumes dos mananciais.

Discussão

Os modelos espectrais testados não apresentaram correlações com a maior parte dos reservatórios e resultaram em erros elevados nas métricas NRMSE e NSE. Isso pode sugerir dependência espacial dos modelos de estimativa de qualidade da água por SRS testados. Geralmente os modelos são gerados para corpos d'água específicos, representando a poluição hídrica local, os constituintes atmosféricos e as condições do clima (Yang et al., 2022). Por este motivo, muitas vezes os modelos podem apresentar bom desempenho em algumas regiões, mas não serem aplicáveis para outros locais. Essa dependência acontece, principalmente, quando as propriedades ópticas inerentes do corpo hídrico assumem um importante papel na geração dos modelos (Matthews, 2011). Corpos hídricos com diferentes características tróficas possuem distintas

assinaturas espectrais (Coelho et al., 2017). Por exemplo, em águas mais claras (águas do tipo 1) os índices que envolvem as bandas azul e verde costumam ser mais eficientes (Alawadi, 2010), como é o caso do SABÍ e dos modelos 1BDA, 2BDA-2, 2BDA-3, 2BDA-4, 2BDA-10, OC2V4 e OC4V4. Águas do tipo 1 são aquelas em que o fitoplâncton é o constituinte predominante, havendo baixa concentração de sedimentos em suspensão e matéria orgânica (Xu et al., 2018). Em águas mais turvas (águas do tipo 2), as propriedades ópticas são complexas e variáveis, devido à forte interação dos diferentes componentes da água (clorofila, sedimentos em suspensão e matéria orgânica dissolvida colorida), sendo mais difícil realizar uma estimativa precisa de Cla-a (Cui et al., 2020).

Além das características ópticas da água, as abordagens metodológicas utilizadas na geração dos modelos espectrais também são importantes para elevar a aplicabilidade destes em diferentes locais. No caso dos modelos empíricos, que representam a maior parte dos modelos testados neste estudo, eles possuem uma baixa eficiência quando utilizados em águas com diferentes componentes opticamente ativos (Cao et al., 2023), sendo pouco eficiente em estimar Cla-a em águas do tipo 2. Os modelos semiempíricos (2BDA-3 e 2BDA-4), possuem maior aplicabilidade do que os de abordagem empírica (Yang et al., 2022). Contudo, o desempenho dos modelos semiempíricos ainda tende a variar de acordo com o local e o tipo de água, sendo mais eficientes em corpos hídricos do tipo 1 (Sagan et al., 2020). O método de forma espectral semi-analítico (FLH) utiliza as propriedades físicas da interação da luz com a água (Satish et al., 2023), superando as razões de banda simples que são suscetíveis aos componentes ativos da água. Todavia, o FLH exige dados com alta resolução espectral o que restringe sua aplicação em dados de satélite (Sagan et al., 2020). Os modelos analíticos são mais robustos que os demais em condições variadas, contudo necessitam de um conhecimento prévio detalhado das propriedades ópticas inerentes da água e de um elevado número de dados de campo (Gholizadeh et al., 2016). Os modelos analíticos utilizados neste trabalho (2BDA-10, 3BDA-5 e 4BDA) não apresentaram desempenhos consideravelmente melhores que os demais. Isso pode ter ocorrido também em virtude da quantidade de dados utilizados em suas gerações (Tabela A - Apêndice A), que pode não ter sido suficiente para calibrar de forma eficiente estes modelos.

A quantidade de correlações também diminuiu com o aumento do período temporal analisado. Isso pode ser consequência de uma

baixa representatividade dos modelos ao longo do tempo, sendo dependentes das características climáticas de um determinado período. O aumento do período de análise ocorreu ao considerar as imagens corrigidas pelo SIAC de 2015 a 2022, onde o número de dados utilizados cresceu para 3.088, se comparado com o período de 2019 a 2022, em que foi trabalhado com 1.580 imagens. Geralmente, os modelos de estimativa de qualidade da água são gerados utilizando dados de campo que foram coletados em um curto intervalo de tempo, limitando a aplicabilidade dos mesmos (Yang et al., 2022). Modelos de Cla-a que foram treinados utilizando dados sazonais possuem acurácia menor em estações diferentes, se comparado com modelos criados com informações de todas as estações (Yang et al., 2024). Isso acontece devido a variação meteorológica que altera os constituintes da água na mesma região (Pompei et al., 2020). Além disso, a concentração de Cla-a varia muito entre espécies diferentes e de acordo com o estágio fisiológico das células (Reynolds, 1984). Então, dentro do mesmo local de estudo a relação existente entre o teor de Cla-a e de biomassa fitoplanctônica pode variar com o tempo (Llodrà-Llabrés et al., 2023). Assim, esse pode ser mais um motivo para o desempenho pouco satisfatório dos modelos testados com os dados deste estudo.

Os elevados erros avaliados pelos valores de NRMSE e NSE, mesmo quando o R^2 apresentou correlação forte ou muito forte, também indica que os modelos podem estar superajustados (overfitting) aos dados de treinamento. Nesse caso, sugere-se uma recalibração dos modelos para os reservatórios em que o R^2 apresentou bom desempenho, como alternativa para elevar a generalização dos mesmos.

As correlações existentes entre as concentrações de Cla-a de campo e as estimadas pelos modelos espectrais, foram maiores ao utilizar as imagens Sentinel 2 corrigidas com o Sen2cor, do que quando aplicado o SIAC. Corroborando com essa análise, Sherjah et al. (2023) avaliaram as reflectâncias das bandas B1 a B6 das imagens Sentinel 2 corrigidas pelo SIAC, contudo apenas a B3 e B4 apresentaram precisões aceitáveis para serem usadas em índices de estimativa do estado trófico. Contudo, segundo as métricas avaliadas por Maciel et al. (2021), tanto o SIAC, quanto o Sen2cor demonstraram desempenhos razoáveis para a correção atmosférica de B2 a B6 do Sentinel 2.

Essas contrariedades presentes na literatura, quanto a eficiência do SIAC e do Sen2cor, ocorrem porque o desempenho dos ACPs pode variar dependendo do tipo do corpo hídrico analisado (Li et al., 2023). Portanto, para entender

melhor o potencial e as limitações de cada algoritmo disponível, recomenda-se uma extensa validação para diferentes tipos de água e condições atmosféricas (Martins et al., 2017). Por exemplo, o Sen2cor exibe resultados de reflectância da superfície realistas ao se trabalhar com lagos mais turvos, contudo o desempenho é ruim quando o ambiente aquático é mais escuro (Toming et al., 2016). A eficiência do Sen2cor também é baixa quando os corpos d'água são mais limpos (Li et al., 2023). Já os algoritmos de correção atmosférica baseados em modelos 6SV, como é o caso do SIAC, tendem a apresentar melhores resultados em águas brilhantes, do que o Sen2cor (Martins et al., 2017). Logo, fazendo análises em um grande número de reservatórios com características heterogêneas, como neste estudo, é difícil chegar a uma tendência ou apontar de forma contundente a qualidade de um ou outro ACP. Para que seja feita uma análise mais profunda do desempenho destes ACPs, recomenda-se a captura da reflectância da superfície da água in loco, em consonância com a passagem do satélite, aumentando assim a segurança na utilização de uma dessas duas metodologias de correção atmosférica no GEE.

Tratando-se da janela temporal utilizada neste trabalho para aquisição dos dados de satélite (± 10 dias), esta foi determinada visando obter o maior número de imagens possível, sem comprometer a precisão dos modelos empregados. Não há um consenso sobre o tamanho ótimo da janela temporal existente entre as datas das coletas de campo e das imagens de satélite. Contudo, melhores desempenhos são obtidos quanto menor for esta diferença de dias (Flores-Anderson et al., 2020). Isso acontece porque pode ocorrer uma floração de algas entre estas duas medidas, já que as mesmas podem surgir e desaparecer em poucos dias (Lee et al., 2005). Alguns autores recomendam intervalos temporais menores do que o utilizado, considerando que ± 2 dias é o mais adequado para obtenção de maior desempenho no emprego de modelos que estimam Cla-a e IET (Lobo et al., 2021). Outros autores obtiveram sucesso na geração de modelos espectrais de Cla-a mesmo com janelas temporais maiores, sendo estas de ± 5 dias (Toming et al., 2016), ± 7 dias (Aranha et al., 2022) e ± 15 dias (Coelho et al., 2017).

De modo geral, pode-se obter elevada eficiência nas estimativas de Cla-a com uma janela temporal maior, como a utilizada, dependendo da estabilidade do corpo hídrico e do período climático (Llodrà-Llabrés et al., 2023). Com a região de estudo não é diferente, uma vez que as concentrações de Cla-a dos reservatórios do SAB demonstram diferentes respostas às variáveis de entrada (nitrogênio total, fósforo total, volume e

precipitação diária) segundo as suas condições (estratificação da coluna d'água, ressuspensão de sedimento, ação do vento, entre outros) (Guimarães & Lima Neto, 2023). Os picos de Cla-a nesta região são mais frequentes em meses de maiores precipitações (variação intranual) e em baixos volumes (Guimarães & Lima Neto, 2023). Há indícios de que a escolha do satélite também pode influenciar no aumento da janela temporal, sem prejudicar o desempenho dos modelos espectrais. Por exemplo, melhores eficiências são relatadas em janelas temporais maiores ao utilizar as resoluções do Sentinel 2, se comparado com o Landsat 5 e 8, em que a diferença temporal máxima de sucesso foi de um e três dias, respectivamente (Kayastha et al., 2022).

Neste estudo, foram considerados dados de campo cujas coletas amostrais ocorreram em pontos próximos às margens dos reservatórios. Nessas regiões é comum ocorrer a presença de macrófitas, o que dificulta a extração de pixels de água sem a interferência destes fitoplânctons. Rodrigues et al. (2020) ao estudarem reservatórios do SAB, também identificaram este problema e estimaram que sempre ocorre um sinal de fundo oriundo de macrófitas emergentes flutuantes. Pontos de coleta próximos às regiões litorâneas também podem ser um problema por causa do efeito de adjacência do solo (Llodrà-Llabrés et al., 2023). Além do mais, é provável que a mata ciliar também interfira na reflectância recebida, principalmente na correção atmosférica do Sentinel 2 (Martins et al., 2017).

Neste estudo não foram analisados outros parâmetros de qualidade da água além de Cla-a. O conhecimento de outros componentes, como as concentrações de NAP e CDOM, proporcionaria entender melhor a complexidade espectral dos corpos hídricos estudados. Portanto, sugere-se a classificação dos reservatórios segundo seus OWTs, para melhor avaliar as eficiências dos modelos espectrais de estimativa de Cla-a e os ACPs para cada tipo de água.

Conclusão

Os resultados demonstraram uma baixa eficiência dos modelos testados quando empregados em um grande número de reservatórios, possivelmente por possuírem dependência espacial por ambientes com características semelhantes aos locais onde foram gerados. Além disso, a quantidade de correlações também se reduziu à medida que o período de análise aumentou (de 2019-2022 para 2015-2022), podendo ser resultado, também, de uma limitada representatividade temporal dos modelos. Em relação à eficiência dos algoritmos de correção

atmosférica Sen2cor e SIAC, percebeu-se que, ao utilizar as imagens Sentinel 2 corrigidas pelo Sen2cor, as correlações foram um pouco maiores, do que ao trabalhar com as imagens corrigidas pelo SIAC. Entre as formas de agrupamento utilizadas (por reservatórios individualmente, por volume dos reservatórios no dia da coleta e por concentração de Cla-a de campo), a que representou a melhor maneira de analisar a eficiência dos modelos espectrais foi a por reservatórios, já que cada corpo hídrico pode apresentar respostas espectrais específicas.

Agradecimentos

Aos financiadores deste trabalho: a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão das bolsas de pesquisa, processos de nº 88887.672242/2022-00 e 88887.672869/2022-00; ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo financiamento do projeto nº 409341/2021-5; a Fundação de Amparo à Pesquisa do Estado da Paraíba (FAPESQ) pelos projetos aprovados nos editais nº 10/2021 e nº 16/2023; e ao Programa de Pesquisa Ecológica de Longa Duração (PELD RIPA) Rio Paraíba Integrado (FAPESQ/PELD nº 23/2020). Carlinda Medeiros agradece ao CNPq pela bolsa de Pós-Doutorado (Processo: 152330/2024-0).

Referências

- Alawadi, F., 2010. Detection of surface algal blooms using the newly developed algorithm surface algal bloom index (SABI). SPIE Proceedings, 7825. <https://doi.org/10.1117/12.862096>
- Alparslan, E., Aydoğan, C., Tufekci, V., & Tufekci, T., 2007. Water quality assessment at Ömerli Dam using remote sensing techniques. Environmental Monitoring and Assessment, 135, 391-398. <https://doi.org/10.1007/s10661-007-9658-6>.
- ANA. Agência Nacional de Águas e Saneamento Básico, 2023. Sistema de Acompanhamento de Reservatórios (SAR): Nordeste e Semiárido. 2023. Disponível: <https://www.ana.gov.br/sar/nordeste-e-semiarido>. Acesso: 20 fev. 2023.
- Aranha, T. R. B. T., Martinez, J. M., Souza, E. P., Barros, M. U. G., & Martins, E. S. P. R., 2022. Remote analysis of the chlorophyll-a concentration using Sentinel-2 MSI images in

