



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA,
INOVAÇÕES E COMUNICAÇÕES



sid.inpe.br/mtc-m21c/2020/03.03.16.42-TDI

**ABORDAGEM HÍBRIDA APLICADA AO
MONITORAMENTO SISTEMÁTICO DO ESTADO
TRÓFICO DA ÁGUA POR SENSORIAMENTO
REMOTO EM RESERVATÓRIOS: RESERVATÓRIO DA
UHE IBITINGA/SP**

Carolline Tressmann Cairo

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Cláudio Clemente Faria Barbosa, e Felipe de Lucia Lobo, aprovada em 01 de abril de 2020.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34R/4247Q9L>

INPE
São José dos Campos
2020

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

CEP 12.227-010

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/7348

E-mail: pubtc@inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dra. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

Membros:

Dra. Carina Barros Mello - Coordenação de Laboratórios Associados (COCTE)

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra (CGOBT)

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SESID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SESID)

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Serviço de Informação e Documentação (SESID)

Cauê Silva Fróes - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA
CIÊNCIA, TECNOLOGIA,
INOVAÇÕES E COMUNICAÇÕES



sid.inpe.br/mtc-m21c/2020/03.03.16.42-TDI

**ABORDAGEM HÍBRIDA APLICADA AO
MONITORAMENTO SISTEMÁTICO DO ESTADO
TRÓFICO DA ÁGUA POR SENSORIAMENTO
REMOTO EM RESERVATÓRIOS: RESERVATÓRIO DA
UHE IBITINGA/SP**

Carolline Tressmann Cairo

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Cláudio Clemente Faria Barbosa, e Felipe de Lucia Lobo, aprovada em 01 de abril de 2020.

URL do documento original:

<http://urlib.net/8JMKD3MGP3W34R/4247Q9L>

INPE
São José dos Campos
2020

Dados Internacionais de Catalogação na Publicação (CIP)

Cairo, Carolline Tressmann.

C123a Abordagem híbrida aplicada ao monitoramento sistemático do estado trófico da água por sensoriamento remoto em reservatórios: reservatório da UHE Ibitinga/SP / Carolline Tressmann Cairo. – São José dos Campos : INPE, 2020.

xxxiv + 176 p. ; (sid.inpe.br/mtc-m21c/2020/03.03.16.42-TDI)

Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2020.

Orientadores : Dr. Cláudio Clemente Faria Barbosa, e Dr. Felipe de Lucia Lobo.

1. Clorofila-a. 2. Estado trófico. 3. Modelo híbrido.
4. Reservatório tropical. I.Título.

CDU 528.8:556.55



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Carolline Tressmann Cairo**

Título: "ABORDAGEM HÍBRIDA APLICADA AO MONITORAMENTO SISTEMÁTICO DO ESTADO TRÓFICO DA ÁGUA POR SENSORIAMENTO REMOTO EM RESERVATÓRIOS: RESERVATÓRIO DA UHE IBITINGA/SP"

Aprovado (a) pela Banca Examinadora em cumprimento ao requisito exigido para obtenção do Título de **Doutor(a)** em

Sensoriamento Remoto

Dr. Milton Kampel

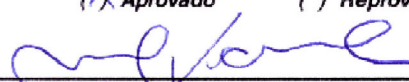


Presidente / INPE / SJCampos - SP

Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Cláudio Clemente Faria Barbosa



Orientador(a) / INPE / SJCampos - SP

Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Felipe de Lucia Lobo



Orientador(a) / UFPEL / Pelotas - RS

Participação por Vídeo - Conferência

Aprovado () Reprovado

Dra. Natália Rudorff Oliveira



Membro da Banca / INPE / Cachoeira Paulista - SP

Participação por Vídeo - Conferência

Aprovado () Reprovado

Dra. Marta Condé Lamparelli



Convidado(a) / CETESB / São Paulo - SP

Participação por Vídeo - Conferência

Aprovado () Reprovado

Dra. Fernanda Sayuri Yoshino Watanabe



Convidado(a) / UNESP / Presidente Prudente - SP

Participação por Vídeo - Conferência

Aprovado () Reprovado

Este trabalho foi aprovado por:

() maioria simples

unanimidade

“Tudo evolui; não há realidades eternas, tal como não há verdades absolutas”.

Friedrich Nietzsche

*À minha família,
em especial a minha mãe
e a meu tio.*

AGRADECIMENTOS

Primeiramente, gostaria de agradecer a Deus por toda a resiliência concedida nesse período do doutorado. Muito obrigada Senhor por ter me dado força e paciência suficientes para superar todos os obstáculos que no meu caminho adentraram.

Agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES - Código de Financiamento 001) e a Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP; Projeto 2008/56252-0) pelo apoio financeiro concedido para a realização das campanhas de campo. Muito obrigada também a CAPES pela bolsa de doutorado. Agradeço ao INPE pela infraestrutura fornecida para a realização do doutorado, e em especial a coordenadora do curso de sensoriamento remoto, Dra Ieda Sanches, pelo excelente trabalho nesses anos de gestão. Agradeço também ao Laquatec/INPE por toda a infraestrutura de laboratório para a realização das análises.

Quero agradecer aos meus orientadores Dr Claudio Clemente Faria Barbosa e Dr Felipe de Lucia Lobo pela oportunidade de fazer um doutorado e por todo aprendizado e conhecimento adquiridos. Agradeço também a Dra Evlyn Márcia de Moraes Novo pela ajuda nas correções do artigo publicado na *Remote Sensing* e por sempre elucidar o complexo. Obrigada Dra Evlyn por me mostrar nesse último ano de doutorado que a solidariedade realmente ajuda a vencer os obstáculos financeiros impostos pelo Governo. Juntos somos mais fortes, juntos podemos fazer a diferença!

Agradeço imensamente aos meus amigos do LabISA por todo incentivo e ajuda nesses 4 longos anos. Toda a amizade, carinho e solidariedade ao próximo nos tornaram uma equipe sólida e coesa. Em especial quero agradecer ao Felipe Menino pelo coração incrível que ele tem, aprendemos juntos a desenvolver um sistema de monitoramento!

Agradeço muito aos meus amigos de Vila Velha/ES e de São José dos Campos/SP por toda a força e compreensão quando eu precisava me ausentar. Obrigada por serem meus ouvidos quando necessitava desabafar e muito obrigada pelos abraços amorosos. Vocês são os melhores amigos que uma pessoa possa ter!

Eu não tenho palavras para agradecer a minha família, em especial a minha mãe Nelma e ao meu tio Deni. Vocês foram o meu suporte quando tudo desabava! Mãe, Deus foi muito benevolente comigo quando me deu você como mãe. Obrigada por ter abraçado esse sonho junto comigo! Tio, onde quer que você esteja aí no céu, muito obrigada por ter trazido calma nas tempestades, muito obrigada por ter sido meu porto seguro. Eu dedico esta tese ao senhor! Vovó e vovô, muito obrigada pelas orações e por todo amor que construíram por mim, vocês moram no meu coração!

RESUMO

O uso do sensoriamento remoto (SR) para o monitoramento do estado trófico de águas interiores depende da calibração de algoritmos bio-ópticos de clorofila-*a* (chl-*a*). Um dos principais fatores limitantes da calibração desses algoritmos é que eles não conseguem lidar com precisão com as amplas faixas de concentração de chl-*a* em águas opticamente complexas sujeitas a diferentes estados tróficos. Assim, este estudo propôs uma abordagem híbrida, que é uma estrutura combinada de algoritmos calibrados com dados *in situ* para faixas específicas de concentração da chl-*a*, para monitorar sistematicamente o estado trófico da água em reservatórios por SR. A área de estudo é o reservatório de Ibitinga, localizado no médio Tietê (região central do estado de São Paulo), sendo caracterizado por uma elevada variabilidade espaço-temporal da concentração da chl-*a* (3–1000 mg/m³). As seguintes etapas foram realizadas para atingir o objetivo do presente estudo: 1) classes ópticas de faixas específicas de concentração da chl-*a* foram definidas usando os métodos limnológico e óptico; 2) algoritmos bio-ópticos de chl-*a* foram calibrados/validados para cada classe óptica usando a simulação Monte Carlo a partir de medidas de R_{rs} *in situ* simuladas para as bandas do sensor *MultiSpectral Instrument* (MSI) do Sentinel-2; e 3) aplicou-se um classificador de árvore de decisão na imagem MSI/Sentinel-2 para detectar as classes ópticas de faixas específicas de concentração da chl-*a* e alternar entre os algoritmos mais adequados para cada classe. Os resultados mostraram que as três classes ópticas definidas apresentaram diferentes intervalos de concentração da chl-*a*: a) para o método limnológico a classe óptica “OligoMeso” teve intervalo de variação de 0–11,03 mg/m³, a classe óptica “EutroSuper” intervalo de 11,03–69,05 mg/m³ e a classe óptica “Hiper” valor de chl-*a* maior que 69,05 mg/m³; e b) para o método óptico a classe óptica “Classe 1” teve intervalo de variação de 2,89–22,83 mg/m³, a classe óptica “Classe 2” intervalo de 19,51–87,63 mg/m³ e a classe óptica “Classe 3” intervalo de 75,89–938,97 mg/m³. Os algoritmos de melhor desempenho para as classes ópticas descritas são, respectivamente: a) para Modelo Híbrido Limnológico (MHL): 3 bandas ($R^2 = 0,92$; MAPE = 25,17%), *Normalized Difference Chlorophyll Index* (NDCI: $R^2 = 0,79$; MAPE = 24,04%), e 2 bandas ou *slope* (B5/B3: $R^2 = 0,89$; MAPE = 21,78% / *slope*: $R^2 = 0,88$; MAPE = 26,65%); e b) para o Modelo Híbrido Óptico (MHO): 3 bandas ($R^2 = 0,78$; MAPE = 34,36%), *slope* ($R^2 = 0,93$; MAPE = 23,35%), e 2 bandas (B5/B3: $R^2 = 0,82$; MAPE = 21,40% / B6/B3: $R^2 = 0,98$; MAPE = 20,12%). O classificador da árvore de decisão mostrou uma acurácia de 95% na detecção das classes ópticas dos métodos limnológico e óptico. A performance geral do MHL e MHO foram satisfatórias (MHL: $R^2 = 0,94$; MAPE = 22,55% / MHO: $R^2 = 0,98$; MAPE = 26,33%) usando dados *in situ*, mas foi reduzida usando a imagem MSI/Sentinel-2 (MHL: $R^2 = 0,56$; MAPE = 33,99% / MHO: $R^2 = 0,42$; MAPE = 28,32%) devido possivelmente à diferença temporal entre os *matchups*, à variabilidade na hidrodinâmica do reservatório, à heterogeneidade da janela 3x3 pixels e à diferença de resolução espacial entre os dados de campo e da imagem MSI/Sentinel-2. Existem algumas limitações da abordagem híbrida desenvolvida neste estudo relacionadas à correção atmosférica e correção do *glint*, e também à sensibilidade do modelo de melhor desempenho em baixas condições tróficas da água. Mas de maneira geral, a estrutura da abordagem híbrida permitiu uma estimativa mais precisa da chl-*a* em águas interiores eutrofizadas. Mesmo tendo desempenhos semelhantes, o MHO mostrou ser um método mais preciso que o MHL para estimar a

concentração da chl-*a*, e conseqüentemente o estado trófico, no reservatório de Ibitinga. Isso porque as classes ópticas do método óptico estariam menos sujeitas a influência da variação da intensidade da R_{rs} decorrentes de incertezas na coleta de campo, a validação da árvore de decisão do MHO com dados *in situ* e com a imagem gerou menos erros de classificação e a estrutura da condicional da árvore de decisão do MHO não usou a Banda 6 (B6) do MSI/Sentinel-2, que geralmente não tem uma boa correção atmosférica pelo 6S (superestimada) em águas interiores, podendo isso levar a erros na classificação do pixel e, conseqüentemente, na estimativa da chl-*a*. Por fim, o resultado das séries temporais mostraram que a eutrofização no reservatório de Ibitinga foi intensificada a partir do ano de 2018, aplicando ambos modelos híbridos nas imagens MSI/Sentinel-2. Para o MHL, o estado trófico predominante no reservatório nos meses de 2018/2019 foi o hipereutrófico, enquanto para o MHO foi o supereutrófico.

Palavras-chave: Clorofila-*a*. Estado trófico. Modelo híbrido. Reservatório tropical.

HYBRID APPROACH APPLIED TO SYSTEMATIC MONITORING OF THE WATER TROPHIC STATE WITH REMOTE SENSING TECHNIQUES IN RESERVOIRS: UHE IBITINGA/SP RESERVOIR

ABSTRACT

Using remote sensing for monitoring trophic states of inland waters relies on the calibration of chlorophyll-*a* (chl-*a*) bio-optical algorithms. One of the main limiting factors of calibrating those algorithms is that they cannot accurately cope with the wide chl-*a* concentration ranges in optically complex waters subject to different trophic states. Thus, this study proposes a hybrid approach, which is a combined framework of algorithms calibrated with *in situ* data for specific chl-*a* concentration ranges, to systematically monitor the trophic state of water in reservoirs by SR. The study area is Ibitinga Reservoir, located in the Middle Tietê (central region of São Paulo State), being characterized by high spatiotemporal variability of chl-*a* concentrations (3–1000 mg/m³). We took the following steps to address this issue: 1) we defined optical classes of specific chl-*a* concentration ranges using limnological and optical methods; 2) we calibrated/validated chl-*a* bio-optical algorithms for each optical class using Monte Carlo simulation from *in situ* R_{rs} data simulated for MultiSpectral Instrument (MSI) bands of Sentinel-2; and 3) we applied a decision tree classifier in MSI/Sentinel-2 image to detect the trophic classes and to switch to the suitable algorithm for the given class. The results showed that the three defined optical classes presented different ranges of chl-*a* concentration: a) for the limnological method, the optical class “OligoMeso” had a variation range of 0–11,03 mg/m³, the optical class “EutroSuper” a range of 11,03–69,05 mg/m³, and the optical class “Hiper” chl-*a* values more than 69,05 mg/m³; and b) for the optical method, the optical class “Class 1” had a variation range of 2,89–22,83 mg/m³, the optical class “Class 2” a range of 19,51–87,63 mg/m³, and the optical class “Class 3” a range of 75,89–938,97 mg/m³. The best performance algorithms for the described optical classes are, respectively: a) for Limnological Hybrid Model (LHM): 3-band (R² = 0,92; MAPE = 25,17%), Normalized Difference Chlorophyll Index (NDCI: R² = 0,79; MAPE = 24,04%), and 2-band or slope (B5/B3: R² = 0,89; MAPE = 21,78% / slope: R² = 0,88; MAPE = 26,65%); and b) for Optical Hybrid Model (OHM): 3-band (R² = 0,78; MAPE = 34,36%), slope (R² = 0,93; MAPE = 23,35%), and 2-band (B5/B3: R² = 0,82; MAPE = 21,40% / B6/B3: R² = 0,98; MAPE = 20,12%). The decision tree classifier showed an accuracy of 95% for detecting optical classes of the limnological e optical methods. The overall performance of LHM and OHM were satisfactory (LHM: R² = 0,94; MAPE = 22,55% / OHM: R² = 0,98; MAPE = 26,33%) using *in situ* data but reduced in the MSI/Sentinel-2 image (LHM: R² = 0,56; MAPE = 33,99% / OHM: R² = 0,42; MAPE = 28,32%) possibly due to the temporal gap between matchups, the variability in reservoir hydrodynamics, the heterogeneity of the 3x3 pixel window and the difference in spatial resolution between the field data and the MSI/Sentinel-2 image. There are some limitations of the hybrid approach developed in this study related to atmospheric and glint correction and to the sensibility of the best performing model in low trophic conditions of the water. But in general, the extension of the hybrid approach framework allowed a more precise chl-*a* estimate in eutrophic inland waters. OHM proved to be a more accurate method than LHM for estimating chl-*a* concentration, as well as the trophic state, in Ibitinga Reservoir. This is because the optical classes of the optical method would be

less subject to the influence of the variation in R_{rs} intensity due to uncertainties in the field collection, the validation of the MHO decision tree with in situ data and image generated less classification errors, and the conditional structure of the MHO decision tree did not use the MSI/Sentinel-2 B6, which generally does not have a good atmospheric correction for 6S (overestimated) in inland waters, and this can lead to errors in pixel classification and, consequently, in the estimate of chl-*a*. Finally, the time series result showed that eutrophication in Ibitinga Reservoir was intensified from 2018, applying both hybrid models in MSI/Sentinel-2 images. For MHL, the predominant trophic state in the reservoir in 2018/2019 months was hypereutrophic, while for MHO it was supereutrophic.

Keywords: Chlorophyll-*a*. Trophic state. Hybrid model. Tropical reservoir.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Princípio do <i>Fluorescence Line Height</i> (FLH), em que λ_F , λ_L e λ_R são respectivamente os comprimentos de ondas centrais da banda de fluorescência e das duas bandas da linha de base. L_F , L_L e L_R são respectivamente as radiâncias da banda de fluorescência e das duas bandas da linha de base.	19
Figura 3.1 - Fluxograma da metodologia desenvolvida na tese.....	30
Figura 3.2 - Localização do reservatório de Ibitinga/SP e seus principais afluentes	31
Figura 3.3 - Campanhas de campo da (A) Londe (2008) e da (B) Cairo (2015), nov/2013, set/2014 e ago/2018. Os pontos vermelhos em (B) são estações amostrais coletadas em todas as campanhas de 2013, 2014 e 2018.	35
Figura 3.4 - Exemplos de supercorreções nas estações amostrais 10 (A) e 20 (B) dos dados de $R_{rs}(\lambda)$ da Londe (2008), utilizando a metodologia proposta por Kutser et al. (2013). A linha contínua preta é a curva de potência ajustada entre os comprimentos de onda de referência (350-380 / 890-900 nm).....	36
Figura 3.5 - Exemplos de correções da $R_{rs}(\lambda)$ <i>in situ</i> de algumas estações amostrais da Londe (2008) pela metodologia de: (A) Kutser et al. (2013) normal, (B) Kutser et al. (2013) adaptação 1, (C) Kutser et al. (2013) adaptação 2 e (D) Kutser et al. (2013) adaptação 3.	38
Figura 3.6 - (A) Classes de referência utilizadas no SAM; (B) o zoom na classe 1 foi com o objetivo de focar na forma do espectro de referência, e assim conseguir comparar com a forma das outras duas classes.....	41
Figura 3.7 – Fluxograma da análise exploratória	44
Figura 3.8 - Fluxograma da simulação Monte Carlo.....	45
Figura 3.9 - Exemplo da estrutura hierárquica de uma classificação por árvore de decisão.....	48
Figura 3.10 – Exemplo de divisão dos atributos de entrada (A) contínuos, usando a razão de bandas B5/B4 com valores fictícios. Esse processo é repetido para todos os registros de treinamento, no caso todas as razões de bandas consideradas.....	50
Figura 3.11 – Fluxograma da rotina de análise temporal.....	55