- a Semiarid environment in northeastern Brazil. *Water*, 14(3), 451. <https://doi.org/10.3390/w14030451>.
- Araújo Filho, J. C., Correa, M. M., Paiva, A. Q., Costa, O. V., Valladares, G. S., Ribeiro, M. R., & Schaefer, C. E. G. R., 2023. Semi-arid Soils of the Caatinga Biome of Northeastern Brazil. In C. E. G. R. Schaefer (Ed.), *The Soils of Brazil*. Springer Cham, pp. 175-193. https://doi.org/10.1007/978-3-031-19949-3_6.
- AWWA. American Water Works Association, APHA. American Public Health Association, & WEF., 2012. *Water Environment Federation. Standard Methods for the Examination of Water and Wastewater*. 22 ed. APHA.
- Barbosa, C. C. F., Novo, E. M. L. M., & Martins, V. S., 2019. *Introdução ao Sensoriamento Remoto de Sistemas Aquáticos: Princípios e aplicações*. 1 ed. LabISA\INPE, São José dos Campos, 161 p. ISBN 978-85-17-00095-9 (E-book).
- Beck, R., Zhan, S., Liu, H., Tong, S., Yang, B., Xu, M., Ye, Z., Huang, Y., Shu, S., Wu, Q., Wang, S., Berling, K., Murray, A., Emery, E., Reif, M., Harwood, J., Young, J., Nietch, C., Macke, D., Martin, M., Stillings, G., Stump, R., & Su, H., 2016. Comparison of satellite reflectance algorithms for estimating chlorophyll-a in a temperate reservoir using coincident hyperspectral aircraft imagery and dense coincident surface observations. *Remote Sensing of Environment*, 178, 15-30. <https://doi.org/10.1016/j.rse.2016.03.002>.
- Cao, Q., Yu, G., & Qiao, Z., 2023. Application and recent progress of inland water monitoring using remote sensing techniques. *Environ. Monit. Assess.*, 195(125). <https://doi.org/10.1007/s10661-022-10690-9>.
- Carlson, R. E., 1977. A trophic state index for lakes. *Limnol. Oceanogr.*, 22(2), 361-369. <https://doi.org/10.4319/lo.1977.22.2.0361>.
- Ceará. Secretaria dos Recursos Hídricos, 1994. Decreto nº 23.068, de 11 de fevereiro de 1994. Regulamenta o controle técnico das obras de oferta hídrica e dá outras providências. *Diário Oficial do Estado*.
- Chen, L., Tan, C. H., Kao, S. J., & Wang, T. S., 2008. Improvement of remote monitoring on water quality in a subtropical reservoir by incorporating grammatical evolution with parallel genetic algorithms into satellite imagery. *Water Res.*, 42(1-2), 296-306. <https://doi.org/10.1016/j.watres.2007.07.014>.
- Ciancia, E., Campanelli, A., Colonna, R., Palombo, A., Pascucci, S., Pignatti, S., & Pergola, N., 2023. Improving Colored Dissolved Organic Matter (CDOM) Retrievals by Sentinel2-MSI Data through a Total Suspended Matter (TSM)-Driven Classification: The Case of Pertusillo Lake (Southern Italy). *Remote Sens.*, 15(24:5718). <https://doi.org/10.3390/rs15245718>.
- Cirilo, J. A., Montenegro, S. M. G. L., & Campos, J. N. B., 2010. A questão da água no Semiárido brasileiro. In: Bicudo, C. E. M.; Tundisi, J. G.; Scheuenstuhl, M. C. B. (Orgs.). *Águas do Brasil: análises estratégicas*. Instituto de Botânica, São Paulo, pp. 81-91. ISBN 978-85-85761-32-5.
- Coelho, C., Heim, B., Foerster, S., Brosinsky, A., & Araújo, J. C., 2017. In Situ and Satellite Observation of CDOM and Chlorophyll-a Dynamics in Small Water Surface Reservoirs in the Brazilian Semiarid Region. *Water*, 9(12), 913. <https://doi.org/10.3390/w9120913>.
- Concha, J. A., & Schott, J. R., 2016. Retrieval of color producing agents in Case 2 waters using Landsat 8. *Remote Sensing of Environment*, 185, 95-107. <https://doi.org/10.1016/j.rse.2016.03.018>.
- Cortez, F., Monicelli, F., Cavalcante, H., & Becker, V., 2022. Effects of prolonged drought on water quality after drying of a semiarid tropical reservoir, Brazil. *Limnologica*, 93, 125959. <https://doi.org/10.1016/j.limno.2022.125959>.
- Cui, T. W., Zhang, J., Wang, K., Wei, J. W., Mu, B., Ma, Y., Zhu, J. H., Liu, R. J., & Chen, X. Y., 2020. Remote sensing of chlorophyll a concentration in turbid coastal waters based on a global optical water classification system. *ISPRS Journal of Photogrammetry and Remote Sensing*, 163, 187-201. <https://doi.org/10.1016/j.isprsjprs.2020.02.017>.
- ESA. European Space Agency, 2023. Sentinel-2. Disponível:

- <https://sentinels.copernicus.eu/web/sentinel/copernicus/sentinel-2>. Acesso: 01 dez. 2023.
- Evans, J. D., 1996. Straightforward statistics for the behavioral sciences. Thomson Brooks/Cole Publishing Co.
- Flores-Anderson, A. I., Griffin, R., Dix, M., Romero-Oliva, C. S., Ochaeta, G., Skinner-Alvarado, J., Ramirez Moran, M. V., Hernandez, B., Cherrington, E., Page, B., & Barreno, F., 2020. Hyperspectral Satellite Remote Sensing of Water Quality in Lake Atitlán, Guatemala. *Frontiers in Environmental Science*, 8. <https://doi.org/10.3389/fenvs.2020.00007>.
- Gernez, P., Zoffoli, M. L., Lacour, T., Fariñas, T. H., Navarro, G., Caballero, I., & Harmel, T., 2023. The many shades of red tides: Sentinel-2 optical types of highly-concentrated harmful algal blooms. *Remote Sensing of Environment*, 287(113486). <https://doi.org/10.1016/j.rse.2023.113486>.
- Gheyi, H. R., Paz, V. P. S., Medeiros, S. S., & Galvão, C. O., 2012. (Eds.). Recursos hídricos em regiões semiáridas. Instituto Nacional do Semiárido / Universidade Federal do Recôncavo da Bahia. ISBN 978-85-64265-03-5.
- Gholizadeh, M. H., Melesse, A. M., & Reddi, L., 2016. A Comprehensive Review on Water Quality Parameters Estimation Using Remote Sensing Techniques. *Sensors*, 16(8), 1298. <https://doi.org/10.3390/s16081298>.
- Gilerson, A. A., Gitelson, A. A., Zhou, J., Gurlin, D., Moses, W., Ioannou, I., & Ahmed, S. A., 2010. Algorithms for remote estimation of chlorophyll-a in coastal and inland waters using red and near infrared bands. *Opt Express*, 18(23), 24109-24125. <https://doi.org/10.1364/OE.18.024109>.
- Gitelson, A. A., Dall'olmo, G., Moses, W., Rundquist, D. C., Barrow, T., Fisher, T. R., Gurlin, D., & Holz, J., 2008. A simple semi-analytical model for remote estimation of chlorophyll-a in turbid waters: validation. *Remote Sensing of Environment*, 112(9), 3582-3593. <https://doi.org/10.1016/j.rse.2008.04.015>.
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N., 2003. Relationships between Leaf Chlorophyll Content and Spectral Reflectance and Algorithms for Non-Destructive Chlorophyll Assessment in Higher Plant Leaves. *Journal of Plant Physiology*, 160(3), 271-282. <https://doi.org/10.1078/0176-1617-00887>.
- Gonçalves-Araujo, R., Röttgers, R., Haraguchi, L., & Brandini, F. P., 2019. Hydrography-Driven Variability of Optically Active Constituents of Water in the South Brazilian Bight: Biogeochemical Implications. *Front. Mar. Sci.*, 6. <https://doi.org/10.3389/fmars.2019.00716>.
- Gons, H. J., Rijkeboer, M., & Ruddick, K. G., 2002. A chlorophyll-retrieval algorithm for satellite imagery (Medium Resolution Imaging Spectrometer) of inland and coastal waters. *Journal of Plankton Research*, 24(9), 947-951. <https://doi.org/10.1093/plankt/24.9.947>.
- Gotelli, N. J., & Ellison, A. M., 2011. *Princípios de estatística em ecologia*. Artmed.
- Guimarães, B. M. D. M., & Lima Neto, I. E., 2023. Chlorophyll-a prediction in tropical reservoirs as a function of hydroclimatic variability and water quality. *Environmental Science and Pollution Research*, 30(39), 91028-91045. <https://doi.org/10.1007/s11356-023-28826-w>.
- Gurlin, D., Gitelson, A. A., & Moses, W. J., 2011. Remote estimation of chl-a concentration in turbid productive waters — Return to a simple two-band NIR-red model? *Remote Sensing of Environment*, 115(12), 3479-3490. <https://doi.org/10.1016/j.rse.2011.08.011>.
- Ha, N. T. T., Koike, K., Nhuan, M. T., Canh, B. D., Thao, N. T. P., & Parsons, M., 2017. Landsat 8/OLI Two Bands Ratio Algorithm for Chlorophyll-A Concentration Mapping in Hypertrophic Waters: An Application to West Lake in Hanoi (Vietnam). *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(11), 4919-4929. <https://doi.org/10.1109/JSTARS.2017.2739184>
- Hajigholizadeh, M., Moncada, A., Kent, S., & Melesse, A. M., 2021. Land–lake linkage and remote sensing application in water quality monitoring in lake Okeechobee, Florida, USA. *Land*, 10(2), 147. <https://doi.org/10.3390/land10020147>.

- IPCC. Intergovernmental Panel on Climate Change, 2023. Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. IPCC. <https://doi.org/10.59327/IPCC/AR6-9789291691647.00>.
- ISO. International Organization for Standardization, 1992. ISO 10260. Water quality - Measurement of biochemical Parameters - Spectrometric determination of the chlorophyll-a concentration. ISO.
- ISO. International Organization for Standardization. 1991. ISO 5667-2. Water quality - Sampling. Part 2: Guidance on sampling techniques. ISO.
- Kayastha, P., Dzialowski, A. R., Stoodley, S. H., Wagner, K. L., & Mansaray, A. S., 2022. Effect of Time Window on Satellite and Ground-Based Data for Estimating Chlorophyll-a in Reservoirs. *Remote Sens.*, 14(4), 846. <https://doi.org/10.3390/rs14040846>.
- Lee, J. H. W., Hodgkiss, I. J., Wong, K. T. M., & Lam, I. H. Y., 2005. Real time observations of coastal algal blooms by an early warning system. *Estuarine, Coastal and Shelf Science*, 65(1-2), 172-190. <https://doi.org/10.1016/j.ecss.2005.06.005>.
- Li, W., Huang, Y., Shen, Q., Yao, Y., Xu, W., Shi, J., Zhou, Y., Li, J., Zhang, Y., & Gao, H., 2023. Assessment of Seven Atmospheric Correction Processors for the Sentinel-2 Multi-Spectral Imager over Lakes in Qinghai Province. *Remote Sens.*, 15(22), 5370. <https://doi.org/10.3390/rs15225370>.
- Llodrà-Llabrés, J., Martínez-López, J., Postma, T., Pérez-Martínez, C., & Alcaraz-Segura, D., 2023. Retrieving water chlorophyll-a concentration in inland waters from Sentinel-2 imagery: Review of operability, performance and ways forward. *International Journal of Applied Earth Observation and Geoinformation*, 125, 103605. <https://doi.org/10.1016/j.jag.2023.103605>.
- Lobo, F. L., Nagel, G. W., Maciel, D. A., Carvalho, L. A. S., Martins, V. S., Barbosa, C. C. F., & Novo, E. M. L. M., 2021. AlgaeMAP: Algae Bloom Monitoring Application for Inland Waters in Latin America. *Remote Sens.*, 13(15), 2874. <https://doi.org/10.3390/rs13152874>.
- Ma, Y., Sun, D., Liu, W., You, Y., Wang, S., Sun, Z., & Wang, S., 2022. Using a Remote-Sensing-Based Piecewise Retrieval Algorithm to Map Chlorophyll-a Concentration in a Highland River System. *Remote Sensing*, 14(23), 6119. <https://doi.org/10.3390/rs14236119>.
- Maciel, D. A., Barbosa, C. C. F., Novo, E. M. L. M., Flores Jr., R., & Begliomini, F. N., 2021. Water clarity in Brazilian water assessed using Sentinel-2 and machine learning methods. *ISPRS Journal of Photogrammetry and Remote Sensing*, 182, 134-152. <https://doi.org/10.1016/j.isprsjprs.2021.10.009>.
- Markogianni, V., Kalivas, D., Petropoulos, G. P., & Dimitriou, E., 2020. Estimating Chlorophyll-a of Inland Water Bodies in Greece Based on Landsat Data. *Remote Sens.*, 12(13), 2087. <https://doi.org/10.3390/rs12132087>.
- Martini, L. C. P., Mattos, D. S., Barbosa, D. F. P., & Rech, A. I. B., 2006. Sensoriamento remoto para avaliação da Clorofila-a na Lagoa da Conceição. *Eng. sanit. ambient.*, 11(4), 318-324. <https://doi.org/10.1590/S1413-41522006000400004>.
- Martins, V. S., Barbosa, C. C. F., Carvalho, L. A. S., Jorge, D. S. F., Lobo, F. D. L., & Novo, E. M. L. M., 2017. Assessment of Atmospheric Correction Methods for Sentinel-2 MSI Images Applied to Amazon Floodplain Lakes. *Remote Sens.*, 9(4), 322.
- Matthews, M. W., 2011. A current review of empirical procedures of remote sensing in inland and near-coastal transitional waters. *International Journal of Remote Sensing*, 32(21), 6855-6899. <https://doi.org/10.1080/01431161.2010.512947>.
- Mcfeters, S. K., 1996. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425-1432. <https://doi.org/10.1080/01431169608948714>.

- Mishra, S., & Mishra, D. R., 2012. Normalized difference chlorophyll index: a novel model for remote estimation of chlorophyll-a concentration in turbid productive waters. *Remote Sensing of Environment*, 117, 394-406.
<https://doi.org/10.1016/j.rse.2011.10.016>.
- Moses, W. J., Gitelson, A. A., Berdnikov, S., & Povazhnyy, V., 2009. Satellite Estimation of Chlorophyll-a concentration using the red and NIR bands of MERIS - The Azov Sea case study. *IEEE Geoscience and Remote Sensing Letters*, 6(4), 845-849.
<https://doi.org/10.1109/LGRS.2009.2026657>.
- Neil, C., Spyarakos, E., Hunter, P. D., & Tyler, A. N., 2020. Corrigendum to “A global approach for chlorophyll-a retrieval across optically complex inland waters based on optical water types” [*Remote Sens. Environ.*, 229: 159–178]. *Remote Sens. Environ.*, 246, 111837.
- Nguyen, U. N. T., Pham, L. T. H., & Dang, T. D., 2019. An automatic water detection approach using Landsat 8 OLI and Google Earth Engine cloud computing to map lakes and reservoirs in New Zealand. *Environ. Monit. Assess.*, 191(235). <https://doi.org/10.1007/s10661-019-7355-x>.
- Nogueira, D. B., Silva, A. O., Giroldo, A. B., Silva, A. P. N., & Costa, B. R. S., 2023. Dry spells in a semi-arid region of Brazil and their influence on maize productivity. *Journal of Arid Environments*, 209, 104892.
<https://doi.org/10.1016/j.jaridenv.2022.104892>.
- O'Reilly, J. E., Maritorena, S., Mitchell, B. G., Siegel, D. A., Carder, K. L., Garver, S. A., Kahru, M., & McClain, C., 1998. Ocean color chlorophyll algorithms for SeaWiFS. *Journal Of Geophysical Research*, 103(C11), 24937-24953. <https://doi.org/10.1029/98JC02160>.
- O'Reilly, J. E., Maritorena, S., O'Brien, M. C., Siegel, D. A., Toole, D., Menzies, D., Smith, R. C., Mueller, J. L., Mitchell, B. G., Kahru, M., Chavez, F. P., Strutton, P., Cota, G. F., Hooker, S. B., McClain, C. R., Carder, K. L., Mueller-Karger, F., Harding, L., Magnuson, A., Phynney, D., Moore, G. F., Aiken, J., Arrigo, K. R., Letelier, R., & Culver, M., 2000. SeaWiFS Postlaunch Calibration and Validation Analyses, Part 3. NASA Goddard Space Flight Center.
- Oliveira, S. C., 2018. Tratamento estatístico de dados ambientais (ESA 944). Universidade Federal de Minas Gerais (UFMG).
- Ouma, Y. O., Noor, L., & Herbert, K., 2020. Modelling Reservoir Chlorophyll-a, TSS, and Turbidity Using Sentinel-2A MSI and Landsat-8 OLI Satellite Sensors with Empirical Multivariate Regression. *Hindawi - Journal of Sensors*, 2020.
<https://doi.org/10.1155/2020/8858408>.
- Paiva, L. V. Q., & Souza, B. I., 2022. Potential for rain water capture in semi-arid urban areas. *International Journal of Hydrology*, 6(6), 236–241.
<https://doi.org/10.15406/ijh.2022.06.00331>.
- Paloschi, R. A., Ramos, D. M., Ventura, D. J., Souza, R., Souza, E., Morellato, L. P. C., Nóbrega, R. L. B., Coutinho, Í. A. C., Verhoef, A., Körting, S., & Borma, L. S., 2021. Environmental Drivers of Water Use for Caatinga Woody Plant Species: Combining Remote Sensing Phenology and Sap Flow Measurements. *Remote Sensing*, 13(1), 75.
<https://doi.org/10.3390/rs13010075>.
- Pereira Neto, M. C., 2017. Prospects of the construction of dam in semiarid brazilian and its implications in the region Seridó of the state of Rio Grande do Norte. *Sociedade & Natureza*, 29(2), 285-294, 2017.
<https://doi.org/10.14393/sn-v29n2-2017-7>.
- Peterson, K. T., Sagan, V., & Sloan, J. J., 2020. Deep learning based water quality estimation and anomaly detection using Landsat-8/Sentinel-2 virtual constellation and cloud computing. *GIScience & Remote Sensing*, 57(4), 510-525.
<https://doi.org/10.1080/15481603.2020.1738061>.
- Pompei, C. M. E., Alves, E. D. L., Vieira, E. M., & Campos, L. C., 2020. Impact of meteorological variables on water quality parameters of a reservoir and ecological filtration system. *Int. J. Environ. Sci. Technol.*, 17, 1387–1396.
<https://doi.org/10.1007/s13762-019-02552-8>.
- Raulino, J. B. S., Silveira, S., & Lima Neto, I. E., 2021. Assessment of climate change impacts on hydrology and water quality of large semi-