Figura 3.12 - Pontos escolhidos ao longo do reservatório de Ibitinga para a análise temporal das classes ópticas e da concentração da chl- <i>a</i>	56
Figura 4.1 - Espectros de R_{rs} <i>in situ</i> classificados pelo SAM. (A) Classe 1, (B) Classe 2 e (C) Classe 3. As setas indicam os picos de reflectância característicos de cada classe. 57	57
Figura 4.2 - Resultado da separação dos espectros de R_{rs} <i>in situ</i> em cada faixa específica de concentração da chl- <i>a</i> do método limnológico, gerando as classes ópticas. (A) Classe “OligoMeso”, (B) Classe “EutroSuper” e (C) Classe “Hiper”.	58
Figura 4.3 - Resultado da árvore de decisão para o Modelo Híbrido Limnológico (MHL), usando dados <i>in situ</i> (N = 69 amostras). (A) Resultado do treinamento do algoritmo de classificação da árvore de decisão, sendo Classe 1 = OligoMeso, Classe 2 = EutroSuper e Classe 3 = Hiper as classes ópticas geradas pelo método limnológico; (B) Resultado do teste do algoritmo treinado, gerando a matriz de confusão.	63
Figura 4.4 - Resultado da árvore de decisão para o Modelo Híbrido Óptico (MHO), usando dados <i>in situ</i> (N = 69 amostras). (A) Resultado do treinamento do algoritmo de classificação da árvore de decisão, sendo Classe 1, 2 e 3 as respectivas classes ópticas do SAM; (B) Resultado do teste do algoritmo treinado, gerando a matriz de confusão. ...	64
Figura 4.5 – Estrutura do MHL. As classes 1, 2 e 3 indicam a presença de baixa (verde), média (amarela) e alta (vermelha) intensidade de floração, respectivamente. Sendo Classe 1 = OligoMeso, Classe 2 = EutroSuper e Classe 3 = Hiper, no caso as classes ópticas geradas pelo método limnológico.....	66
Figura 4.6 - Estrutura do MHO. As classes 1, 2 e 3 indicam a presença de baixa (verde), média (amarela) e alta (vermelha) intensidade de floração, respectivamente. Sendo classe 1, 2 e 3 as respectivas classes ópticas do SAM.	67
Figura 4.7 – Desempenho da validação dos algoritmos usando dados <i>in situ</i> , referente aos 30% da validação da Monte Carlo de cada faixa específica de concentração da chl- <i>a</i> do método limnológico. Esse conjunto de 30% de dados aleatórios para a validação foi o mesmo para os quatro casos mostrados. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste exponencial, calibrado/validado até 600 mg/m ³ ; (B) Algoritmo NDCI do Mishra e Mishra (2012), com ajuste polinomial, calibrado/validado até 600 mg/m ³ ; (C) Algoritmo razão de bandas B5/B3, com ajuste exponencial, calibrado/validado até 600 mg/m ³ ; (D) Modelo Híbrido Limnológico (MHL) considerando a classe 3 (Hiper) com valores até 600 mg/m ³	69

Figura 4.8 - Desempenho da validação dos algoritmos usando dados *in situ*, referente aos 30% da validação da Monte Carlo de cada faixa específica de concentração da chl-*a* do método limnológico. Esse conjunto de 30% de dados aleatórios para a validação foi o mesmo para os quatro casos mostrados. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste exponencial, calibrado/validado até 1000 mg/m³; (B) Algoritmo NDCI do Mishra e Mishra (2012), com ajuste polinomial, calibrado/validado até 1000 mg/m³; (C) Algoritmo *Slope* do Mishra e Mishra (2010), com ajuste polinomial, calibrado/validado até 1000 mg/m³; (D) Modelo Híbrido Limnológico (MHL) considerando a classe 3 (Hiper) com valores até 1000 mg/m³. 70

Figura 4.9 – Desempenho da validação dos algoritmos usando dados *in situ*, referente aos 30% da validação da Monte Carlo de cada faixa específica de concentração da chl-*a* do método óptico. Esse conjunto de 30% de dados aleatórios para a validação foi o mesmo para os quatro casos mostrados. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste linear, calibrado/validado até 600 mg/m³; (B) Algoritmo *Slope* do Mishra e Mishra (2010), com ajuste exponencial, calibrado/validado até 600 mg/m³; (C) Algoritmo razão de bandas B5/B3, com ajuste exponencial, calibrado/validado até 600 mg/m³; (D) Modelo Híbrido Óptico (MHO) considerando a classe 3 com valores até 600 mg/m³. 71

Figura 4.10 – Desempenho da validação dos algoritmos usando dados *in situ*, referente aos 30% da validação da Monte Carlo de cada faixa específica de concentração da chl-*a* do método óptico. Esse conjunto de 30% de dados aleatórios para a validação foi o mesmo para os quatro casos mostrados. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste linear, calibrado/validado até 1000 mg/m³; (B) Algoritmo *Slope* do Mishra e Mishra (2010), com ajuste exponencial, calibrado/validado até 1000 mg/m³; (C) Algoritmo razão de bandas B6/B3, com ajuste polinomial, calibrado/validado até 1000 mg/m³; (D) Modelo Híbrido Óptico (MHO) considerando a classe 3 com valores até 1000 mg/m³. 72

Figura 4.11 - Desempenho dos algoritmos bio-ópticos que compõem o MHL após o processo de validação usando dados *in situ*. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste exponencial, calibrado/validado para a faixa de chl-*a* da classe óptica “OligoMeso”; (B) Algoritmo NDCI do Mishra e Mishra (2012), com ajuste polinomial, calibrado/validado para a faixa de chl-*a* da classe óptica “EutroSuper”; (C) Algoritmo razão de bandas B5/B3, com ajuste exponencial, calibrado/validado para a faixa de chl-*a*

da classe óptica “Hiper” até 600 mg/m³; (D) Algoritmo *Slope* do Mishra e Mishra (2010), com ajuste polinomial, calibrado/validado para a faixa de chl-*a* da classe óptica “Hiper” até 1000 mg/m³..... 74

Figura 4.12 - Desempenho dos algoritmos bio-ópticos que compõem o MHO após o processo de validação usando dados *in situ*. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste linear, calibrado/validado para a faixa de chl-*a* da classe óptica “Classe 1”; (B) Algoritmo *Slope* do Mishra e Mishra (2010), com ajuste exponencial, calibrado/validado para a faixa de chl-*a* da classe óptica “Classe 2”; (C) Algoritmo razão de bandas B5/B3, com ajuste exponencial, calibrado/validado para a faixa de chl-*a* da classe óptica “Classe 3” até 600 mg/m³; (C) Algoritmo razão de bandas B6/B3, com ajuste polinomial, calibrado/validado para a faixa de chl-*a* da classe óptica “Classe 3” até 1000 mg/m³..... 75

Figura 4.13 - Validação da correção atmosférica (A) sem a correção do *glint*, (B) com a correção do *glint* pela subtração da banda 11 do MSI/Sentinel-2 e (C) com a correção do *glint* pela subtração da banda 12 do MSI/Sentinel-2..... 76

Figura 4.14 - Validação do MHL_ate1000 (coluna esquerda: A, C, E) e MHO_ate1000 (coluna direita: B, D, F) na imagem do MSI/Sentinel-2 (13 agosto 2018) corrigida atmosféricamente: (A, B) sem a correção do *glint*, (C, D) com a correção do *glint* pela subtração da banda 11 e (E, F) com a correção do *glint* pela subtração da banda 12. Obs1: Para o MHL, Classe 1 = OligoMeso e Classe 2 = EutroSuper. Obs2: Os círculos azul, vermelho e laranja se referem às estações amostrais P1, P2 e P6, respectivamente, do campo de Agosto/2018. 79

Figura 4.15 – Validação do MHL a partir da imagem MSI/Sentinel-2, considerando a correção do *glint* com a subtração da banda 11. (A) MHL_ate600: usa os modelos referentes às faixas de chl-*a* das classes ópticas “OligoMeso”, “EutroSuper” e “Hiper_ate600”; (B) MHL_ate1000: usa os modelos referentes às faixas de chl-*a* das classes ópticas “OligoMeso”, “EutroSuper” e “Hiper_ate1000” (Tabela 4.3). Obs1: Classe 2 = EutroSuper. Obs2: O círculo vermelho enfatiza a estação amostral do campo de Agosto/2018 (P03) que provoca a pequena mudança dos valores estatísticos entre o MHL_ate600 e MHL_ate1000..... 80

Figura 4.16 - (A) Janela 3x3 pixels da estação amostral P03 do campo de Agosto/2018, com as classes ópticas estabelecidas pela árvore de decisão, e os (B) respectivos espectros

de R_{rs} com os valores estimados da concentração da chl-*a* (mg/m^3), considerando os algoritmos da “Classe 2” (“EutroSuper”) e “Classe 3” (“Hiper_ate600” e “Hiper_ate1000”; Tabela 4.3) do MHL, para cada pixel da janela. Obs1: os espectros de R_{rs} estão sem valores nos eixos, pois têm apenas a função de mostrar a forma espectral. Obs2.: nos valores de MHL_ate600 e MHL_ate1000 é considerada a correção do *glint* com a subtração da B11 do MSI/Sentinel-2, mas essa situação para o MHL também ocorre com a subtração da B12 e sem considerar a correção do *glint*..... 82

Figura 4.17 - Espacialização das classes ópticas (A) e da estimativa da concentração da chl-*a* (B) aplicando o MHL_ate1000 na imagem MSI/Sentinel-2, referente ao campo do dia 13 de agosto de 2018 no reservatório de Ibatinga. As classes 1, 2 e 3 indicam a presença de baixa (verde), média (amarela) e alta (vermelha) intensidade de floração no reservatório, respectivamente. Obs: Classe 1 = OligoMeso, Classe 2 = EutroSuper e Classe 3 = Hiper. 83

Figura 4.18 - Espacialização das classes ópticas (A) e da estimativa da concentração da chl-*a* (B) aplicando o MHO_ate1000 na imagem MSI/Sentinel-2, referente ao campo do dia 13 de agosto de 2018 no reservatório de Ibatinga. As classes 1, 2 e 3 indicam a presença de baixa (verde), média (amarela) e alta (vermelha) intensidade de floração no reservatório, respectivamente. Obs.: As classes 1, 2 e 3 são as respectivas classes ópticas do SAM. 84

Figura 4.19 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses dos anos 2016 e 2017 (conjunto 1). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente. 88

Figura 4.20 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses dos anos 2017 e 2018 (conjunto 2). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente. 89

Figura 4.21 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses do ano 2018 (conjunto 3). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente..... 90

Figura 4.22 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses dos anos 2018 e 2019 (conjunto 4). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.	91
Figura 4.23 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses do ano 2019 (conjunto 5). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.....	92
Figura 4.24 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses do ano 2019 (conjunto 6). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.....	93
Figura 4.25 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses dos anos 2016 e 2017 (conjunto 1).....	94
Figura 4.26 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses dos anos 2017 e 2018 (conjunto 2).....	95
Figura 4.27 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses do ano 2018 (conjunto 3).	96
Figura 4.28 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses dos anos 2018 e 2019 (conjunto 4).....	97
Figura 4.29 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses do ano 2019 (conjunto 5).	98
Figura 4.30 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses do ano 2019 (conjunto 6).	99
Figura 4.31 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” –	

Tabela 4.3) referente à estação amostral P1A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação média da chl- <i>a</i> em P1A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.	100
Figura 4.32 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3) referente à estação amostral P2A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação média da chl- <i>a</i> em P2A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.	100
Figura 4.33 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3) referente à estação amostral P3A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação média da chl- <i>a</i> em P3A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.	101
Figura 4.34 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3) referente à estação amostral P4A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação média da chl- <i>a</i> em P4A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.	101
Figura 4.35 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3) referente à estação amostral P5A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação média da chl- <i>a</i> em P5A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.	102
Figura 4.36 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3) referente à estação amostral P6A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação	

média da chl- <i>a</i> em P6A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.	102
Figura 4.37 – Análise temporal do valor mínimo, máximo e médio da concentração de chl- <i>a</i> estimada pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), para todo o reservatório de Ibitinga. Esses valores abrangem uma representatividade de 96% dos dados de chl- <i>a</i> estimada, pois os <i>outliers</i> foram excluídos desconsiderando os percentis dos 2% iniciais e finais do conjunto de dados.	103
Figura 4.38 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.25), referente aos meses dos anos 2016 e 2017 (conjunto 1).....	104
Figura 4.39 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.26), referente aos meses dos anos 2017 e 2018 (conjunto 2).....	105
Figura 4.40 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.27), referente aos meses do ano 2018 (conjunto 3).	106
Figura 4.41 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.28), referente aos meses dos anos 2018 e 2019 (conjunto 4).....	107
Figura 4.42 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.29), referente aos meses do ano 2019 (conjunto 5).	108
Figura 4.43 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.30), referente aos meses do ano 2019 (conjunto 6).	109
Figura 4.44 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses dos anos 2016 e 2017 (conjunto 1). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.....	114
Figura 4.45 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses dos anos 2017 e 2018 (conjunto 2). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.....	115

Figura 4.46 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses do ano 2018 (conjunto 3). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.....	116
Figura 4.47 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses dos anos 2018 e 2019 (conjunto 4). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.....	117
Figura 4.48 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses do ano 2019 (conjunto 5). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.....	118
Figura 4.49 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses do ano 2019 (conjunto 6). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.....	119
Figura 4.50 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses dos anos 2016 e 2017 (conjunto 1).....	120
Figura 4.51 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses dos anos 2017 e 2018 (conjunto 2).....	121
Figura 4.52 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses do ano 2018 (conjunto 3).	122
Figura 4.53 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses dos anos 2018 e 2019 (conjunto 4).....	123
Figura 4.54 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses do ano 2019 (conjunto 5).	124

Figura 4.55 – Mapa de concentração de chl- <i>a</i> gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses do ano 2019 (conjunto 6).	125
Figura 4.56 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P1A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação média da chl- <i>a</i> em P1A ao longo dos anos.	126
Figura 4.57 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P2A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação média da chl- <i>a</i> em P2A ao longo dos anos.	126
Figura 4.58 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P3A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação média da chl- <i>a</i> em P3A ao longo dos anos.	127
Figura 4.59 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P4A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação média da chl- <i>a</i> em P4A ao longo dos anos.	127
Figura 4.60 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P5A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação média da chl- <i>a</i> em P5A ao longo dos anos.	128
Figura 4.61 – Análise temporal das classes ópticas e da concentração da chl- <i>a</i> geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P6A da Figura 3.12. Os pontos pretos pequenos	

mostram o valor médio mensal de chl- <i>a</i> e a linha preta pontilhada a tendência de variação média da chl- <i>a</i> em P6A ao longo dos anos.	128
Figura 4.62 – Análise temporal do valor mínimo, máximo e médio da concentração de chl- <i>a</i> estimada pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), para todo o reservatório de Ibitinga. Esses valores abrangem uma representatividade de 96% dos dados de chl- <i>a</i> estimada, pois os <i>outliers</i> foram excluídos desconsiderando os percentis dos 2% iniciais e finais do conjunto de dados.	129
Figura 4.63 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.50), referente aos meses dos anos 2016 e 2017 (conjunto 1).....	130
Figura 4.64 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.51), referente aos meses dos anos 2017 e 2018 (conjunto 2).....	131
Figura 4.65 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.52), referente aos meses do ano 2018 (conjunto 3).	132
Figura 4.66 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.53), referente aos meses dos anos 2018 e 2019 (conjunto 4).....	133
Figura 4.67 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.54), referente aos meses do ano 2019 (conjunto 5).	134
Figura 4.68 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl- <i>a</i> (Figura 4.55), referente aos meses do ano 2019 (conjunto 6).	135
Figura 5.1 - Análise da mudança da cor da água, do comportamento espectral da R_{rs} e da variação espectral do a_{phy} , a_{nap} e a_{cdom} para as três classes ópticas geradas usando os métodos limnológicos e óptico: (A) Estação P1 de maio/2014, presente nas classes ópticas “OligoMeso” e “Classe 1”; (B) Estação P1 de julho/2014, presente nas classes ópticas “EutroSuper” e “Classe 2”; e (C) Estação P1 de fevereiro/2014, presente nas classes ópticas “Hiper” e “Classe 3”. Obs1: no canto direito de (A) é a R_{rs} com uma escala ampliada, para enfatizar a forma do espectro em relação à (B) e (C). Obs2: em (C) a escala da absorção está diferente de (A) e (B).	136