- arid reservoirs in Brazil. *Hydrological Sciences Journal*, 66(8), 1321-1336. <https://doi.org/10.1080/02626667.2021.1933491>.
- Reynolds, C. S., 1984. *The Ecology of Freshwater Phytoplankton*. Cambridge University Press.
- Rocha Junior, C. A. N., Costa, M. R. A., Menezes, R. F., Attayde, J. L., & Becker, V., 2018. Water volume reduction increases eutrophication risk in tropical semi-arid reservoirs. *Acta Limnologica Brasiliensia*, 30. <https://doi.org/10.1590/S2179-975X2117>.
- Rodrigues, G., Potes, M., Costa, M. J., Novais, M. H., Penha, A. M., Salgado, R., & Morais, M. M., 2020. Temporal and Spatial Variations of Secchi Depth and Diffuse Attenuation Coefficient from Sentinel-2 MSI over a Large Reservoir. *Remote Sens.*, 12(5), 768. <https://doi.org/10.3390/rs12050768>.
- Sagan, V., Peterson, K. T., Maimaitijiang, M., Sidike, P., Sloan, J., Greeling, B. A., Maalouf, S., & Adams, C., 2020. Monitoring inland water quality using remote sensing: potential and limitations of spectral indices, bio-optical simulations, machine learning, and cloud computing. *Earth-Science Reviews*, 205, 103187. <https://doi.org/10.1016/j.earscirev.2020.103187>.
- Satish, N., Rajitha, K., Anmala, J., & Varma, M. R. R., 2023. Trophic status estimation of case-2 water bodies of the Godavari River basin using satellite imagery and artificial neural network (ANN). *H2Open Journal*, 6(2), 297-314. <https://doi.org/10.2166/h2oj.2023.034>.
- Schaeffli, B., & Gupta, H. V., 2007. Do Nash values have value? *Hydrological Processes*, 21(15), 2075-2080. <https://doi.org/10.1002/hyp.6825>.
- Shapiro, S. S., & Wilk, M. B., 1965. An Analysis of Variance Test for Normality (Complete Samples). *Biometrika*, 52(3/4), 591-611. <https://doi.org/10.2307/2333709>.
- Sherjah, P. Y., Sajikumar, N., & Nowshaja, P. T., 2023. Quality monitoring of inland water bodies using Google Earth Engine. *Journal of Hydroinformatics*, 25(2), 432-450. <https://doi.org/10.2166/hydro.2023.137>.
- Sherjah, P. Y., Sajikumar, N., & Nowshaja, P. T., 2022. Semi-analytical model for TSI estimation of inland water bodies from Sentinel 2 imagery. *Journal of Hydroinformatics*, 24(2), 444-463. <https://doi.org/10.2166/hydro.2022.151>.
- SNISB. Sistema Nacional de Informações Sobre Segurança de Barragens, 2024. Consultar Barragens. Disponível: <https://www.snish.gov.br/portal-snish/consultar-barragem>. Acesso: 08 out. 2024.
- SUDENE. Superintendência do Desenvolvimento do Nordeste, 2017. Delimitação do Semiárido. Disponível: <https://www.gov.br/sudene/pt-br/assuntos/projetos-e-iniciativas/delimitacao-do-semiarido>. Acesso: 10 maio 2022.
- Tavares, M. H., Lins, R. C., Harmel, T., Fragoso Jr., C. R., Martínez, J. M., & Motta-Marques, D., 2021. Atmospheric and sunglint correction for retrieving chlorophyll-a in a productive tropical estuarine-lagoon system using Sentinel-2 MSI imagery. *ISPRS J. Photogramm. Remote Sens.*, 174, 215-236. <https://doi.org/10.1016/j.isprsjprs.2021.01.021>.
- Toledo Jr., A. P., 1990. Informe preliminar sobre os estudos para a obtenção de um índice para avaliação do estado trófico de reservatórios de regiões quentes tropicais. Companhia de Tecnologia de Saneamento Ambiental.
- Toming, K., Kutser, T., Laas, A., Sepp, M., Paavel, B., & Nõges, T., 2016. First Experiences in Mapping Lake Water Quality Parameters with Sentinel-2 MSI Imagery. *Remote Sensing*, 8(8), 640. <https://doi.org/10.3390/rs8080640>.
- Topp, S. N., Pavelsky, T. M., Jensen, D., Simard, M., & Ross, M. R. V., 2020. Research Trends in the Use of Remote Sensing for Inland Water Quality Science: Moving Towards Multidisciplinary Applications. *Water*, 12(1:169). <https://doi.org/10.3390/w12010169>.
- Tundisi, J. G., Tucci, C. E. M., Spilki, F. R., Hespanhol, I., Cirilo, J. A., Scheuenstuhl, M. C. B., & Periotto, N. A., 2015. Urban Waters in Brazil. In: IANAS – Interamerican Network of Academies of Sciences. Urban water challenges in the Americas: a perspective from the Academies of Sciences. IANAS / UNESCO, México, pp. 86-111.

- Xu, M., Liu, H., Beck, R., Lekki, J., Yang, B., Shu, S., Kang, E. L., Anderson, R., Johansen, R., Emery, E., Reif, M., & Benko, T., 2018. A spectral space partition guided ensemble method for retrieving chlorophyll-a concentration in inland waters from Sentinel-2A satellite imagery. *Journal of Great Lakes Research*, 45(3), 454-465. <https://doi.org/10.1016/j.jglr.2018.09.002>.
- Yang, H., Kong, J., Hu, H., Du, Y., Gao, M., & Chen, F. A., 2022. A review of remote sensing for water quality retrieval: progress and challenges. *Remote Sens.*, 14(8), 1770. <https://doi.org/10.3390/rs14081770>.
- Yang, Y., Hou, X., Gao, W., Li, F., Guo, F., & Zhang, Y., 2024. Retrieving Lake Chla concentration from remote Sensing: Sampling time matters. *Ecological Indicators*, 158, 111290. <https://doi.org/10.1016/j.ecolind.2023.111290>.
- Yin, F., Lewis, P. E., & Gomez-Dans, J. L., 2022. Bayesian atmospheric correction over land: Sentinel-2/MSI and Landsat 8/OLI. *Geosci. Model Dev.*, 15(21), 7933–7976. <https://doi.org/10.5194/gmd-15-7933-2022>.
- Zhao, D., Xing, X., Liu, Y., Yang, J., & Wang, L., 2010. The relation of chlorophyll-a concentration with the reflectance peak near 700 nm in algae-dominated waters and sensitivity of fluorescence algorithms for detecting algal bloom. *International Journal of Remote Sensing*, 31(1), 39-48. <https://doi.org/10.1080/01431160902882512>.
- Zhao, M., Bai, Y., Li, H., He, X., Gong, F., & Li, T., 2022. Fluorescence Line Height Extraction Algorithm for the Geostationary Ocean Color Imager. *Remote Sens.*, 14(11), 2511. <https://doi.org/10.3390/rs14112511>.

APÊNDICE A

Tabela A. Modelos espectrais de estimativa de Cla-a com seus respectivos dados de desenvolvimento: satélite, local de aplicação, número de amostras, intervalo de Cla-a, desempenho e autoria.

Modelo	Equação	Satélite	Local de aplicação	Nº Amostras	Cla-a (µg.L ⁻¹)	Desempenho	Fonte
1BDA	$4050,2 * B3 - 170,43$	L8	Barragem Chebara - Quênia	Cal.: 15	Cal.: 6,24 - 113,73	Val.: R ² de 0,86; MAE de 2,56 µg.L ⁻¹ ; NMAE de 54,03%; e RMSE de 5,96 µg.L ⁻¹	Ouma <i>et al.</i> (2020)
	$378524,04 * B3^2 - 30345,60 * B3 + 616,37$	S2	Barragem Chebara - Quênia	Cal.: 15	Cal.: 6,24 - 113,73	Val.: R ² de 0,63; MAE de 3,49 µg.L ⁻¹ ; NMAE de 73,14%; e RMSE de 27,34 µg.L ⁻¹	Ouma <i>et al.</i> (2020)
	$28,1 * e^{0,72 * \left(\frac{B3}{B2}\right)}$	L8	Lago West em Hanói - Vietnã	Cal.: 19. Val.: 20	Cal.: 48,7 - 164. Val.: 42 - 258	Cal.: R de 0,88; e MSE de 3,89 µg.L ⁻¹ . Val.: R de 0,78; e MSE de 7,96 µg.L ⁻¹	Ha <i>et al.</i> (2017)
2BDA	$735,98 * B1 - 425,88 * B2 - 60,20$	L5	Lagoa da Conceição, Florianópolis (SC) - Brasil	5	2,5 - 7,6	R ² de 0,96	Martini <i>et al.</i> (2006)
	$402,73 * \ln(B2 + B3) + 888,88$	L8	Barragem Chebara - Quênia	Cal.: 15	Cal.: 6,24 - 113,73	Val.: R ² de 0,85; MAE de 1,98 µg.L ⁻¹ ; NMAE de 60,11%; e RMSE de 7,70 µg.L ⁻¹	Ouma <i>et al.</i> (2020)
	$3188,9 * (B2 + B3) - 349,09$	L8	Barragem Chebara - Quênia	Cal.: 15	Cal.: 6,24 - 113,73	Val.: R ² de 0,85; MAE de 1,41 µg.L ⁻¹ ; NMSE de 59,59%; e RMSE de 8,29 µg.L ⁻¹	Ouma <i>et al.</i> (2020)
	$53,29 * \left(\frac{B9}{B7}\right) - 30,08$	Meris	Sistemas aquáticos continentais e costeiros globais	-	-	Val.: R de 0,82; RMSE de 0,21 µg.L ⁻¹ ; MAE de 0,16 µg.L ⁻¹ ; RPD de 50,48; e BIAS de -0,03 µg.L ⁻¹	Moses <i>et al.</i> (2009), adaptado por Neil <i>et al.</i> (2020)
	$86,09 * \left(\frac{B9}{B7}\right)^2 - 517,5 * \left(\frac{B9}{B7}\right) + 886,7$	Meris	Sistemas aquáticos continentais e costeiros globais	-	-	Val.: R de 0,65; RMSE de 0,20 µg.L ⁻¹ ; MAE de 0,17 µg.L ⁻¹ ; RPD de 65,79; e BIAS de -0,06 µg.L ⁻¹	Gurlin <i>et al.</i> (2011), adaptado por Neil <i>et al.</i> (2020)
	$\frac{\left(\frac{B9}{B7}\right) * \left(0,7 + 0,016_{0,016} - 0,4 - 0,016_{0,016}^{1,063}\right)}{0,016}$	Meris	Lagoa Ijssel (Holanda)	Cal.: 114. Val.: 91	Cal.: 3 - 185. Val.: 1 - 181	Cal.: SE de 8,3 µg.L ⁻¹ . Val.: SE de 9,2 µg.L ⁻¹	Gons <i>et al.</i> (2002)

Modelo	Equação	Satélite	Local de aplicação	Nº Amostras	Cla-a (µg.L ⁻¹)	Desempenho	Fonte
	$66,644 * \left(\frac{B9}{B7}\right) - 28,538$	Meris	Lago Harsha no sudoeste de Ohio - EUA	9	-	R de 0,92; e R ² de 0,84	Beck <i>et al.</i> (2016)
	$61,324 * \left(\frac{B9}{B7}\right) - 37,94$	Meris	Baía de Taganrog e mar de Azov, na Rússia	Cal.: 18. Val.: 8	Cal.: 0,63 - 65,51. Val.: 18,37 - 47,86	Cal.: R ² de 0,97. Val.: RMSE de 3,65 µg.L ⁻¹	Moses <i>et al.</i> (2009)
	$25,28 * \left(\frac{B9}{B7}\right)^2 + 14,85 * \left(\frac{B9}{B7}\right) - 15,18$	Meris	Lagos Fremont, Nebraska EUA	Cal.: 89. Val.: 63	Cal.: 0 - 100. Val.: 0 - 100 Cal.: 0 - 100. Val.: 0 - 25	Cal.: R ² de 0,95. Val.: MAE de 2,3 µg.L ⁻¹ ; RMSE de 3,6 µg.L ⁻¹ ; e NMAE de 11,6% Cal.: R ² de 0,95. MAE de 1,2 µg.L ⁻¹ ; RMSE de 1,4 µg.L ⁻¹ ; e NMAE de 11,5%	Gurlin <i>et al.</i> (2011)
	$\left[35,75 * \left(\frac{B9}{B7}\right) - 19,30\right]^{1,124}$	Meris	Lagos Fremont, Nebraska EUA	Cal.: 89. Val.: 63	Cal.: 0 - 100. Val.: 0 - 100 Cal.: 0 - 100. Val.: 0 - 25	Val.: MAE de 2,8 µg.L ⁻¹ ; RMSE de 5,0 µg.L ⁻¹ ; e NMAE de 12,6% Val.: MAE de 1,2 µg.L ⁻¹ ; RMSE de 1,6 µg.L ⁻¹ ; e NMAE de 11,9%	Gurlin <i>et al.</i> (2011)
	$190,34 * \left(\frac{B15}{B13}\right) - 32,45$	Modis	Lagos Fremont, Nebraska EUA	Cal.: 89. Val.: 63	Cal.: 0 - 100. Val.: 0 - 100 Cal.: 0 - 100. Val.: 0 - 25	Cal.: R ² de 0,75. Val.: MAE de 4,6 µg.L ⁻¹ ; RMSE de 6,1 µg.L ⁻¹ ; e NMAE de 27,6% Cal.: R ² de 0,75. MAE de 3,1 µg.L ⁻¹ ; RMSE de 3,8 µg.L ⁻¹ ; e NMAE de 30,9%	Gurlin <i>et al.</i> (2011)
	$-(16,2 \pm 1,8) + (136,3 \pm 3,2) * \left(\frac{B15}{B13}\right)$	Modis	Lagos e reservatórios em Nebraska, Iowa e Minnetonka (Minnesota)	Cal. e Val.: 241	Cal. e Val.: 1,2 - 236	Cal. e Val.: R ² de 0,95; NRMS de 33,0%; MNB: 22,9%; e RMSE de 10,9 µg.L ⁻¹	Gitelson <i>et al.</i> (2008)
	$70,75 * \left(\frac{B5}{B4}\right) - 58,45$	S2	Lago Harsha em Ohio - EUA	Cal.: 28. Val.: 28	Cal. e Val.: 7,84 - 60,95	Cal.: R ² 0,75. Val.: R de 0,87; e RMSE de 4,5 µg.L ⁻¹	Xu <i>et al.</i> (2018)

Modelo	Equação	Satélite	Local de aplicação	Nº Amostras	Cla-a (µg.L ⁻¹)	Desempenho	Fonte
	$395763 * X^2 - 44991 * X + 1288,2$ $X = (B2 - B11)$	S2	Barragem Chebara - Quênia	Cal.: 15	Cal.: 6,24 - 113,73	Val.: R ² de 0,70; MAE de 2,87 µg.L ⁻¹ ; NMAE de 44,74%; e RMSE de 12,84 µg.L ⁻¹	Ouma <i>et al.</i> (2020)
	$246622 * X^2 - 38346 * X + 1497,6$ $X = \left(\frac{B2 + B12}{2}\right)$	S2	Barragem Chebara - Quênia	Cal.: 15	Cal.: 6,24 - 113,73	Val.: R ² de 0,63; MAE de 6,04 µg.L ⁻¹ ; NMAE de 67,47%; e RMSE de 23,20 µg.L ⁻¹	Ouma <i>et al.</i> (2020)
	$1748431,97 * X^2 - 126132,79 * X + 2289,87$ $X = \left(\frac{B2 - B11}{2}\right)$	S2	Barragem Chebara - Quênia	Cal.: 15	Cal.: 6,24 - 113,73	Val.: R ² de 0,65; MAE de 10,24 µg.L ⁻¹ ; NMAE de 73,39%; e RMSE de 18,62 µg.L ⁻¹	Ouma <i>et al.</i> (2020)
	$-13,793 * X^3 - 17,957 * X^2 - 6,7982 * X + 0,0347$ $X = \log\left(\frac{\text{blue}}{\text{green}}\right)$	Hyp.	Lago Atitlan - Guatemala	Cal.: 30. Val.: 9	Cal. e Val.: 1,01 - 10,91	Cal.: R ² de 0,7054. Val.: MRE de 31,58%; RMSE de 1,54 µg.L ⁻¹ ; BIAS de ±0,32 µg.L ⁻¹ ; PBIAS de - 8,91%; RSR de 0,63; e NSE de 0,60	Flores-Anderson <i>et al.</i> (2020)
	$-11,648 * X^3 - 16,144 * X^2 - 6,5509 * X + 0,0229$ $X = \log\left(\frac{\text{blue}}{\text{green}}\right)$	Hyp.	Lago Atitlan - Guatemala	Cal.: 30. Val.: 9	Cal. e Val.: 1,01 - 10,91	Cal.: R ² de 0,7027. Val.: MRE de 31,58%; RMSE de 1,54 µg.L ⁻¹ ; BIAS de ±0,32 µg.L ⁻¹ ; PBIAS de - 8,91%; RSR de 0,63; e NSE de 0,60	Flores-Anderson <i>et al.</i> (2020)
	$74,358 * \left(\frac{B6}{B5}\right) - 19,085$	WV 2	Lago Harsha em Ohio - EUA	29	-	R de 0,84; e R ² de 0,71	Beck <i>et al.</i> (2016)
3BDA	Período seco = $881,1 * \left(\frac{B2}{B4}\right) - 1784,7$ $* \left(\frac{B3}{B4}\right) + 5331,5 * \left(\frac{B4}{B2}\right) - 3096,2 * \left(\frac{B4}{B3}\right)$ $+ 1167 * B2 + 525,5$	L8	Lago Okeechobee - Florida, EUA	Cal. e Val.: 48	1,0 - 67,7	R ² de 0,84; SE de 8,84; e Durbin-Watson de 1,80	Hajigholizadeh <i>et al.</i> (2021)
	$593,38 * \ln(B2 + B3 + B4) + 964,48$	L8	Barragem Chebara - Quênia	Cal.: 15	Cal.: 6,24 - 113,73	Val.: R ² de 0,85; MAE de 0,85 µg.L ⁻¹ ; NMAE de 61,44%; e RMSE de 9,48 µg.L ⁻¹	Ouma <i>et al.</i> (2020)

Modelo	Equação	Satélite	Local de aplicação	Nº Amostras	Cla-a (µg.L ⁻¹)	Desempenho	Fonte
	$2749,1 * (B2 + B3 + B5) - 539,88$	L8	Barragem Chebara - Quênia	Cal.: 15	Cal.: 6,24 - 113,73	Val.: R ² de 0,86; MAE de 0,48 µg.L ⁻¹ ; NMAE de 60,94%; e RMSE de 9,91 µg.L ⁻¹	Ouma <i>et al.</i> (2020)
	$244,2 * \left(\frac{B10}{B7 - B9}\right) + 18,12$	Meris	Sistemas aquáticos continentais e costeiros globais	-	-	Val.: R de 0,76; RMSE de 0,19 µg.L ⁻¹ ; MAE de 0,21 µg.L ⁻¹ ; RPD de 72,89; e BIAS de -0,08 µg.L ⁻¹	Moses <i>et al.</i> (2009), adaptado por Neil <i>et al.</i> (2020)
	$232,29 * \left(\frac{B10}{B7 - B9}\right) + 23,174$	Meris	Baía de Taganrog e mar de Azov, na Rússia	Cal.: 18. Val.: 8	Cal.: 0,63 - 65,51. Val.: 18,37 - 47,86	Cal.: R ² de 0,95. Val.: RMSE de 5,02 µg.L ⁻¹	Moses <i>et al.</i> (2009)
	$315,5 * X^2 + 215,95 * X + 25,66$ $X = \left(\frac{B10}{B7 - B9}\right)$	Meris	Lagos Fremont, Nebraska EUA	Cal.: 89. Val.: 63	Cal.: 0 - 100. Val.: 0 - 100. Val.: 0 - 25	Cal.: R ² de 0,95. Val.: MAE de 2,5 µg.L ⁻¹ ; RMSE de 3,3 µg.L ⁻¹ ; e NMAE de 18,0% Cal.: R ² de 0,95. MAE de 1,9 µg.L ⁻¹ ; RMSE de 2,1 µg.L ⁻¹ ; e NMAE de 21,5%	Gurlin <i>et al.</i> (2011)
	$\left[113,36 * \left(\frac{B10}{B7 - B9}\right) + 16,45\right]^{1,124}$	Meris	Lagos Fremont, Nebraska EUA	Cal.: 89. Val.: 63	Cal.: 0 - 100. Val.: 0 - 100. Val.: 0 - 25	Val.: MAE de 3,4 µg.L ⁻¹ ; RMSE de 5,8 µg.L ⁻¹ ; e NMAE de 15,6% Val.: MAE de 1,4 µg.L ⁻¹ ; RMSE de 1,6 µg.L ⁻¹ ; e NMAE de 15,2%	Gurlin <i>et al.</i> (2011)
	$(23,09 \pm 0,98) + (117,42 \pm 2,49) * \left(\frac{B10}{B7 - B9}\right)$	Meris	Lagos e reservatórios em Nebraska, Iowa e Minnetonka (Minnesota)	Cal. e Val.: 253	Cal. e Val.: 1,2 - 236	Cal. e Val.: R ² de 0,96; NRMS de 32,1%; MNB: 7,25%; e RMSE de 7,8 µg.L ⁻¹	Gitelson <i>et al.</i> (2008)
	$105,979 * \left(\frac{B11}{B7 - B9}\right) + 38,537$	Meris	Lago Harsha em Ohio - EUA	9	-	R de 0,91; e R ² de 0,83	Gitelson <i>et al.</i> (2003). Adaptado por Beck <i>et al.</i> (2016)

Modelo	Equação	Satélite	Local de aplicação	Nº Amostras	Cla-a (µg.L ⁻¹)	Desempenho	Fonte
	$279,95 * \left(\frac{B6}{B4 - B5} \right) + 38,06$	S2	Reservatórios do Ceará - Brasil	Cal.: 171. Val.: 71	Cal.: 0,2 - 90. Val.: 1 - 100	Cal.: R ² de 0,80; e RMSE de 28%. Val.: R ² de 0,77	Aranha <i>et al.</i> (2022)
	$466683 * X^2 - 39497 * X + 835,87$ $X = B3 + (B12 - B11)$	S2	Barragem Chebara - Quênia	Cal.: 15	Cal.: 6,24 - 113,73	Val.: R ² de 0,69; MAE de 0,16 µg.L ⁻¹ ; NMAE de 8,72%; e RMSE de 3,04 µg.L ⁻¹	Ouma <i>et al.</i> (2020)
	$107,069 * \left(\frac{B7}{B5 - B6} \right) + 55,455$	WV 2	Lago Harsha em Ohio - EUA	29	-	R de 0,86; e R ² de 0,74	Gitelson <i>et al.</i> (2008) adaptado por Beck <i>et al.</i> (2016)
4BDA	$44,7869 - 0,2908 * B1 - 0,6905 * B2 + 0,1019 * B3 + 0,4843 * B4$	L7	Barragem de Ömerli, Istambul - 6 Turquia		0,75 - 2,72	Multiple R de 0,96; R ² de 0,92; Adjusted R ² de 0,59; e SE de 0,49	Alparslan <i>et al.</i> (2007)
LMR	$4,483 + 0,022 * B1 + 0,031 * B2 - 0,041 * B3 - 0,13 * B4 + 0,108 * B5 - 0,235 * B7$	L7	Reservatório Feitsui - Taiwan	24	0,48 - 4,02	R de 0,82; SSE de 3,31; e RMSE de 0,37	Chen <i>et al.</i> (2008)
	$e^{17,239 - 2,593 * \ln(B1) + 0,111 * \ln(B2) + 0,191 * \ln(B3) - 0,961 * \ln(B4) + 0,347 * \ln(B5) - 1,473 * \ln(B7)}$	L7	Reservatório Feitsui - Taiwan	24	0,48 - 4,02	R de 0,77; SSE de 4,74; e RMSE de 0,44	Chen <i>et al.</i> (2008)
GEGA	$\ln \left[e^{a * \left(\frac{b}{e^{B7/B1}} \right) + c - B4} \right] + \ln \left(\frac{B1}{d} \right) * \left[e - \left(\frac{B5 * B7}{f} \right) \right]$ a = 15,765706; b = 60,304886; c = 31,6022906; d = 95,110605; e = 9,884309; f = 26,271711	L7	Reservatório Feitsui - Taiwan	24	0,48 - 4,02	R de 0,89; SSE de 2,17; e RMSE de 0,30	Chen <i>et al.</i> (2008)
SABI	$\frac{(B2 - B1)}{(B3 + B4)}$	Modis	Golfo do México	Cal.: 606	-	Cal.: SE de 0,14	Alawadi (2010)
NDCI	$142,507 * \left(\frac{B6 - B5}{B6 + B5} \right) + 56,04$	WV 2 e 3	Lago Harsha em Ohio - EUA	29	-	R de 0,85; e R ² de 0,72	Mishra e Mishra (2012) adaptado por Beck <i>et al.</i> (2016)

Modelo	Equação	Satélite	Local de aplicação	Nº Amostras	Cla-a (µg.L ⁻¹)	Desempenho	Fonte
	$179,18 * \left(\frac{B5 - B4}{B5 + B4} \right) + 10,82$	S2	Lago Harsha em Ohio - EUA	Cal.: 28. Val.: 28	Cal. e Val.: 7,84 - 60,95	Cal.: R ² de 0,71. Val.: R de 0,83; e RMSE de 4,70 µg.L ⁻¹	Mishra e Mishra (2012) adaptado por Xu <i>et al.</i> (2018)
	$13,55 + 87,99 * X + 212,6 * X^2$ $X = \left(\frac{B9 - B7}{B9 + B7} \right)$	Meris	Baía de Chesapeake, Baía de Delaware, Baía de Mobile e a região do delta do rio Mississippi no norte do Golfo do México	Cal.: 35. Val.: 14	Cal.: 0,9 - 16,06. Val.: 4,21 - 28,18	Cal.: R ² de 0,72; Adj. R ² de 0,70; e SE de 2,15 µg.L ⁻¹ . Val.: R ² de 0,94; e RMSE de 1,43 µg.L ⁻¹	Mishra e Mishra (2012)
	$18,44 + 149,2 * X + 374,9 * X^2$ $X = \left(\frac{B9 - B7}{B9 + B7} \right)$	Meris	Sistemas aquáticos continentais e costeiros globais	-	-	Val.: R de 0,79; RMSE de 0,21 µg.L ⁻¹ ; MAE de 0,19 µg.L ⁻¹ ; RPD de 62,66; e BIAS de 0,02 µg.L ⁻¹	Mishra e Mishra (2012) adaptado por Neil <i>et al.</i> (2020)
OC2V4	$10^{-5020+29000*X-61000*X^2+57490*X^3-20260*X^4}$ $X = \log \left(\frac{B3}{B5} \right)$	Meris	Sistemas aquáticos continentais e costeiros globais	-	-	Val.: R de 0,60; RMSE de 0,59 µg.L ⁻¹ ; MAE de 0,58 µg.L ⁻¹ ; RPD de 72,72; e BIAS de 0,44 µg.L ⁻¹	O'Reilly <i>et al.</i> (2000), adaptado por Neil <i>et al.</i> (2020)
OC2V4	$10^{0,2975 - 21,502 * X - 215,53 * X^2 - 784,5 * X^3 - 859,7 * X^4}$ $X = \log \left(\frac{B2}{B3} \right)$	S2	Rio Kaidu e lagoas no Pantanal de Bayanbulak - Xinjiang	26 10	2,53 - 4,5 4,5 - 8,72	R ² de 0,85; RMSE de 0,23 µg.L ⁻¹ ; MAE de 0,18 µg.L ⁻¹ ; e MRE de 5,83% R ² de 0,13; RMSE de 2,28 µg.L ⁻¹ ; MAE de 1,64; e MRE de 24,03%	O'Reilly <i>et al.</i> (1998), adaptado por Ma <i>et al.</i> (2022)
OC3V4	$10^{0,0536 + 7,308 * X + 116,2 * X^2 + 412,4 * X^3 + 463,5 * X^4}$ $X = \log \left(\frac{B3}{B5} \right)$	Meris	Sistemas aquáticos continentais e costeiros globais	-	-	Val.: R de 0,72; RMSE de 0,20 µg.L ⁻¹ ; MAE de 0,21 µg.L ⁻¹ ; RPD de 61,18; e BIAS de -0,001 µg.L ⁻¹	O'Reilly <i>et al.</i> (2000), adaptado por Neil <i>et al.</i> (2020)
OC4V4	$10^{-0,599 - 50,54 * X - 578,38 * X^2 - 2525,7 * X^3 - 376,2 * X^4}$ $X = \log \left(\frac{B2}{B3} \right)$	S2	-	-	-	-	O'Reilly <i>et al.</i> (1998), adaptado por Ma <i>et al.</i> (2022)