Figura 5.2 – (A) Exemplos de espectros (R_{rs} <i>in situ</i> simulada para as bandas do MSI/Sentinel-2) de transição entre as classes 1 (linha laranja) e 2 (linha verde) do SAM, com valores de concentração de chl- <i>a</i> (mg/m^3) próximos; e de (B) espectros de R_{rs} <i>in situ</i> simulado (linha vermelha) e derivado de satélite (linha roxa) da estação amostral “P6_Aug_2018”, mostrando o valor da concentração da chl- <i>a</i> <i>in situ</i> (vermelha) e estimada pela imagem (roxa).....	141
Figura 5.3 - Variabilidade da cor da água no reservatório de Ibitinga para (A) 12/08/2018 (OLI/Landsat-8, RGB composição das bandas 4-3-2) e (B) 13/08/2018 (MSI/Sentinel-2, RGB composição das bandas 4-3-2). Ambas imagens possuem o mesmo contraste aplicado. Os pontos se referem às estações amostrais P1, P2 e P6 coletadas no campo de Agosto/2018.....	150
Figura 5.4 – (A) Imagem RGB MSI/Sentinel-2 do dia 17/09/2016 (composição das bandas 4-3-2); os pontos amarelos (P1B a P6B) foram obtidos de maneira aleatória para realizar a análise. (B) Espectros de R_{rs} da imagem MSI/Sentinel-2 em três tipos de condições: i) sem correção atmosférica e correção do <i>glint</i> (subtração B11); ii) somente com correção atmosférica; e iii) com correção atmosférica e correção do <i>glint</i> (subtração B11).....	154
Figura A.1 – Gráficos de dispersão da validação da Monte Carlo para os algoritmos de melhor desempenho do MHL (Tabela 4.3), em cada faixa específica de concentração da chl- <i>a</i> . Os algoritmos são: (A) três bandas do Gitelson et al. (2011a) com ajuste exponencial; (B) NDCI do Mishra e Mishra (2012) com ajuste polinomial; (C) razão B5/B3 com ajuste exponencial e (D) <i>Slope</i> do Mishra e Mishra (2010) com ajuste polinomial.....	174
Figura A.2 – Gráficos de dispersão da validação da Monte Carlo para os algoritmos de melhor desempenho do MHO (Tabela 4.3), em cada faixa específica de concentração da chl- <i>a</i> . Os algoritmos são: (A) três bandas do Gitelson et al. (2011a) com ajuste linear; (B) <i>Slope</i> do Mishra e Mishra (2010) com ajuste exponencial; (C) razão B5/B3 com ajuste exponencial e (D) razão B6/B3 com ajuste polinomial.	175
Figura A.3 – Resultado da validação do algoritmo NDCI de Mishra e Mishra (2012) para uma faixa mais ampla de concentração de chl- <i>a</i> , até $600 \text{ mg}/\text{m}^3$. Sendo: MAPE (%), RMSE (mg/m^3) e NRMSE (%).	175

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 - Valores parâmetros do IET de Carlson	9
Tabela 2.2 - Classificação do IET de Carlson	9
Tabela 2.3 - Classificação do IET de Toledo	10
Tabela 2.4 - Classificação do IET de Lamparelli para reservatórios tropicais.....	11
Tabela 2.5 - Classificação do IET de Cunha e colaboradores para reservatórios tropicais/subtropicais.....	12
Tabela 3.1 - Informações sobre as campanhas de campo	35
Tabela 3.2 - Tipos e equações dos algoritmos bio-ópticos para a estimativa da concentração da chl- <i>a</i> baseado nas bandas do MSI/Sentinel-2, em que λ_1 , λ_2 , λ_3 , e λ_4 são B3 (560 nm), B4 (665 nm), B5 (705 nm) e B6 (740 nm), respectivamente. λ_x e λ_y se referem a combinação de bandas “B4 e B3”, “B5 e B3”, “B5 e B4”, “B6 e B3”, e “B6 e B4”.....	42
Tabela 3.3 – Especificações das bandas do sensor MSI/Sentinel-2. SNR é a relação sinal ruído, e L_{ref} é a radiância de referência.	43
Tabela 4.1 - Resultado da divisão do conjunto de valores de concentração de chl- <i>a</i> em faixas específicas de concentração.	59
Tabela 4.2 – Resultado estatístico (R^2) da análise exploratória para cada classe óptica dos métodos limnológico e óptico, considerando os algoritmos bio-ópticos de melhor desempenho para cada faixa específica de concentração de chl- <i>a</i> . Sendo: Lin é ajuste linear, Pol é ajuste polinomial, Exp é ajuste exponencial.	60
Tabela 4.3 - Resultado da validação pela Monte Carlo; algoritmos bio-ópticos de melhor desempenho para cada faixa específica de concentração da chl- <i>a</i> geradas pelos métodos limnológico e óptico. Sendo: N é número de amostras usado para na validação, Lin é ajuste linear, Pol é ajuste polinomial, Exp é ajuste exponencial, MAPE (%), RMSE (mg/m^3) e NRMSE (%).	61
Tabela 4.4 - Resultado da validação pela Monte Carlo, usando os algoritmos bio-ópticos de melhor desempenho da Tabela 4.3 para faixas mais amplas de concentração de chl- <i>a</i> , até $600 \text{ mg}/\text{m}^3$ e até $1000 \text{ mg}/\text{m}^3$. Sendo: Lin é ajuste linear, Pol é ajuste polinomial, Exp é ajuste exponencial, MAPE (%), RMSE (mg/m^3) e NRMSE (%).	62

Tabela 4.5 - Avaliação do desempenho de classificação da árvore de decisão para cada modelo híbrido usando dados <i>in situ</i>	65
Tabela 4.6 - Desempenho da correção atmosférica, com e sem a correção do <i>glint</i> , para a estimativa da R_{rs} ($n = 8$), considerando separadamente as bandas do MSI/Sentinel-2..	77
Tabela A.1 – Resultado da validação do MHL e MHO com a imagem MSI/Sentinel-2, considerando as 8 estações amostrais do campo de Agosto/2018. Sendo: MAPE (%), RMSE (mg/m^3) e NRMSE (%).	176
Tabela A.2 – Frequência de imagens por mês do MSI/Sentinel-2 para os anos de 2016 a 2019.	176

LISTA DE SIGLAS E ABREVIATURAS

APA	Área de Proteção Ambiental
BIOEN	Environmental and Socioeconomic Impacts Associated with the Production and Conception of Sugar Cane Ethanol in South Central Brazil
CETESB	Companhia Ambiental do Estado de São Paulo
CDOM	Colored Dissolved Organic Matter
COA	Componentes Ópticamente Ativos
EUA	Estados Unidos da América
FAPESP	Fundação de Amparo à Pesquisa do Estado de São Paulo
FLH	Fluorescence Line Height
FRB	Fator de Reflectância Bidirecional
HAB	Harmful Algal Bloom
HICO	Hyperspectral Imager for the Coastal Ocean
IET	Índice de Estado Trófico
LABISA	Laboratório de Instrumentação de Sistemas Aquáticos
LUT	Look-up-Table
MARD	Median Absolute Relative Difference
MAPAQUALI	Monitoramento da qualidade de águas interiores por satélite
MAPE	Mean Absolute Percentage Error
MCI	Maximum Chlorophyll Index
MERIS	Medium Resolution Imaging Spectrometer
MHL	Modelo Híbrido Limnológico
MHO	Modelo Híbrido Óptico
MNDWI	Modified Normalized Difference Water Index
MODIS	Moderate-Resolution Imaging Spectroradiometer
MPH	Maximum Peak-Height
MSI	Multispectral Instrument
NAP	Non-Algal Particles
NDCI	Normalized Difference Chlorophyll Index
NIR	Near-infrared
NMAE	Normalized Mean Absolute Error
NRMSE	Normalized Root Mean Square Error
OC	Ocean Color

OLCI	Ocean and Land Colour Instrument
OLI	Operational Land Imager
OWT	Optical Water Type
PAR	Photosynthetically Active Radiation
POA	Propriedade Óptica Aparente
POI	Propriedade Óptica Inerente
QAA	Quasi-Analytical Algorithm
REM	Radiação Eletromagnética
RGB	Red-Green-Blue / cor verdadeira
RGCI	Red Green Chl-a Index
RMSE	Root Mean Square Error
SAM	Spectral Angle Mapper
SeaBASS	SeaWiFS Bio-optical Archive and Storage System
SeaWiFS	Sea-viewing Wide Field-of-view Sensor
SNR	Signal-to-Noise Ratio
SP	São Paulo
SR	Sensoriamento Remoto
SWIR	Shortwave Infrared
TM	Thematic Mapper
UGRHI	Unidade de Gerenciamento de Recursos Hídricos
UHE	Usina Hidrelétrica
USGS	United States Geological Service

LISTA DE SÍMBOLOS

A	Atributo de entrada
a_{cdom}	Coefficiente de absorção do CDOM
a_{nap}	Coefficiente de absorção do NAP
a_{phy}	Coefficiente de absorção do fitoplâncton
a_{phy}^*	Coefficiente de absorção específico do fitoplâncton
$\text{chl-}a$	Concentração de clorofila- a
d	Grau de similaridade
E_s	Irradiância incidente na superfície da água
Exp	Ajuste exponencial
F_n	Número de falsos negativos
F_p	Número de positivos falsos
FR	Fator de reflectância
ha	Hectare
i	Número de espectros contidos no conjunto de amostras
j	Número de espectros de referência que serão utilizados para comparação
k	Número de elementos ou bandas da cura espectral
L_a	Radiância da amostra
L_F	Radiância da banda de fluorescência
L_L	Radiância da linha de base esquerda
L_R	Radiância da linha de base direita
L_r	Radiância de uma superfície lambertiana
L_s	Radiância difusa na atmosfera
L_w	Radiância emergente da coluna d'água
lat	Latitude
Lin	Ajuste Linear
long	Longitude
P	Concentração de fósforo total
$p(i/t)$	Fração de registros que pertencem à classe i em um determinado nodo t
Pol	Ajuste Polinomial
PSI	Fotossistema I
PSII	Fotossistema II
r	Espectro de referência