Modelo	Equação	Satélite	Local de aplicação	Nº Amostras	Cla-a (µg.L ⁻¹)	Desempenho	Fonte
FLH	$B8 - B9 - \left(\frac{709 - 681,25}{709 - 665} \right) * (B7 - B9)$	Meris	Regiões oceânicas e tanques de cultura	-	-	R ² de 0,87	Zhao <i>et al.</i> (2010)
	$B14 - B15 - \left(\frac{748 - 678}{748 - 667} \right) * (B13 - B15)$	Modis	Mar da China Oriental	Val.: 17	-	Val.: R ² de 0,63; RMSD de 0,39 sr ⁻¹ ; APD de 35,10%; e RPD de - 35,02%	Zhao <i>et al.</i> (2022)
	$Rrs(685) - Rrs(745) - \left(\frac{745 - 685}{745 - 660} \right) * [Rrs(660) - Rrs(745)]$ Rrs(660) = 1,0322 * B1 + 0,0003 Rrs(685) = 0,8938 * B14 + 0,00025 Rrs(745) = 1,0123 * B15 + 0,00003	Modis	Mar da China Oriental	Val.: 17	-	Val.: R ² de 0,74; RMSD de 0,35 sr ⁻¹ ; APD de 28,85%; e RPD de - 27,75%	Zhao <i>et al.</i> (2022)
	$Rrs(685) - B5 - \left(\frac{685 - 660}{745 - 660} \right) * (B7 - B5)$ Rrs(685) = 0,9215 * B6 + 0,00034	Goci	Mar da China Oriental	Val.: 52	< 5	Val.: R ² de 0,67; RMSD de 0,16 sr ⁻¹ ; APD de 41,92%; e RPD de 19,09%	Zhao <i>et al.</i> (2022)
	$B6 - B5 - \left(\frac{680 - 660}{745 - 660} \right) * (B7 - B5)$	Goci	Mar da China Oriental	Val.: 52	< 5	Val.: R ² de 0,61; RMSD de 0,32 sr ⁻¹ ; APD de 105,72%; e RPD de - 35,02%	Zhao <i>et al.</i> (2022)
	$B12 - B14 - \left(\frac{710 - 680}{710 - 667} \right) * (B11 - B14)$	Gli	Regiões oceânicas e tanques de cultura	-	-	R ² de 0,90	Zhao <i>et al.</i> (2010)
	$-264,74 * [B3 - B4 - \left(\frac{559,5 - 664,75}{664,75 - 834,05} \right) * (B4 - B8)] + 2,32$	S2	Bacia do rio Godavari - Índia	-	< 20	R ² de 0,91; e RMSE de 1,6 µg.L ⁻¹	Satish <i>et al.</i> (2023)

Legenda: BDA - Band Algorithm; LMR - Linear Multi-regression; GECA - Genetic Algorithm; FLH - Fluorescence Line Height; NDCI - Normalized Difference Chlorophyll Index; e SABI - Surface Algal Bloom Index; S2 - Sentinel 2; L5 - Landsat 5; L7 - Landsat 7; L8 - Landsat 8; WV - WorldView; Cal - Calibração; Val - Validação; R - Coeficiente de correlação; R² - Coeficiente de correlação ao quadrado; MAE - Mean Absolute Error; NMAE - Normalized Mean Absolute Error; RMSE - Root Mean Squared Error; NSE - Nash-Sutcliffe Efficiency; PBIAS - Percent Bias; SE - Standard Error; SSE - Sum of Square Errors; RPD - Relative Percentage Deviation; NRMS - Normalized Root Mean Square; MNB - Mean Normalized Bias; APD - Absolute Percentage Deviation; RMSD - Root Mean Square Deviation; RSR - Relative Strength Ratio; e MRE - Mean Relative Error.

APÊNDICE B

Tabela B.1. Modelos espectrais que apresentaram as maiores correlações entre os dados de Cla-a observados e os estimados, para cada um dos reservatórios estudados. As cores estão relacionadas a magnitude da correlação, ou seja, quanto mais intensa a cor maior é a correlação.

Reservatório	Sentinel 2 com correção Sen2cor		Imagens com correção SIAC Dados entre 2019 e 2022		Imagens com correção SIAC Dados entre 2015 e 2022	
	Maior correlação	Modelo	Maior correlação	Modelo	Maior correlação	Modelo
Acarape do Meio	0,21	2BDA-2	0,20	3BDA-4; 3BDA-5	0,10	FLH
Acaraú Mirim	0,47	OC2V4	0,18	3BDA-1	0,13	3BDA-5
Adauto Bezerra	- -		- -		0,72	3BDA-2
Amanary	0,67	2BDA-7	0,61	2BDA-6	0,41	2BDA-1; 2BDA-5; 2BDA-6
Angicos	- -		- -		0,32	OC4V4
Aracoiaba	0,39	3BDA-5	0,52	SABI	0,36	FLH
Araras	0,58	2BDA-6	0,32	3BDA-1	0,23	2BDA-1; 2BDA-5; 2BDA-6
Arneiroz II	0,60	FLH	0,93	2BDA-9	0,63	2BDA-9
Arrebita	0,48	2BDA-7	0,59	2BDA-8	0,11	2BDA-9
Atalho	0,56	OC4V4	0,25	FLH	0,43	3BDA-5
Ayres de Sousa	0,17	OC2V4	0,25	3BDA-5	0,20	3BDA-5
Banabuiú	0,38	3BDA-5	0,25	OC2V4	0,18	2BDA-1; 2BDA-5; 2BDA-6
Barra Velha	0,58	SABI	0,77	2BDA-1	0,88	FLH
Barragem do Batalhão	- -		- -		0,60	3BDA-3
Batente	0,37	3BDA-1	0,54	3BDA-1; 3BDA-3	0,47	3BDA-3
Benguê	0,73	1BDA	0,37	2BDA-9	0,47	3BDA-3
Bodocongó	0,53	2BDA-7	0,26	3BDA-5; SABI	0,26	3BDA-5; SABI
Bonito	0,45	3BDA-4	0,75	3BDA-2	0,47	3BDA-5
Broco	- -		- -		0,13	2BDA-9
Cachoeiras	- -		- -		0,29	3BDA-5FLH
Caldeirões	0,66	1BDA	0,42	FLH	0,25	FLH

Reservatório	Sentinel 2 com correção Sen2cor		Imagens com correção SIAC Dados entre 2019 e 2022		Imagens com correção SIAC Dados entre 2015 e 2022	
	Maior correlação	Modelo	Maior correlação	Modelo	Maior correlação	Modelo
Camalaú	0,54	2BDA-8	0,56	2BDA-1; 2BDA-5; 2BDA-6	0,56	2BDA-1; 2BDA-5; 2BDA-6
Canafístula	0,48	2BDA-6	0,49	3BDA-1	0,35	3BDA-5
Canoas	-	-	-	-	0,14	4BDA
Capitão Mor	-	-	-	-	0,16	3BDA-5
Carão	0,41	3BDA-5	0,59	3BDA-4	0,59	3BDA-4
Carmina	0,28	2BDA-4	0,66	3BDA-3	0,66	3BDA-3
Carnaubal	0,65	FLH	0,89	OC4V4	0,86	3BDA-5
Castanhão	0,57	2BDA-1; 2BDA-5; 2BDA-6	0,21	3BDA-4	0,08	3BDA-1
Castro	0,83	2BDA-5; 2BDA-6; 3BDA-1	0,29	FLH	0,47	4BDA
Cauhipe	0,66	2BDA-6	0,62	2BDA-6	0,43	NDCI
Caxitóre	0,67	SABI	0,39	3BDA-5	0,19	3BDA-4
Cedro	0,51	2BDA-9	0,34	2BDA-9	0,50	4BDA
Cipoada	0,54	NDCI	0,79	2BDA-6	0,31	3BDA-3
Colina	-	-	-	-	0,11	3BDA-5
Cordeiro	0,58	FLH	0,43	SABI	0,43	SABI
Coremas	0,79	3BDA-4	0,49	1BDA	0,49	1BDA
Cupim	0,41	SABI	0,60	3BDA-3	0,48	3BDA-3
Curral Velho	0,50	FLH	0,54	3BDA-4	0,52	3BDA-3
Desterro	0,69	FLH	0,47	3BDA-3	0,31	3BDA-3
Diamante	0,24	OC4V4	0,08	2BDA-6	0,28	3BDA-1
Diamantino II	0,21	OC2V4	0,27	2BDA-3; 2BDA-4	0,16	2BDA-7
Do Coronel	-	-	-	-	0,07	2BDA-8; 3BDA-4

Reservatório	Sentinel 2 com correção Sen2cor		Imagens com correção SIAC Dados entre 2019 e 2022		Imagens com correção SIAC Dados entre 2015 e 2022	
	Maior correlação	Modelo	Maior correlação	Modelo	Maior correlação	Modelo
Edson Queiroz	0,41	2BDA-4	0,27	FLH	0,12	3BDA-3
Ema	0,54	4BDA	0,50	NDCI; 2BDA-1; 2BDA-5; 2BDA-6	0,38	SABI
Eng. Arcoverde	0,38	3BDA-4	0,44	3BDA-4	0,44	3BDA-4
Eng. Ávidos	0,32	2BDA-3; 2BDA-4	0,54	1BDA	0,54	1BDA
Escondido	0,81	FLH	0,44	2BDA-3; 2BDA-4	0,37	FLH
Escuridão	0,29	3BDA-5	0,08	2BDA-2	0,11	3BDA-2
Facundo	0,47	3BDA-2	0,69	2BDA-7; 2BDA-9	0,16	OC2V4
Faé	0,80	SABI	0,66	FLH	0,66	FLH
Farias de Sousa	0,44	SABI; OC4V4	0,70	SABI	0,53	SABI
Farinha	0,51	NDCI; 2BDA-1; 2BDA-5; 2BDA-6	0,43	2BDA-5; 2BDA-6	0,43	2BDA-5; 2BDA-6
Figueiredo	0,47	NDCI; 2BDA-1; 2BDA-5; 2BDA-6	0,73	2BDA-8	0,19	2BDA-8
Flor do Campo	0,47	2BDA-9	0,68	3BDA-4	0,42	3BDA-3
Fogareiro	0,42	2BDA-6	0,36	2BDA-2	0,21	3BDA-4
Forquilha	0,58	2BDA-7; 2BDA-9	0,48	NDCI; 2BDA-1; 2BDA-5; 2BDA-6	0,32	FLH
Frios	0,14	OC4V4	0,35	2BDA-10	0,24	1BDA
Gameleira	0,84	3BDA-4	0,66	2BDA-6	0,19	2BDA-6
Gangorra	- -		- -		0,22	3BDA-3
General Sampaio	0,69	3BDA-2	0,26	4BDA	0,25	3BDA-5
Gerardo Atimbone	0,30	3BDA-5	0,26	OC2V4	0,41	3BDA-1
Germinal	0,59	SABI	0,49	OC2V4	0,34	3BDA-4
Itapajé	0,22	2BDA-10	0,35	1BDA	0,15	4BDA
Itapebussu	0,73	2BDA-10	0,60	3BDA-5	0,43	NDCI; OC4V4

Reservatório	Sentinel 2 com correção Sen2cor		Imagens com correção SIAC Dados entre 2019 e 2022		Imagens com correção SIAC Dados entre 2015 e 2022	
	Maior correlação	Modelo	Maior correlação	Modelo	Maior correlação	Modelo
Itaúna	0,49	SABI	0,42	3BDA-1	0,22	3BDA-5
Jaburu I	0,12	2BDA-6	0,52	3BDA-5	0,24	2BDA-8
Jaburu II	0,40	3BDA-5	0,67	3BDA-4	0,14	2BDA-7
Jatobá	0,43	2BDA-8	0,28	2BDA-7; 2BDA-9	0,29	3BDA-5
Jatobá I	0,69	3BDA-5	0,57	OC2V4	0,57	OC2V4
Jatobá II	0,13	4BDA	0,20	3BDA-1	0,04	1BDA
Jenipapeiro	0,47	2BDA-9	0,50	2BDA-2	0,15	2BDA-10
Jenipapeiro Buiú	0,64	OC4V4	0,62	3BDA-1	0,57	3BDA-1; 3BDA-5
Jenipapeiro II	0,40	2BDA-7; 2BDA-9	0,21	3BDA-1	0,26	OC4V4
Jenipapo	0,52	SABI	0,20	FLH	0,22	3BDA-3
Jerimum	0,72	FLH	0,25	3BDA-1	0,29	3BDA-1
João Luís	- -		- -		0,58	2BDA-7
Joaquim Távora	0,41	3BDA-5	0,24	2BDA-7; 2BDA-9	0,35	NDCI
Junco	0,64	1BDA	0,43	2BDA-6	0,10	NDCI; 2BDA-1; 2BDA-5; 2BDA-6
Lagoa do Arroz	0,65	3BDA-5	0,41	2BDA-2; 2BDA-3; 2BDA-4	0,41	2BDA-2; 2BDA-3; 2BDA-4
Lima Campos	0,28	3BDA-5	0,30	OC2V4	0,17	OC4V4
Macacos	0,38	4BDA	0,51	OC4V4	0,22	3BDA-3
Mãe d'Água	0,35	2BDA-8	0,49	OC4V4	0,49	OC4V4
Malcozinhado	0,31	2BDA-6	0,29	3BDA-1	0,49	3BDA-3
Mamoeiro	- -		- -		0,16	2BDA-2; 2BDA-3; 2BDA-4; OC4V4
Manoel Balbino	- -		- -		0,04	2BDA-2; 2BDA-3; 2BDA-4; 3BDA-4; OC4V4
Maranguapinho	0,25	3BDA-4	0,37	OC2V4	0,18	3BDA-2; 3BDA-5

Reservatório	Sentinel 2 com correção Sen2cor		Imagens com correção SIAC Dados entre 2019 e 2022		Imagens com correção SIAC Dados entre 2015 e 2022	
	Maior correlação	Modelo	Maior correlação	Modelo	Maior correlação	Modelo
Martinópolis	0,69	1BDA	0,49	3BDA-5	0,15	3BDA-5
Missi	0,38	4BDA	0,63	OC2V4	0,26	OC2V4
Monsenhor Tabosa	-	-	-	-	0,04	2BDA-9
Monte Belo	-	-	-	-	0,51	OC2V4
Mucutu	0,57	3BDA-1	0,80	2BDA-6	0,80	2BDA-6
Mundaú	0,56	NDCI; 2BDA-1; 2BDA-5; 2BDA-6	0,74	2BDA-10	0,67	3BDA-3
Muquém	0,64	OC4V4	0,56	SABI	0,20	OC2V4
Namorado	0,12	4BDA	0,45	4BDA	0,45	4BDA
Nova Floresta	0,37	NDCI	0,48	3BDA-1	0,78	3BDA-3
Olho d'Água	0,31	2BDA-4	0,41	2BDA-8	0,51	3BDA-3
Orós	0,40	4BDA	0,61	OC2V4	0,25	2BDA-3
Pacajus	0,33	3BDA-5	0,29	3BDA-3	0,24	3BDA-3
Pacoti	0,32	SABI	0,45	3BDA-4	0,22	2BDA-3; 2BDA-4
Parambu	0,78	2BDA-7; 2BDA-9	0,41	SABI	0,75	3BDA-3
Patos	0,72	2BDA-2; 3BDA-5	0,57	2BDA-1; 2BDA-5; 2BDA-6	0,43	3BDA-4
Patu	0,77	NDCI	0,63	2BDA-3	0,17	FLH
Pau Preto	-	-	-	-	0,16	3BDA-5
Pedras Brancas	0,42	2BDA-2	0,46	2BDA-10	0,18	3BDA-2
Penedo	0,80	OC4V4	0,33	FLH	0,25	3BDA-3
Pentecoste	0,76	2BDA-7; 2BDA-9	0,77	2BDA-8	0,13	2BDA-8
Pesqueiro	0,48	1BDA	0,71	3BDA-1	0,22	1BDA
Pilões	0,47	3BDA-1	0,30	1BDA	0,30	1BDA
Pirabibu	-	-	-	-	0,69	2BDA-10; 1BDA

Reservatório	Sentinel 2 com correção Sen2cor		Imagens com correção SIAC Dados entre 2019 e 2022		Imagens com correção SIAC Dados entre 2015 e 2022	
	Maior correlação	Modelo	Maior correlação	Modelo	Maior correlação	Modelo
Poço da Pedra	- -		- -		0,48	4BDA
Poço do Barro	0,49	2BDA-7	0,45	2BDA-7	0,49	3BDA-3
Poço Verde	0,51	FLH	0,53	FLH	0,30	OC2V4
Pompeu Sobrinho	0,56	1BDA	0,35	FLH	0,20	FLH
Prazeres	0,30	2BDA-2	0,27	2BDA-2	0,31	NDCI; 2BDA-1; 2BDA-5; 2BDA-6
Premuoca	0,39	FLH	0,09	3BDA-2	0,14	OC2V4
Quandú	0,68	NDCI; 2BDA-1; 2BDA-5	0,48	2BDA-1; 2BDA-5; 2BDA-6	0,47	3BDA-3
Quincoé	0,41	3BDA-4	0,34	SABI	0,29	FLH
Quixabinha	0,62	SABI	0,24	3BDA-5	0,15	FLH
Quixeramobim	0,41	3BDA-5	0,49	4BDA	0,36	4BDA
Realejo	0,85	4BDA	0,93	1BDA	0,45	3BDA-2
Riacho da Serra	0,15	3BDA-2	0,40	2BDA-2	0,18	1BDA
Riacho do Sangue	0,32	2BDA-6; FLH; OC4V4	0,72	3BDA-5	0,23	SABI
Rivaldo de Carvalho	- -		- -		0,16	NDCI
Rosário	0,50	2BDA-9; FLH	0,23	2BDA-9	0,09	1BDA
Saco	0,28	3BDA-3; 3BDA-4	0,53	3BDA-5	0,53	3BDA-5
Salão	- -		- -		0,69	2BDA-2; 2BDA-10
Santa Luzia	0,59	2BDA-7	0,61	2BDA-9	0,61	2BDA-9
Santa Maria	0,58	3BDA-2	0,66	3BDA-5	0,26	3BDA-5
Santa Maria de Aracatiçu	0,81	1BDA	0,39	OC2V4	0,71	3BDA-3
Santo Antônio	0,40	FLH	0,78	OC4V4	0,26	3BDA-5
Santo Antônio de Aracatiçu	0,51	2BDA-7	0,36	2BDA-5; 2BDA-6	0,09	2BDA-10

Reservatório	Sentinel 2 com correção Sen2cor		Imagens com correção SIAC Dados entre 2019 e 2022		Imagens com correção SIAC Dados entre 2015 e 2022	
	Maior correlação	Modelo	Maior correlação	Modelo	Maior correlação	Modelo
Santo Antônio de Russas	0,22	3BDA-1; 3BDA-4	0,12	3BDA-2SABI	-	-
São Domingos	0,38	OC4V4	0,31	NDCI	0,23	2BDA-9
São Domingos II	0,53	2BDA-10	0,25	2BDA-5; 2BDA-6	0,28	3BDA-5
São Gonçalo	0,35	2BDA-2; 2BDA-3; 2BDA-4; OC2V4	0,61	2BDA-5; 2BDA-6	0,61	2BDA-5; 2BDA-6
São José I	0,84	2BDA-2	0,68	3BDA-5	-	-
São José II	0,66	2BDA-3	0,54	3BDA-4	0,14	3BDA-3; 3BDA-5
São José III	0,54	FLH	0,44	4BDA	0,71	3BDA-5
São Mamede	0,47	OC2V4	0,41	3BDA-2	0,41	3BDA-2
São Mateus	0,78	OC4V4	0,75	3BDA-4	0,70	3BDA-4
São Paulo	0,61	4BDA	0,64	SABI	0,64	SABI
São Pedro Timbaúba	0,64	3BDA-1	0,55	2BDA-6	-	-
São Vicente	0,65	OC4V4	0,37	2BDA-9	0,19	SABI
Serafim Dias	0,60	3BDA-2	0,51	3BDA-4	0,51	3BDA-4
Sítios Novos	0,29	3BDA-1	0,26	2BDA-9	0,18	2BDA-6
Sobral	0,27	2BDA-6	0,36	NDCI; 2BDA-1	0,26	NDCI; 2BDA-1; 2BDA-5; 2BDA-6
Soledade	0,46	3BDA-2	0,39	3BDA-4	0,39	3BDA-4
Sousa	0,72	2BDA-1; 2BDA-5; 2BDA-6	0,59	3BDA-5	-	-
Sucesso	0,37	FLH	0,73	FLH	0,41	2BDA-6
Taquara	0,24	3BDA-4	0,24	4BDA	0,16	2BDA-2; OC4V4
Tatajuba	0,33	3BDA-5	0,44	2BDA-8	0,20	SABI
Tejuçuoca	0,39	3BDA-2	0,26	2BDA-9	0,34	2BDA-9
Thomás Osterne	-	-	-	-	0,10	NDCI; 2BDA-1; 2BDA-5; 2BDA-6

Reservatório	Sentinel 2 com correção Sen2cor		Imagens com correção SIAC Dados entre 2019 e 2022		Imagens com correção SIAC Dados entre 2015 e 2022	
	Maior correlação	Modelo	Maior correlação	Modelo	Maior correlação	Modelo
Tigre	0,68	3BDA-1	0,67	3BDA-5	0,20	FLH
Tijuquinha	0,37	SABI	0,45	3BDA-2	0,48	3BDA-3
Trapiá II	0,29	SABI	0,39	NDCI	0,10	2BDA-7; 2BDA-9; 3BDA-1
Trapiá III	0,28	NDCI; 2BDA-1; 2BDA-5; 2BDA-6	0,22	2BDA-9	0,21	2BDA-8
Trici	0,66	NDCI	0,25	3BDA-5	0,16	3BDA-3
Trussu	0,63	3BDA-4	0,52	OC2V4	0,33	3BDA-4
Tucunduba	0,49	2BDA-7	0,28	2BDA-4	0,20	3BDA-5
Ubalzinho	0,44	FLH	0,21	3BDA-5	0,47	3BDA-5
Umari	0,41	SABI	0,40	2BDA-7	0,26	3BDA-5
Valério	- -		- -		0,13	SABI
Várzea da Volta	0,18	OC2V4	0,57	2BDA-7	0,23	3BDA-3; 3BDA-5
Várzea do Boi	- -		- -		0,41	FLH
Vieirão	0,53	2BDA-2	0,73	FLH	0,93	3BDA-5
Muito fraca		7		5		46
Fraca		38		50		55
Moderada		57		52		42
Forte		34		33		16
Muito forte		8		4		4
Total de reservatórios com n ≥ 6		144		144		163

Tabela B.2 - Resultados das testagens da eficiência dos modelos espectrais utilizando imagens Sentinel 2 com correção atmosférica pelo algoritmo Sen2cor para o período de 2019 a 2022, considerando os agrupamentos de dados por reservatórios.

Modelo	Nº dados	Nº de reserv. com $n \geq 6$	Nº de reserv. com $n < 6$	Nº de reservatórios com correlação (R^2)					NRMSE (%)		NSE	
				Muito forte	Forte	Moderada	Fraca	Muito fraca	Mínimo	Máximo	Mínimo	Máximo
1BDA	1399	138	32	2	4	7	21	104	71,75	6,66E+5	-1,80E+8	-0,97
2BDA-1	1516	140	30	2	6	17	19	96	15,43	506,23	-128,24	0,69
2BDA-2	1516	143	27	1	1	9	31	101	41,05	1715,32	-1551,98	0,21
2BDA-3	1532	144	26	0	3	10	28	103	98,59	268,53	-25,53	-0,15
2BDA-4	1534	144	26	0	2	12	28	102	98,82	268,56	-25,55	-0,15
2BDA-5	1515	140	30	2	6	17	19	96	19,50	703,84	-257,11	0,49
2BDA-6	1512	140	30	2	7	15	26	90	22,30	797,14	-311,51	0,63
2BDA-7	1445	141	29	0	4	16	23	98	380,89	1,80E+5	-1,14E+7	-43,38
2BDA-8	1433	140	30	0	1	11	22	106	308,11	3,55E+5	-5,13E+7	-7,56
2BDA-9	1448	142	28	0	5	13	24	100	784,42	2,39E+5	-2,00E+7	-100,27
2BDA-10	1460	141	29	0	2	4	18	117	123,07	1604,19	-1154,85	-0,04
3BDA-1	1447	139	31	1	4	6	28	100	332,04	4,07E+5	-5,83E+7	-10,90
3BDA-2	1395	137	33	0	2	11	19	105	100,51	6,40E+5	-1,66E+8	-2,51
3BDA-3	154	3	167	0	0	0	2	1	3,46E+4	6,42E+4	-1,84E+6	-4,31E+5
3BDA-4	1412	141	29	1	2	5	35	98	2,39E+5	1,33E+9	-5,53E+14	-2,91E+6
3BDA-5	993	113	57	0	3	6	34	70	947,46	5,20E+4	-1,84E+6	-308,43
4BDA	1492	140	30	1	2	7	22	108	32,09	1287,49	-743,53	0,00
FLH	1447	142	28	1	4	14	31	92	83,09	526,12	-110,24	-0,11
NDCI	1531	140	30	2	5	19	21	93	15,66	520,25	-118,73	0,68
SABI	1561	144	26	1	2	15	21	105	-	-	-	-
OC2V4	1525	142	28	0	1	12	20	109	45,55	364,74	-233,31	0,27
OC4V4	1394	141	29	1	4	12	29	95	67,60	9,66E+55	-1,64E+109	0,22

Tabela B.3. Resultados das testagens da eficiência dos modelos espectrais utilizando imagens Sentinel 2 com correção atmosférica pelo algoritmo SIAC para o período de 2019 a 2022, considerando os agrupamentos de dados por reservatórios.

Modelo	Nº Dados	Nº de reser. com $n \geq 6$	Nº de reser. com $n < 6$	Nº de reservatórios com correlação (R^2)					NRMSE (%)		NSE	
				Muito forte	Forte	Moderada	Fraca	Muito fraca	Mínimo	Máximo	Mínimo	Máximo
1BDA	1433	138	32	1	0	8	12	117	290,49	2,09E+6	-2,01E+9	-10,67
2BDA-1	1529	142	28	0	5	16	19	102	31,85	288,81	-28,28	0,37
2BDA-2	1531	140	30	0	3	4	21	112	34,65	2074,73	-2310,69	0,25
2BDA-3	1580	139	31	0	3	4	20	112	95,18	268,22	-24,97	-0,15
2BDA-4	1580	139	31	0	3	4	20	112	95,66	268,23	-25,00	-0,15
2BDA-5	1528	141	29	0	4	15	20	102	29,17	518,47	-135,11	0,24
2BDA-6	1528	141	29	1	5	12	21	102	25,82	570,31	-157,48	0,31
2BDA-7	1445	141	29	1	2	8	23	107	301,86	1,21E+5	-1,49E+7	-59,49
2BDA-8	1426	137	33	0	3	5	19	110	249,41	5,77E+5	-1,54E+8	-5,44
2BDA-9	1443	140	30	1	3	5	28	103	642,83	1,58E+5	-2,54E+7	-117,90
2BDA-10	1520	139	31	0	2	3	19	115	103,57	1699,43	-1296,17	0,19
3BDA-1	1376	137	33	0	3	7	26	101	952,86	5,95E+5	-2,34E+8	-601,71
3BDA-2	1409	138	32	0	2	8	14	114	200,37	1,78E+6	-1,46E+9	-13,18
3BDA-3	785	64	106	0	2	4	11	47	1,63E+4	8,98E+5	-5,62E+8	-1,23E+4
3BDA-4	1387	141	29	0	3	14	14	110	7,97E+5	1,20E+9	-9,53E+14	-4,66E+7
3BDA-5	1005	116	54	1	6	12	16	81	1231,86	7,47E+4	-3,12E+6	-733,71
4BDA	1491	140	30	2	0	7	21	110	33,42	1287,46	-743,48	0,00
FLH	1464	141	29	0	3	6	26	106	73,69	309,47	-94,63	-0,09
NDCI	1535	142	28	0	5	16	19	102	38,71	277,91	-30,28	0,47
SABI	1564	141	29	0	4	9	23	105	-	-	-	-
OC2V4	1534	139	31	1	2	7	11	118	30,46	238,34	-15,20	0,21
OC4V4	1370	137	33	1	1	5	19	111	52,62	4,71E+29	-1,57E+55	-0,05

Tabela B.4. Resultados das testagens da eficiência dos modelos espectrais utilizando imagens Sentinel 2 com correção atmosférica pelo algoritmo SIAC para o período de 2015 a 2022, considerando os agrupamentos de dados por reservatórios.