R^2	Coeficiente de determinação
RL_w	Reflectância radiância emergente da água
R_{rs}	Reflectância de sensoriamento remoto
$R_{rs_atmcorr}$	Reflectância de sensoriamento remoto corrigida atmosféricamente
R_{rs_insitu}	Reflectância de sensoriamento remoto medida em campo
R_{rs_simul}	Reflectância de sensoriamento remoto simulada
SD	Profundidade do disco de secchi
SRF	Spectral response function
t	Espectro teste
x_i	Valor da concentração da chl- <i>a</i> obtido <i>in situ</i> para a estação <i>i</i>
x_{max}	Valor máximo de concentração da chl- <i>a</i> do conjunto de dados
x_{min}	Valor mínimo de concentração da chl- <i>a</i> do conjunto de dados
y_i	Valor estimado da concentração da chl- <i>a</i> para a estação <i>i</i>
π	Pi
ρ_{BRmax}	Valores máximos de reflectância nos comprimentos de onda de 681 nm, 709 nm ou 753 nm
ρ_{BR664}	Valor de reflectância em 664 nm
ρ_{BR885}	Valor de reflectância em 885 nm
λ	Comprimento de onda
λ_{max}	Comprimento de onda máximo
λ_F	Comprimento de onda central da banda de fluorescência
λ_L	Comprimento de onda central da banda de linha de base esquerda
λ_R	Comprimento de onda central da banda de linha de base direita
ν	Divisões
6S	Second Simulation Of The Satellite Signal In The Solar Spectrum

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Hipótese	6
1.2 Objetivo	6
1.2.1 <i>Objetivo geral</i>	6
1.2.2 <i>Objetivos específicos</i>	6
2 FUNDAMENTAÇÃO TEÓRICA	7
2.1 Eutrofização	7
2.2 Monitoramento do estado trófico da água.....	8
2.3 Modelos bio-ópticos de estimativa da concentração da chl- <i>a</i>	15
2.3.1 <i>Abordagem baseada na absorção</i>	15
2.3.2 <i>Abordagem baseada na fluorescência</i>	18
2.3.3 <i>Abordagem baseada no espalhamento</i>	20
2.4 Abordagem híbrida para a estimativa da concentração da chl- <i>a</i>	25
3 MATERIAL E MÉTODOS	30
3.1 Área de estudo	31
3.2 Conjunto de dados <i>in situ</i>	33
3.3 Classificação limnológica e espectral.....	39
3.4 Algoritmos bio-ópticos de estimativa da concentração da chl- <i>a</i>	42
3.5 Calibração e validação dos algoritmos bio-ópticos	43
3.6 Construção dos modelos híbridos	47
3.7 Validação dos modelos híbridos com dados <i>in situ</i>	51
3.8 Aplicação dos modelos híbridos na imagem MSI/Sentinel-2	51
3.8.1 <i>Correção atmosférica e correção do glint - validação</i>	51
3.8.2 <i>Validação dos modelos híbridos na imagem MSI/Sentinel-2</i>	52
3.8.3 <i>Análise temporal das classes ópticas, da concentração da chl-<i>a</i> e do estado trófico</i>	53
4 RESULTADOS	57
4.1 Classes ópticas	57

4.2 Avaliação dos algoritmos bio-ópticos de chl- <i>a</i> para cada faixa específica de concentração de chl- <i>a</i>	59
4.3 Árvore de decisão para detectar as classes ópticas	63
4.4 Estrutura dos modelos híbridos e validação <i>in situ</i>	65
4.5 Avaliação da correção atmosférica e validação dos modelos híbridos a partir da imagem MSI/Sentinel-2	75
4.6 Série temporal das classes ópticas, concentração da chl- <i>a</i> e estado trófico	84
5 DISCUSSÃO DOS RESULTADOS	136
5.1 Propriedades ópticas das classes ópticas	136
5.2 Avaliação da divisão das faixas específicas de concentração da chl- <i>a</i>	138
5.3 Comparações dos algoritmos bio-ópticos de chl- <i>a</i>	142
5.4 Avaliação da estrutura dos modelos híbridos	145
5.5 Análise temporal – comparação entre o MHL e MHO – limitações	151
6 CONCLUSÕES	157
REFERÊNCIAS BIBLIOGRÁFICAS	160
APÊNDICE A – FIGURAS E TABELAS COMPLEMENTARES	174

1 INTRODUÇÃO

Reservatórios são sistemas de transição entre rios e lagos, criados a partir do represamento de um rio. Por serem ecossistemas de funcionamento complexo, estão sujeitos a rápidas mudanças em suas variáveis bióticas e abióticas, devido à variabilidade natural do ambiente, a mudanças no uso e cobertura da terra da bacia de drenagem, bem como às demandas de seus recursos hídricos (MARGALEF, 1975; WETZEL, 2001). Suas principais funções são geração de energia, abastecimento público, controle de inundações e irrigação (TUNDISI, 1999).

Já na década de 1970, o desenvolvimento industrial e o crescimento urbano intenso e desorganizado têm afetado os processos ecossistêmicos dos reservatórios, especialmente a preservação da qualidade da água (BRANCO; ROCHA, 1977). Esses fatores antropogênicos promovem a eutrofização da água, principalmente devido ao enriquecimento por nutrientes causado pelas descargas de esgotos doméstico e industrial dos centros urbanos e pelo escoamento das regiões agrícolas (AZEVEDO; VASCONCELOS, 2006). Esses altos insumos de nutrientes ao longo do tempo prejudicam a qualidade da água, levando a aumentos na produção primária, na frequência de florações de cianobactérias e na mortalidade de peixes (AZEVEDO; VASCONCELOS, 2006; RANDOLF et al., 2008). Além disso, a interação entre mudança climática e eutrofização pode, em breve, aumentar a dominância das cianobactérias e diminuir a biodiversidade do fitoplâncton (RIGOSI et al., 2014). Assim, os reservatórios podem perder seus múltiplos usos e se tornarem graves ameaças à saúde pública. Portanto, para uma melhor governança dos recursos hídricos interiores e para cumprir as metas do milênio, é essencial melhorar o monitoramento da qualidade da água nos reservatórios (ONDA et al., 2012).

A viabilidade do uso do sensoriamento remoto (SR) para o monitoramento e gerenciamento dos sistemas aquáticos tem sido amplamente avaliada, pois alguns componentes utilizados na avaliação da qualidade da água (Componentes Ópticamente Ativos – COAs: fitoplâncton, material em suspensão e matéria orgânica dissolvida colorida (CDOM)) interagem com a radiação eletromagnética (REM) nas regiões do visível e infravermelho próximo (NIR), mudando a cor da água (KIRK, 2011). Associado

às medições *in situ*, o SR pode ser uma ferramenta essencial para o monitoramento de ameaças ambientais, como a eutrofização e a proliferação de algas nocivas (*Harmful Algae Blooms*, HABs, em inglês), fornecendo, portanto, informações para apoiar novas estratégias de gestão sustentável dos ecossistemas aquáticos (BRIVIO et al., 2001; GURLIN et al., 2011). Além disso, o SR também oferece vantagens substanciais sobre os métodos tradicionais de monitoramento, principalmente devido à cobertura sinóptica dos dados e à consistência temporal (MATTHEWS, 2011).

O uso do SR no monitoramento do estado trófico da água é baseado no fato de que as consequências do processo de eutrofização, como o aumento da produtividade fitoplanctônica, estão associadas a mudanças nas propriedades ópticas da água (BABAN, 1996). Assim, o SR é estabelecido como uma importante fonte de informação para determinar o estado trófico das águas interiores por meio da estimativa de parâmetros da qualidade da água opticamente ativos, como a concentração da clorofila-*a* (*chl-a*; pigmento fotossintético presente em todas as espécies de fitoplâncton (REYNOLDS, 2006)) (WANG et al., 2018). A *chl-a* é o parâmetro mais comumente derivado no SR da qualidade da água, principalmente porque é o índice mais abrangente do estado trófico do sistema aquático (NOVO et al., 2013; THIEMANN; KAUFMANN, 2000; WEZERNAK et al., 1976). Além disso, a concentração da *chl-a* pode ser usada como *proxy* da biomassa fitoplanctônica (MATTHEWS, 2017; O'REILLY et al., 2000).

A *chl-a* é estimada por SR a partir de algoritmos bio-ópticos. Recentemente, estudos mostraram que os algoritmos bio-ópticos usados na estimativa da *chl-a* apresentam melhor desempenho quando calibrados para faixas específicas de concentração de *chl-a* (MATSUSHITA et al., 2015; ODERMATT et al., 2012; SMITH et al., 2018). No SR da cor da água, algoritmos baseados na relação entre a reflectância nas regiões espectrais do azul e verde (*blue-green ratio*) são destinados a águas oceânicas (O'REILLY et al., 1998), em que o CDOM não mascara as feições de absorção da *chl-a* na região do azul (CARDER et al., 1999). Entretanto, alguns tipos de algoritmos *blue-green ratio* foram aplicados com sucesso para estimar a concentração da *chl-a* na faixa de 0-10 mg/m³ em águas opticamente complexas, em que as propriedades ópticas da água das áreas de estudo analisadas se assemelhavam às de águas oceânicas. Já os algoritmos baseados na relação

entre as bandas do vermelho e NIR (*red-NIR ratio*) são mais adequados para estimar concentrações de chl-*a* acima de 10 mg/m³ em ambientes mais eutrofizados (ODERMATT et al., 2012).