Modelo	Nº Dados	Nº reser. com n ≥ 6	Nº reser. com n < 6	Nº de reservatórios com correlação (R²)						NRMSE (%)		NSE	
				Muito forte	Forte	Moderada	Fraca	Muito fraca		Mínimo	Máximo	Mínimo	Máximo
1BDA	2689	162	8	0	1	4	13	144		290,49	5,84E+6	-1,82E+9	-10,67
2BDA-1	2862	162	8	0	2	5	15	140		44,49	390,28	-26,49	0,37
2BDA-2	2837	163	7	0	1	2	9	151		44,40	1985,27	-1876,18	0,09
2BDA-3	2975	162	8	0	1	2	11	148		96,42	392,60	-10,13	-0,07
2BDA-4	2978	162	8	0	1	2	11	148		96,83	392,61	-10,13	-0,07
2BDA-5	2794	161	9	0	2	5	15	139		44,47	707,60	-112,89	0,24
2BDA-6	2788	161	9	1	1	6	14	139		40,92	766,13	-131,64	0,31
2BDA-7	2668	161	9	0	1	3	9	148		781,54	5,90E+5	-1,92E+7	-30,54
2BDA-8	2714	162	8	0	0	2	15	145		265,87	1,44E+6	-1,11E+8	-5,44
2BDA-9	2688	162	8	0	2	2	9	149		1427,52	6,54E+5	-2,36E+7	-117,90
2BDA-10	2873	163	7	0	2	2	10	149		83,09	4177,25	-1080,48	0,19
3BDA-1	2566	160	10	0	0	3	14	143		1374,82	1,26E+6	-2,34E+8	-101,79
3BDA-2	2664	162	8	0	2	4	11	145		428,71	5,21E+6	-1,45E+9	-16,64
3BDA-3	1487	131	39	0	6	12	15	98		3381,24	3,93E+6	-1,52E+10	-332,18
3BDA-4	2562	160	10	0	1	5	9	145		7,97E+5	1,20E+9	-9,53E+14	-4,13E+7
3BDA-5	1843	148	22	2	1	8	24	113		1239,43	1,50E+5	-1,07E+7	-14,66
4BDA	2788	160	10	0	1	6	12	141		30,79	1406,59	-716,75	0,00
FLH	2729	162	8	1	2	3	23	133		78,24	431,23	-24,39	-0,08
NDCI	2801	161	9	0	3	8	15	135		40,78	390,43	-30,28	0,47
SABI	2908	161	9	0	3	4	17	137		-	-	-	-
OC2V4	2857	158	12	0	1	3	9	145		52,22	391,56	-7,88	0,21
OC4V4	2487	157	13	0	1	2	10	144		77,59	3,03E+19	-1,12E+35	0,14

APÊNDICE C

Tabela C.1. Resultados das testagens da eficiência dos modelos espectrais utilizando imagens Sentinel 2 com correção atmosférica pelo algoritmo Sen2cor para o período de 2019 a 2022, considerando os agrupamentos de dados formados pelas concentrações de Clorofila-*a*. O I, II, III e IV, indicam os quartis. O intervalo de concentração de Cla-*a* de cada quartil é: I - 0,05 a 8,81 $\mu\text{g.L}^{-1}$; II - 8,81 a 18,65 $\mu\text{g.L}^{-1}$; III - 18,65 a 38,87 $\mu\text{g.L}^{-1}$; e IV - 38,87 a 2589,00 $\mu\text{g.L}^{-1}$. Os valores de R^2 em negrito simbolizam os dados com distribuição normal e cujas correlações foram verificadas por Pearson.

Modelo	Nº Dados				Correlação (R^2)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
1BDA	333	335	328	340	0,00	0,00	0,00	0,00	6,08E+4	1,52E+4	7541,04	4570,58	-1,83E+6	-4,92E+5	-1,29E+5	-853,70
2BDA-1	387	375	376	375	0,00	0,00	0,03	0,04	306,18	71,28	33,89	173,88	-41,02	-9,64	-1,65	-0,19
2BDA-2	381	369	375	379	0,00	0,00	0,00	0,01	1163,32	383,54	142,04	159,60	-610,29	-314,92	-45,26	-0,06
2BDA-3	399	395	400	396	0,01	0,00	0,00	0,02	105,98	100,32	101,13	182,27	-4,16	-19,93	-22,26	-0,42
2BDA-4	399	395	401	396	0,01	0,00	0,00	0,02	106,21	100,42	101,18	182,27	-4,18	-19,97	-22,28	-0,42
2BDA-5	387	375	376	375	0,00	0,00	0,03	0,04	480,70	130,70	31,23	171,02	-104,09	-34,77	-1,25	-0,15
2BDA-6	388	372	374	372	0,00	0,00	0,04	0,04	535,45	152,77	41,55	169,91	-129,87	-47,96	-2,97	-0,13
2BDA-7	356	350	352	352	0,00	0,00	0,00	0,00	4,72E+4	1,86E+4	7844,04	2945,04	-1,06E+6	-7,33E+5	-1,37E+5	-846,39
2BDA-8	324	329	319	327	0,00	0,00	0,00	0,01	1,62E+4	5549,79	2516,70	1406,49	-1,29E+5	-6,68E+4	-1,43E+4	-305,62
2BDA-9	361	348	352	353	0,00	0,00	0,00	0,00	7,38E+4	2,69E+4	1,21E+4	4213,29	-2,58E+6	-1,53E+6	-3,23E+5	-1711,01
2BDA-10	365	362	370	354	0,00	0,01	0,00	0,00	978,98	447,64	261,78	207,40	-455,52	-426,78	-153,52	-0,80
3BDA-1	305	331	366	389	0,00	0,00	0,02	0,02	5,82E+4	2,26E+4	8454,64	1648,68	-1,48E+6	-1,01E+6	-1,67E+5	-115,31
3BDA-2	335	334	329	333	0,00	0,01	0,00	0,00	4,37E+4	8316,21	4400,07	2381,65	-9,41E+5	-1,46E+5	-4,38E+4	-231,75
3BDA-3	78	45	14	3	0,00	0,09	0,13	-	1,16E+5	6,36E+4	3,43E+4	-	-6,59E+6	-9,34E+6	-1,93E+6	-
3BDA-4	342	343	353	381	0,00	0,01	0,01	0,01	5,06E+7	1,75E+7	5,76E+6	1,42E+6	-1,13E+12	-6,09E+11	-7,71E+10	-8,60E+7
3BDA-5	255	246	247	237	0,01	0,00	0,01	0,00	4,37E+4	1,73E+4	8203,48	1951,00	-8,43E+5	-6,16E+5	-1,56E+5	-130,42
4BDA	378	373	375	360	0,00	0,00	0,00	0,00	800,02	244,27	68,38	164,15	-297,76	-126,12	-9,59	-0,13
FLH	344	352	351	366	0,01	0,00	0,03	0,08	125,11	101,75	103,70	187,15	-6,37	-20,83	-23,13	-0,43
NDCI	387	381	376	383	0,00	0,00	0,03	0,05	310,42	78,20	34,82	171,54	-42,34	-11,75	-1,80	-0,19
SABI	402	402	403	396	0,00	0,01	0,01	0,03	-	-	-	-	-	-	-	-
OC2V4	403	395	389	386	0,00	0,00	0,00	0,01	85,91	67,30	82,60	180,11	-2,37	-8,44	-14,54	-0,37

Modelo	N° Dados				Correlação (R²)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
OC4V4	345	338	321	314	0,00	0,00	0,00	0,00	111,70	80,73	86,15	189,95	-4,57	-12,60	-15,85	-0,30

Tabela C.2. Resultados das testagens da eficiência dos modelos espectrais utilizando imagens Sentinel 2 com correção atmosférica pelo algoritmo SIAC para o período de 2019 a 2022, considerando os agrupamentos de dados formados pelas concentrações de Clorofila-*a*. O I, II, III e IV, indicam os quartis. O intervalo de concentração de Cla-*a* de cada quartil é: I - 0,05 a 8,81 µg.L⁻¹; II - 8,81 a 18,65 µg.L⁻¹; III - 18,65 a 38,87 µg.L⁻¹; e IV - 38,87 a 2589,00 µg.L⁻¹. Os valores de R² em negrito simbolizam os dados com distribuição normal e cujas correlações foram verificadas por Pearson.

Modelo	N° Dados				Correlação (R²)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
1BDA	349	349	357	335	0,00	0,00	0,00	0,01	5,58E+5	1,77E+5	1,28E+5	2,34E+4	-1,39E+8	-6,54E+7	-3,69E+7	-2,19E+4
2BDA-1	394	392	371	369	0,00	0,00	0,01	0,05	153,73	42,62	60,63	181,47	-9,60	-2,78	-7,46	-0,26
2BDA-2	378	380	377	374	0,00	0,00	0,00	0,01	1233,13	411,36	146,67	160,22	-690,73	-360,46	-47,47	-0,05
2BDA-3	406	403	404	397	0,00	0,00	0,00	0,01	103,34	99,23	100,80	181,96	-3,87	-19,47	-22,14	-0,42
2BDA-4	406	403	404	397	0,00	0,00	0,00	0,02	103,65	99,35	100,85	181,97	-3,90	-19,52	-22,16	-0,42
2BDA-5	396	392	372	367	0,00	0,00	0,01	0,05	354,62	76,24	27,34	177,62	-55,61	-11,10	-0,72	-0,20
2BDA-6	398	393	372	367	0,00	0,00	0,01	0,05	384,94	87,77	24,91	176,61	-65,87	-14,99	-0,43	-0,19
2BDA-7	360	360	359	357	0,00	0,00	0,00	0,00	7,21E+4	3,31E+4	1,48E+4	4340,01	-2,34E+6	-2,28E+6	-4,89E+5	-757,78
2BDA-8	353	353	365	332	0,00	0,00	0,00	0,00	1,79E+5	5,95E+4	4,52E+4	6913,11	-1,44E+7	-7,37E+6	-4,64E+6	-1926,32
2BDA-9	354	363	362	350	0,00	0,00	0,00	0,00	8,82E+4	4,40E+4	2,02E+4	5342,23	-3,43E+6	-4,06E+6	-9,13E+5	-1144,73
2BDA-10	385	391	396	382	0,00	0,00	0,00	0,00	1212,05	475,17	256,81	195,10	-677,43	-469,57	-148,72	-0,64
3BDA-1	350	340	357	324	0,00	0,00	0,00	0,00	2,07E+5	8,10E+4	4,52E+4	8111,01	-1,98E+7	-1,38E+7	-4,69E+6	-2798,63
3BDA-2	344	339	349	324	0,00	0,00	0,00	0,01	3,61E+5	1,02E+5	8,23E+4	1,19E+4	-5,85E+7	-2,13E+7	-1,55E+7	-5511,79
3BDA-3	238	219	201	114	0,00	0,00	0,00	0,03	2,27E+5	8,18E+4	5,63E+4	2,55E+4	-2,41E+7	-1,50E+7	-7,66E+6	-3,06E+4
3BDA-4	340	336	345	328	0,00	0,00	0,00	0,05	9,98E+7	4,23E+7	2,12E+7	3,84E+6	-4,59E+12	-3,72E+12	-1,01E+12	-6,33E+8
3BDA-5	247	242	244	236	0,01	0,00	0,00	0,00	5,94E+4	2,25E+4	1,03E+4	2463,61	-1,50E+6	-1,02E+6	-2,55E+5	-204,54
4BDA	363	365	384	346	0,00	0,00	0,00	0,00	808,73	243,15	67,40	167,42	-294,13	-122,01	-9,31	-0,14
FLH	349	356	364	351	0,00	0,01	0,00	0,01	141,71	101,11	101,70	186,51	-7,84	-20,29	-22,05	-0,41
NDCI	391	391	374	376	0,00	0,00	0,01	0,06	146,56	57,34	66,56	180,09	-8,69	-5,84	-9,12	-0,27

Modelo	N° Dados				Correlação (R ²)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
SABI	401	396	400	390	0,00	0,01	0,00	0,01	-	-	-	-	-	-	-	-
OC2V4	404	395	398	384	0,00	0,00	0,00	0,00	83,87	50,08	76,87	180,47	-2,22	-4,30	-12,48	-0,36
OC4V4	335	327	321	312	0,00	0,00	0,01	0,00	141,97	81,06	80,72	143,93	-7,89	-12,51	-14,12	-0,57

Tabela C.3. Resultados das testagens da eficiência dos modelos espectrais utilizando imagens Sentinel 2 com correção atmosférica pelo algoritmo SIAC para o período de 2015 a 2022, considerando os agrupamentos de dados formados pelas concentrações de Clorofila-*a*. O I, II, III e IV, indicam os quartis. O intervalo de concentração de Cla-*a* de cada quartil é: I - 0,05 a 8,99 µg.L⁻¹; II - 8,99 a 21,73 µg.L⁻¹; III - 21,73 a 48,20 µg.L⁻¹; e IV - 48,20 a 2617,67 µg.L⁻¹. Os valores de R² em negrito simbolizam os dados com distribuição normal e cujas correlações foram verificadas por Pearson.

Modelo	N° Dados				Correlação (R ²)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
1BDA	681	701	708	701	0,01	0,00	0,00	0,03	9,56E+5	3,01E+5	1,90E+5	3,96E+4	-4,01E+8	-1,46E+8	-6,96E+7	-8,44E+4
2BDA-1	729	728	713	707	0,00	0,00	0,01	0,00	145,69	42,30	67,34	165,97	-8,02	-1,96	-7,73	-0,39
2BDA-2	727	727	721	727	0,00	0,00	0,00	0,00	1205,15	357,51	104,76	145,55	-615,76	-209,83	-20,14	-0,15
2BDA-3	772	771	771	772	0,00	0,00	0,00	0,00	104,54	100,38	101,42	166,64	-3,60	-15,36	-18,74	-0,56
2BDA-4	772	771	771	772	0,00	0,00	0,00	0,00	104,83	100,48	101,46	166,65	-3,63	-15,39	-18,76	-0,56
2BDA-5	731	729	711	704	0,00	0,00	0,01	0,00	345,68	61,40	37,52	162,01	-49,73	-5,22	-1,71	-0,33
2BDA-6	733	729	711	697	0,00	0,00	0,01	0,00	375,45	71,50	33,91	161,83	-58,94	-7,44	-1,22	-0,31
2BDA-7	679	680	672	691	0,00	0,00	0,00	0,02	9,73E+4	2,90E+4	1,49E+4	4,02E+3	-4,07E+6	-1,34E+6	-4,18E+5	-844,22
2BDA-8	698	701	733	725	0,00	0,00	0,00	0,00	3,08E+5	9,13E+4	6,34E+4	1,32E+4	-4,12E+7	-1,35E+7	-7,72E+6	-9496,11
2BDA-9	681	689	684	693	0,00	0,00	0,00	0,01	1,21E+5	3,94E+4	2,01E+4	5038,12	-6,35E+6	-2,49E+6	-7,67E+5	-1336,34
2BDA-10	771	766	770	771	0,00	0,00	0,00	0,01	1542,08	485,28	244,80	169,02	-1002,52	-381,38	-114,12	-0,60
3BDA-1	653	657	673	654	0,00	0,00	0,00	0,02	2,02E+5	8,33E+4	3,82E+4	6596,18	-1,77E+7	-1,12E+7	-2,74E+6	-2267,58
3BDA-2	685	675	692	684	0,00	0,00	0,00	0,02	7,28E+5	1,83E+5	1,31E+5	2,55E+4	-2,31E+8	-5,34E+7	-3,30E+7	-3,45E+4
3BDA-3	454	443	372	247	0,00	0,00	0,00	0,01	2,22E+5	1,03E+5	4,74E+4	1,43E+4	-2,15E+7	-1,69E+7	-4,22E+6	-1,51E+4
3BDA-4	646	648	657	656	0,00	0,00	0,00	0,00	9,65E+7	4,48E+7	1,88E+7	2,85E+6	-4,05E+12	-3,29E+12	-6,68E+11	-4,40E+8
3BDA-5	473	472	439	457	0,00	0,00	0,00	0,00	6,15E+4	2,08E+4	8738,88	1945,80	-1,45E+6	-6,95E+5	-1,42E+5	-182,71
4BDA	758	740	765	760	0,00	0,00	0,00	0,00	788,63	209,32	43,01	150,45	-262,57	-69,33	-2,55	-0,26

Modelo	N° Dados				Correlação (R²)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
FLH	686	667	705	700	0,00	0,00	0,00	0,00	154,56	99,82	99,02	168,69	-8,75	-15,06	-17,75	-0,54
NDCI	727	722	712	724	0,00	0,00	0,01	0,00	134,94	53,66	72,10	164,83	-6,79	-3,80	-9,03	-0,41
SABI	758	751	748	748	0,00	0,00	0,00	0,01	-	-	-	-	-	-	-	-
OC2V4	763	758	759	735	0,00	0,00	0,00	0,01	80,13	58,59	82,06	165,37	-1,74	-4,61	-11,95	-0,50
OC4V4	625	619	619	607	0,00	0,00	0,00	0,01	137,32	77,68	85,65	153,79	-6,89	-8,88	-13,00	-0,56

APÊNDICE D

Tabela D.1. Resultados das testagens da eficiência dos modelos espectrais utilizando imagens Sentinel 2 com correção atmosférica pelo algoritmo Sen2cor para o período de 2019 a 2022, considerando os agrupamentos de dados formados pelos volumes disponíveis nos reservatórios nos dias das coletas de campo. O I, II, III e IV, indicam os quartis. O intervalo de concentração de Cla-a de cada quartil é: I - 0 a 2,29 hm³; II - 2,29 a 7,38 hm³; III - 7,38 a 28,63 hm³; IV - 28,63 a 1054,38 hm³. Os valores de R² em negrito simbolizam os dados com distribuição normal e cujas correlações foram verificadas por Pearson.

Modelo	N° Dados				Correlação (R²)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
1BDA	338	332	329	335	0,01	0,00	0,00	0,00	1,06E+4	6794,32	8618,98	6383,88	-1322,13	-2460,06	-6366,88	-2690,31
2BDA-1	366	354	364	373	0,11	0,16	0,12	0,14	314,41	133,41	108,18	112,21	-0,03	0,06	0,11	0,13
2BDA-2	382	375	368	372	0,01	0,01	0,02	0,03	283,30	153,06	184,77	207,34	0,00	-0,21	-1,39	-1,62
2BDA-3	400	401	392	394	0,01	0,02	0,01	0,02	299,43	168,14	152,87	157,57	-0,12	-0,53	-0,72	-0,65
2BDA-4	401	401	393	395	0,00	0,02	0,01	0,02	299,58	168,16	152,77	157,76	-0,12	-0,53	-0,72	-0,64
2BDA-5	363	354	362	371	0,12	0,16	0,11	0,14	312,02	131,72	112,93	119,00	-0,01	0,09	0,03	0,03
2BDA-6	363	351	365	368	0,12	0,14	0,11	0,14	311,11	133,17	117,00	124,06	-0,01	0,10	-0,03	-0,03
2BDA-7	358	354	342	346	0,00	0,00	0,01	0,00	8235,40	6840,25	7135,71	5221,75	-1763,13	-2450,98	-3811,22	-2123,99
2BDA-8	327	321	322	341	0,00	0,00	0,00	0,01	3729,18	2013,52	2601,19	3129,91	-159,77	-206,07	-566,79	-784,06
2BDA-9	359	355	345	348	0,00	0,00	0,01	0,00	1,16E+4	1,01E+4	1,14E+4	9079,87	-3489,56	-5364,14	-9661,91	-6428,61
2BDA-10	357	368	354	358	0,00	0,02	0,01	0,00	335,47	247,92	287,23	311,79	-0,34	-2,29	-6,00	-5,68
3BDA-1	372	354	335	327	0,00	0,11	0,06	0,02	3637,82	5495,01	7670,75	1,06E+4	-173,46	-1733,70	-4825,48	-8407,27
3BDA-2	331	331	324	331	0,00	0,00	0,00	0,01	4922,21	3302,25	4445,47	4501,32	-282,41	-592,41	-1661,86	-1346,98

Modelo	N° Dados				Correlação (R²)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
3BDA-3	26	21	36	62	0,00	0,05	0,00	0,03	8,24E+4	4,60E+4	1,52E+5	5,37E+4	-9,98E+5	-4,88E+5	-4,87E+6	-7,62E+4
3BDA-4	352	336	337	330	0,01	0,01	0,00	0,02	2,32E+6	3,54E+6	5,50E+6	8,04E+6	-7,44E+7	-7,38E+8	-2,42E+9	-4,66E+9
3BDA-5	247	257	248	248	0,01	0,00	0,00	0,02	3962,18	5478,65	8072,73	8056,81	-179,06	-1496,35	-4439,60	-3756,58
4BDA	368	374	365	375	0,00	0,00	0,00	0,00	289,00	136,98	129,43	149,32	0,00	-0,01	-0,38	-0,52
FLH	366	360	347	346	0,07	0,02	0,02	0,00	300,79	170,53	154,34	160,25	-0,14	-0,63	-0,81	-0,62
NDCI	378	366	371	375	0,12	0,12	0,10	0,14	306,33	133,98	108,50	111,15	-0,03	0,07	0,09	0,13
SABI	397	401	397	399	0,01	0,00	0,00	0,00	-	-	-	-	-	-	-	-
OC2V4	391	390	395	395	0,00	0,01	0,01	0,03	295,86	159,91	140,67	145,24	-0,10	-0,38	-0,43	-0,36
OC4V4	309	317	329	347	0,00	0,00	0,00	0,02	325,90	166,64	148,49	152,97	-0,07	-0,36	-0,44	-0,34

Tabela D.2. Resultados das testagens da eficiência dos modelos espectrais utilizando imagens Sentinel 2 com correção atmosférica pelo algoritmo SIAC para o período de 2019 a 2022, considerando os agrupamentos de dados formados pelos volumes disponíveis nos reservatórios nos dias das coletas de campo. O I, II, III e IV, indicam os quartis. O intervalo de concentração de Cla-*a* de cada quartil é: I - 0 a 2,29 hm³; II - 2,29 a 7,38 hm³; III - 7,38 a 28,63 hm³; e IV - 28,63 a 1054,38 hm³. Os valores de R² em negrito simbolizam os dados com distribuição normal e cujas correlações foram verificadas por Pearson.

Modelo	N° Dados				Correlação (R²)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
1BDA	356	345	344	351	0,00	0,00	0,00	0,00	5,13E+4	6,45E+4	8,14E+4	1,52E+5	-3,07E+4	-2,18E+5	-5,34E+5	-1,52E+6
2BDA-1	369	372	377	370	0,01	0,10	0,05	0,06	234,46	142,53	126,58	131,87	-0,10	-0,19	-0,16	-0,15
2BDA-2	382	377	372	376	0,00	0,00	0,00	0,00	287,62	153,91	193,55	223,09	0,00	-0,24	-1,65	-2,09
2BDA-3	403	402	401	401	0,00	0,00	0,01	0,01	298,28	168,11	152,61	158,03	-0,12	-0,53	-0,71	-0,63
2BDA-4	403	402	401	401	0,00	0,00	0,01	0,01	298,29	168,13	152,65	158,07	-0,12	-0,53	-0,71	-0,63
2BDA-5	369	370	376	371	0,06	0,10	0,05	0,06	228,53	132,10	115,77	120,56	-0,04	-0,01	0,03	0,04
2BDA-6	366	370	378	373	0,05	0,10	0,05	0,06	229,78	130,65	115,46	120,89	-0,03	0,01	0,04	0,05
2BDA-7	377	347	360	356	0,00	0,00	0,02	0,00	1,17E+4	8386,06	1,64E+4	9977,11	-1640,64	-3620,79	-2,23E+4	-7511,09
2BDA-8	363	345	344	350	0,00	0,01	0,00	0,01	1,89E+4	1,95E+4	2,66E+4	4,45E+4	-4281,18	-1,98E+4	-5,68E+4	-1,29E+5
2BDA-9	379	350	365	351	0,00	0,00	0,01	0,00	1,50E+4	1,16E+4	2,21E+4	1,26E+4	-2757,83	-6908,32	-4,04E+4	-1,22E+4
2BDA-10	393	389	372	398	0,00	0,00	0,01	0,00	320,07	236,56	276,24	331,25	-0,29	-2,00	-5,22	-6,11

Modelo	N° Dados				Correlação (R ²)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
3BDA-1	343	341	342	340	0,00	0,01	0,00	0,01	1,94E+4	2,56E+4	3,77E+4	3,94E+4	-4,39E+3	-3,46E+4	-1,01E+5	-9,50E+4
3BDA-2	351	343	334	343	0,00	0,00	0,00	0,00	3,16E+4	4,39E+4	4,55E+4	1,02E+5	-1,17E+4	-1,03E+5	-1,70E+5	-7,13E+5
3BDA-3	146	185	184	249	0,04	0,04	0,11	0,04	3,51E+4	6,35E+4	6,99E+4	5,77E+4	-1,39E+4	-3,13E+5	-3,04E+5	-2,07E+5
3BDA-4	339	333	341	334	0,03	0,02	0,00	0,00	9,26E+6	1,22E+7	1,87E+7	1,97E+7	-1,01E+9	-7,96E+9	-2,54E+10	-2,35E+10
3BDA-5	248	256	234	245	0,00	0,00	0,01	0,01	4786,70	6823,63	1,01E+4	1,14E+4	-251,00	-2509,77	-6937,07	-7461,08
4BDA	369	354	361	385	0,00	0,00	0,00	0,00	289,76	138,27	128,85	152,27	-0,01	-0,01	-0,35	-0,49
FLH	366	354	356	343	0,01	0,01	0,00	0,00	302,15	168,61	151,28	156,84	-0,13	-0,57	-0,86	-0,58
NDCI	369	374	376	368	0,01	0,10	0,05	0,06	234,33	143,50	127,39	136,95	-0,11	-0,22	-0,22	-0,21
SABI	400	397	392	391	0,00	0,00	0,01	0,00	-	-	-	-	-	-	-	-
OC2V4	387	396	392	399	0,00	0,00	0,00	0,00	298,20	158,17	137,03	142,41	-0,10	-0,35	-0,39	-0,32
OC4V4	320	322	317	327	0,00	0,00	0,00	0,00	237,91	158,22	141,77	150,37	-0,18	-0,34	-0,36	-0,34

Tabela D.3. Resultados das testagens da eficiência dos modelos espectrais utilizando imagens Sentinel 2 com correção atmosférica pelo algoritmo SIAC para o período de 2015 a 2022, considerando os agrupamentos de dados formados pelos volumes disponíveis nos reservatórios nos dias das coletas de campo. O I, II, III e IV, indicam os quartis. O intervalo de concentração de Cla-*a* de cada quartil é: I - 0 a 1,39 hm³; II - 1,39 a 5,15 hm³; III - 5,15 a 18,24 hm³; IV - 18,24 a 1054,38 hm³. Os valores de R² em negrito simbolizam os dados com distribuição normal e cujas correlações foram verificadas por Pearson.

Modelo	N° Dados				Correlação (R ²)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
1BDA	700	702	687	675	0,01	0,00	0,00	0,00	6,76E+4	1,26E+5	1,50E+5	1,40E+5	-9,11E+4	-7,01E+5	-1,45E+6	-1,28E+6
2BDA-1	687	704	697	707	0,03	0,02	0,03	0,07	242,36	163,30	138,06	136,19	-0,13	-0,18	-0,20	-0,20
2BDA-2	730	719	712	719	0,00	0,00	0,01	0,00	230,14	163,45	160,33	186,08	-0,01	-0,15	-0,56	-1,17
2BDA-3	771	767	768	768	0,00	0,00	0,01	0,00	245,18	179,08	159,64	157,68	-0,20	-0,44	-0,62	-0,64
2BDA-4	771	767	768	768	0,00	0,00	0,01	0,00	245,18	179,09	159,67	157,71	-0,20	-0,44	-0,62	-0,64
2BDA-5	688	704	696	708	0,03	0,02	0,03	0,07	237,47	153,73	126,47	123,38	-0,09	-0,05	-0,01	0,01
2BDA-6	684	702	695	711	0,02	0,02	0,03	0,07	232,88	152,27	125,75	123,02	-0,08	-0,03	0,01	0,03
2BDA-7	697	685	671	660	0,00	0,00	0,01	0,00	8209,90	1,31E+4	1,26E+4	9168,96	-1312,66	-7571,55	-1,04E+4	-5684,09
2BDA-8	727	715	710	697	0,00	0,00	0,00	0,01	2,32E+4	3,94E+4	5,05E+4	4,76E+4	-1,07E+4	-7,04E+4	-1,65E+5	-1,53E+5

Modelo	N° Dados				Correlação (R ²)				NRMSE (%)				NSE			
	I	II	III	IV	I	II	III	IV	I	II	III	IV	I	II	III	IV
2BDA-9	703	688	685	671	0,00	0,00	0,01	0,00	1,06E+4	1,69E+4	1,72E+4	1,32E+4	-2171,80	-1,37E+4	-1,96E+4	-1,17E+4
2BDA-10	768	765	765	763	0,00	0,00	0,01	0,00	253,77	235,01	262,16	291,40	-0,28	-1,48	-3,38	-4,60
3BDA-1	654	666	658	654	0,00	0,00	0,00	0,01	1,37E+4	2,79E+4	3,09E+4	3,17E+4	-3634,71	-3,47E+4	-6,18E+4	-6,42E+4
3BDA-2	688	699	677	665	0,01	0,00	0,00	0,00	4,59E+4	9,16E+4	1,05E+5	9,84E+4	-41234,38	-3,70E+5	-7,15E+5	-6,40E+5
3BDA-3	303	370	380	450	0,07	0,04	0,04	0,06	2,35E+4	5,20E+4	5,67E+4	4,58E+4	-1,20E+4	-1,10E+5	-1,98E+5	-1,14E+5
3BDA-4	647	651	651	639	0,03	0,00	0,01	0,00	6,51E+6	1,33E+7	1,44E+7	1,51E+7	-8,27E+8	-7,88E+9	-1,35E+10	-1,43E+10
3BDA-5	479	458	466	466	0,00	0,00	0,00	0,01	3315,69	6885,43	8128,23	9873,63	-195,82	-2037,81	-4007,58	-5587,95
4BDA	757	757	748	746	0,00	0,00	0,00	0,00	229,62	149,23	128,32	134,59	-0,05	0,00	-0,07	-0,20
FLH	721	692	678	670	0,01	0,00	0,01	0,00	247,51	179,72	155,61	158,05	-0,19	-0,43	-0,66	-0,59
NDCI	689	703	702	703	0,03	0,02	0,04	0,07	242,23	164,54	139,29	138,80	-0,14	-0,20	-0,25	-0,26
SABI	754	756	744	743	0,01	0,01	0,01	0,00	248,30	179,08	159,83	158,53	-0,19	-0,45	-0,64	-0,66
OC2V4	740	754	748	760	0,00	0,00	0,00	0,00	-	-	-	-	-	-	-	-
OC4V4	606	616	603	619	0,00	0,00	0,00	0,00	231,33	176,51	153,90	151,64	-0,19	-0,30	-0,38	-0,39