Nas águas interiores tropicais brasileiras, estudos usando um único algoritmo para estimar a concentração de chl-*a* forneceram resultados satisfatórios em uma faixa específica de chl-*a* (AUGUSTO-SILVA et al., 2014; FLORES JR. et al., 2019; LINS et al., 2017; SANDER DE CARVALHO et al., 2019; WATABABE et al., 2015, 2018). Como exemplo, Augusto-Silva et al. (2014) usaram algoritmos bio-ópticos *red-NIR* para estimar a concentração de chl-*a* no reservatório de Funil (Rio de Janeiro). Entretanto, os algoritmos divergem da linha 1:1 à medida que a concentração de chl-*a* aumenta para 20 µg·L⁻¹, com um erro mais significativo além desse valor. Com esses resultados, os autores concluíram que deve haver dois tipos de algoritmos para estimar e fornecer valores mais precisos de concentração de chl-*a*, no caso um algoritmo para o que eles chamam de "condições normais" e outro para "condições de floração".

Além disso, Watanabe et al. (2015) mostraram, em um trabalho realizado no reservatório de Barra Bonita/SP, que o algoritmo polinomial *NIR-Green* subestimou as altas concentrações da chl-*a* e superestimou as baixas concentrações, prejudicando a classificação do estado trófico. Portanto, um único algoritmo não consegue lidar com precisão com a ampla faixa de concentração de chl-*a* em águas opticamente complexas sujeitas a diferentes estados tróficos. Isso porque esses sistemas são caracterizados por uma mistura complexa de COAs e uma ampla gama de propriedades ópticas (ANDRADE et al., 2018).

Devido às constantes mudanças nas condições ambientais causadas por fatores naturais ou antrópicos, as propriedades ópticas de um sistema aquático podem apresentar uma alta variabilidade espaço-temporal (GIARDINO et al., 2019). Essa grande variabilidade óptica faz com que as águas opticamente complexas apresentem comportamentos espectrais bem diferentes, resultando em alta variabilidade de formas espectrais e de intensidade da reflectância de sensoriamento remoto (R_{rs}). Assim, vários tipos ópticos de água podem estar presentes simultaneamente no mesmo sistema aquático ou entre

sistemas aquáticos distintos, tendo águas dominadas por fitoplâncton, material total em suspensão, CDOM, ou por suas diversas combinações possíveis (FENG et al., 2005; LE et al., 2011; LUBAC; LOISEL, 2007; MOORE et al., 2014; SHI et al., 2013). Como resultado de toda essa complexidade óptica, estimativas precisas da concentração de chl-*a* por SR em águas interiores são desafiadoras (ANSPER; ALIKAS, 2019; LIU et al., 2020; TILSTONE et al., 2012).

De forma a superar esse desafio, os estudos mencionados fornecem suporte teórico para o desenvolvimento de uma abordagem operacionalmente definida como híbrida para a estimativa da concentração da chl-*a* em águas interiores sujeitas a diferentes níveis tróficos. A abordagem híbrida alterna entre algoritmos específicos para diferentes faixas de concentração de chl-*a*, tendo, por exemplo, um algoritmo para representar cada conjunto de comportamento espectral proveniente, principalmente, da variação da chl-*a* na água. Segundo Smith et al. (2018), o monitoramento operacional da concentração da chl-*a* de um sistema aquático caracterizado por elevada variabilidade de estado trófico seria beneficiado por uma abordagem dinâmica baseada no uso de algoritmos compatíveis com as características ópticas dominantes e com as variações *in situ* da biomassa fitoplanctônica.

Assim, o uso da abordagem híbrida seria mais adequado para estimar a concentração da chl-*a* em reservatórios tropicais, uma vez que o estado trófico varia amplamente no espaço e no tempo, num mesmo sistema aquático e entre sistemas aquáticos distintos, em função de forçantes climáticas, hidrológicas, hidrodinâmicas e antropogênicas. Nesse contexto, o desafio dessa pesquisa foi desenvolver e testar uma abordagem híbrida para o monitoramento sistemático da chl-*a* em reservatórios hidroelétricos a partir de imagens MSI/Sentinel-2.

A área de estudo desta pesquisa é o reservatório da Usina Hidrelétrica de Ibitinga (UHE-Ibitinga), que é o terceiro reservatório tropical de um sistema em cascata construído ao longo do Rio Tietê. Por ser um reservatório de regulação, o funcionamento da barragem controla a dinâmica hidráulica e trófica do reservatório, gerando uma elevada variabilidade espaço-temporal das propriedades ópticas e limnológicas (chl-*a* ~ 3-1000

mg/m³). Estudos anteriores realizados no reservatório de Ibitinga (LONDE, 2008; NOVO et al., 2013; LONDE et al., 2016; Projeto BIOEN - *Environmental and Socioeconomic Impacts Associated with the Production and Conception of Sugar Cane Ethanol in South Central Brazil* – FAPESP 08/56252-0) foram baseados em um único algoritmo de estimativa da concentração da chl-*a* para todo o reservatório, sendo o algoritmo calibrado e validado usando dados adquiridos em apenas uma campanha de campo. Portanto, o algoritmo não consegue capturar com precisão mudanças sazonais no estado trófico do reservatório. O presente estudo se concentrou em romper essa limitação, combinando algoritmos bio-ópticos e critérios de seleção de algoritmos usando a abordagem híbrida. Além disso, utilizou um banco de dados composto por medições adquiridas em diferentes estações do ano e anos hidrológicos, representando uma ampla gama de condições ópticas, limnológicas e tróficas do reservatório de Ibitinga.

Este estudo teve como pretensão dar continuidade à linha de pesquisa desenvolvida no projeto BIOEN, de forma a aprimorar a avaliação espaço-temporal da eutrofização nos sistemas aquáticos interiores do Brasil em resposta à expansão da cana-de-açúcar usando imagens de satélite. Além disso, a motivação deste trabalho foi desenvolver uma metodologia para auxiliar na implementação de um sistema de monitoramento da qualidade da água de reservatórios tropicais por SR. Assim, a qualidade trófica da água deixaria de ter uma visão pontual e passaria a ter uma visão espaço-temporal, proporcionando ao gestor um maior subsídio no planejamento de programas de conservação, gerenciamento e recuperação de represas.

É importante ressaltar também que como o reservatório de Ibitinga possui predominância de florações de cianobactérias (principalmente *Microcystis aeruginosa*) (LONDE, 2008), no espaço e no tempo, o nível de estado trófico poderia ser utilizado como uma medida indireta da densidade fitoplanctônica. Dessa forma, a espacialização do estado trófico poderia indicar os locais de maior risco de contaminação pelas toxinas produzidas pelas cianobactérias (CHORUS; BARTRAM, 1999), auxiliando os gestores em questões de balneabilidade do reservatório, indicação dos melhores pontos de captação de água para a agricultura/indústria e abastecimento de cidades e criação de políticas ambientais e de

saúde pública. Além disso, uma estimativa mais precisa da concentração da chl-*a* por SR pode ser útil também para estudos de estimativas de balanço de carbono.

1.1 Hipótese

A hipótese do presente estudo é que é possível ter uma melhor descrição espaço-temporal da concentração da chl-*a* e da condição trófica da água por SR a partir de uma abordagem híbrida.

1.2 Objetivo

1.2.1 Objetivo geral

O objetivo geral deste estudo foi desenvolver uma metodologia baseada em SR para monitorar o estado trófico em reservatórios tropicais, no espaço e no tempo. Como área teste selecionou o reservatório da UHE de Ibitinga/SP.

1.2.2 Objetivos específicos

Para atender ao objetivo geral deste trabalho, foram identificados os seguintes objetivos específicos:

- Construir uma base de dados ópticos e limnológicos padronizados, representativos de diferentes condições hidrológicas, sazonais e métodos de aquisição, e que abrangem elevada amplitude de estados tróficos e características bio-ópticas;
- Avaliar métodos para identificar classes ópticas baseadas na concentração de chl-*a* a partir de medidas de R_{rs} ;
- Calibrar, validar e selecionar algoritmos bio-ópticos específicos adequados às faixas específicas de concentração da chl-*a* identificadas;
- Desenvolver uma estrutura híbrida que permita alternar entre os algoritmos selecionados de acordo com as classes de faixas específicas de chl-*a*;
- Aplicar e validar os modelos híbridos em imagens MSI/Sentinel-2;
- Gerar e analisar uma série temporal das classes ópticas, da concentração da chl-*a* e da classificação do estado trófico da CETESB no reservatório de Ibitinga.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Eutrofização

Eutrofização é o aumento da concentração de nutrientes (principalmente fósforo e nitrogênio) nos ambientes aquáticos, tendo como consequência o crescimento excessivo do fitoplâncton e de plantas aquáticas, em níveis tais que sejam considerados como causadores de interferências com os usos desejáveis do corpo d'água (THOMANN; MUELLER, 1987).

A eutrofização pode ser um processo natural ou artificial. Quando natural, é um processo lento e contínuo que resulta do aporte de nutrientes trazidos pelas chuvas e pelas águas superficiais que erodem e lavam a superfície terrestre, correspondendo ao "envelhecimento natural" do corpo d'água. Quanto artificial (também denominada cultural ou antrópica), é um processo de origem antrópica em que o aporte de nutrientes é proveniente de efluentes industriais, efluentes domésticos e atividades agrícolas, causando o "envelhecimento precoce" do corpo d'água (ESTEVES, 1998).

O processo de eutrofização artificial causa profundas modificações qualitativas e quantitativas na estrutura biológica, física e química do sistema aquático, como por exemplo frequentes florações de algas, mau odor, anaerobiose, aumento da turbidez, mortandade de peixes e diminuição da diversidade de espécies. Além disso, pode causar maior dificuldade e elevação nos custos de tratamento da água, redução na navegação e capacidade de transporte, problemas graves de saúde na população pela toxicidade das algas (neurotoxinas e hepatotoxinas), como por exemplo as cianobactérias, prejudicar o uso da água para recreação e produção de energia (ARCEIVALA, 1981; SINHA et al., 2017; THOMANN; MUELLER, 1987; VON SPERLING, 1994).

O nível de eutrofização esta usualmente associado ao uso e ocupação do solo predominante na bacia de drenagem do corpo d'água, podendo ser classificado como oligotrófico (águas claras e com baixa produtividade), mesotrófico (produtividade intermediária), eutrófico (elevada produtividade) e hipereutrófico (produtividade excessiva, formação de escumas de fitoplâncton) (SALAS; MARTINO, 2003).

2.2 Monitoramento do estado trófico da água

O Índice de Estado Trófico (IET) foi desenvolvido com o objetivo de resumir os parâmetros da qualidade da água, que se relacionam diretamente com o processo de eutrofização, em um número que possibilite caracterizar o estágio de eutrofização de um corpo d'água no espaço e no tempo (VON SPERLING, 2005). Esse índice fornece uma visão sobre como a disponibilidade de nutrientes e luz controla o desenvolvimento do fitoplâncton (CUNHA et al., 2013). Além disso, funciona como um registro das atividades humanas nas bacias hidrográficas, possibilitando a tomada de medidas preventivas e/ou corretivas do processo de eutrofização, bem como permitir o planejamento e usos das bacias (MAIA et al., 2015).

A base da fundamentação conceitual do IET é que nos sistemas aquáticos o grau de eutrofização está relacionado com o aumento da concentração de nutrientes na água, sendo o fósforo o principal nutriente responsável. Assim, o aumento da concentração de fósforo leva ao aumento da quantidade de florações de algas, estimada a partir da concentração da chl-*a*, e a diminuição da transparência da água, medida pelo disco de Secchi (OLEM; FLOCK, 1990).

Carlson (1977) desenvolveu o IET (Tabelas 2.1 e 2.2) como uma escala numérica contínua (de 0 a 100) para avaliar o estado trófico, sendo que cada divisão (0, 10, 20...) representa a capacidade de dobrar a biomassa algal, e propôs três equações baseadas na concentração de fósforo total (Equação 2.1 - P é a concentração de fósforo em mg/m³), concentração da chl-*a* (Equação 2.2 - chl-*a* é a concentração de clorofila-*a* em mg/m³) e na transparência da água (Equação 2.3 - SD é o valor de transparência em metros). O IET pode ser calculado separadamente para cada um dos parâmetros ou como média dos três valores. Além disso, esse índice foi desenvolvido para lagos e reservatórios de regiões temperadas do hemisfério norte que tem limitação de fósforo, e é um dos índices mais usados para a classificação da qualidade da água pela sua simplicidade e objetividade (FIA et al., 2009).

$$IET_{transparência} = 10 \times \left[6 - \left(\frac{\ln(SD)}{\ln 2} \right) \right] \quad (2.1)$$

$$IET_{fósforo\ total} = 10 \times \left[6 - \left(\frac{\ln\left(\frac{48}{P}\right)}{\ln 2} \right) \right] \quad (2.2)$$

$$IET_{clorofila-a} = 10 \times \left[6 - \left(\frac{2,04 - 0,68 \ln(Chl-a)}{\ln 2} \right) \right] \quad (2.3)$$

Tabela 2.1 - Valores parâmetros do IET de Carlson

IET	Profundidade Secchi (m)	Fósforo Superficial (mg/m³)	Clorofila Superficial (mg/m³)
0	64	0,75	0,04
10	32	1,5	0,12
20	16	3	0,34
30	8	6	0,94
40	4	12	2,6
50	2	24	6,4
60	1	48	20
70	0,5	96	56
80	0,25	192	154
90	0,12	384	427
100	0,062	768	1183

Fonte: Carlson (1977).

Tabela 2.2 - Classificação do IET de Carlson.

Categoria Estado Trófico	IET
Ultra oligotrófico	IET < 20
Oligotrófico	21 < IET ≤ 40
Mesotrófico	41 < IET ≤ 50
Eutrófico	51 < IET ≤ 60
Hipereutrófico	IET > 61

Fonte: Carlson (1977).

De forma a adaptar o IET desenvolvido por Carlson (1977) para regiões tropicais, Toledo et al. (1983, 1984) propuseram modificações no cálculo do IET (Equações 2.4, 2.5 e 2.6) utilizando dados de reservatórios do Estado de São Paulo, resultando em uma nova classificação de estado trófico (Tabela 2.3). Os autores utilizaram análise estatística por

regressão para adequar as expressões originais aos ambientes subtropicais, sendo as equações abaixo usadas para rios e reservatórios.

$$IET_{transparência} = 10 \times \left[6 - \left(\frac{0,64 + \ln(SD)}{\ln 2} \right) \right] \quad (2.4)$$

$$IET_{fósforo\ total} = 10 \times \left[6 - \left(\frac{\ln\left(\frac{80,32}{P}\right)}{\ln 2} \right) \right] \quad (2.5)$$

$$IET_{clorofila-a} = 10 \times \left[6 - \left(\frac{2,04 - 0,695 \ln(Chl-a)}{\ln 2} \right) \right] \quad (2.6)$$

Tabela 2.3 - Classificação do IET de Toledo.

Categoria Estado Trófico	IET	Transparência (m)	Fósforo Total (mg/L)	Clorofila-a (mg/L)
Ultraoligotrófico	$IET \leq 24$	$SD \geq 7,8$	$P \leq 0,006$	$Chl-a \leq 0,51$
Oligotrófico	$24 < IET \leq 44$	7,7 - 2,0	0,007 - 0,026	0,52 - 3,81
Mesotrófico	$44 < IET \leq 54$	1,9 - 2,0	0,027 - 0,052	3,82 - 10,34
Eutrófico	$54 < IET \leq 74$	0,9 - 0,3	0,053 - 0,211	10,35 - 76,06
Hipereutrófico	$IET > 74$	0,3 > SD	$P > 0,211$	$Chl-a > 76,06$

Fonte: Toledo (1990).

Lamparelli (2004) também desenvolveu um IET Carlson (1977) modificado para regiões tropicais (Equações 2.7, 2.8 e 2.9 referentes ao cálculo do IET para reservatórios), usando os dados da rede da Companhia Ambiental do Estado de São Paulo (CETESB), considerando 34 pontos amostrados em reservatórios e 35 em rios no período de 1996-2001. O IET desenvolvido pela autora teve uma maior sensibilidade que o IET Carlson (1977) modificado por Toledo et al. (1983, 1984), ampliando a abrangência das classificações tróficas. Além disso, o IET é calculado separadamente para rios e reservatórios. Atualmente, essa metodologia de classificação é adotada pela CETESB (Tabela 2.4). A CETESB usa apenas as variáveis concentração da chl-a e concentração do fósforo total para o cálculo do IET, aplicando uma média aritmética simples entre os IETs desses parâmetros. A justificativa de não utilizar a transparência da água no cálculo

do IET é que os valores de transparência muitas vezes não são representativos do estado de trofia, podendo ser afetada pela elevada turbidez decorrente de material mineral em suspensão e não apenas pela densidade de organismos planctônicos.

$$IET_{transparência} = 10 \times \left[6 - \left(\frac{\ln(SD)}{\ln 2} \right) \right] \quad (2.7)$$

$$IET_{fósforo\ total} = 10 \times \left[6 - \left(\frac{1,77 - 0,42 \ln(P)}{\ln 2} \right) \right] \quad (2.8)$$

$$IET_{clorofila-a} = 10 \times \left[6 - \left(\frac{0,92 - 0,64 \ln(Chl-a)}{\ln 2} \right) \right] \quad (2.9)$$

Tabela 2.4 - Classificação do IET de Lamparelli para reservatórios tropicais.

Categoria Estado Trófico	Ponderação IET	Profundidade Secchi (m)	Fósforo Total (mg/m³)	Clorofila-a (mg/m³)
Ultraoligotrófico	IET ≤ 47	SD ≥ 2,4	P ≤ 8	Chl-a ≤ 1,17
Oligotrófico	47 < IET ≤ 52	2,4 > SD ≥ 1,7	8 < P ≤ 19	1,17 < Chl-a ≤ 3,24
Mesotrófico	52 < IET ≤ 59	1,7 > SD ≥ 1,1	19 < P ≤ 52	3,24 < Chl-a ≤ 11,03
Eutrófico	59 < IET ≤ 63	1,1 > SD ≥ 0,8	52 < P ≤ 120	11,03 < Chl-a ≤ 30,55
Supereutrófico	63 < IET ≤ 67	0,8 > SD ≥ 0,6	120 < P ≤ 233	30,55 < Chl-a ≤ 69,05
Hipereutrófico	IET > 67	0,6 > SD	P > 233	Chl-a > 69,05

Fonte: Lamparelli (2004).

Cunha et al. (2013) criaram um IET para reservatórios tropicais/subtropicais (Tabela 2.5, Equações 2.10, 2.11 e 2.12), baseado no trabalho de Lamparelli (2004), utilizando dados da CETESB de dezoito reservatórios tropicais/subtropicais do Estado de São Paulo, no período de 1996 a 2009, com diferentes características químicas da água, características topográficas e atributos morfológicos. O cálculo do IET também utilizou a média aritmética do IET da concentração da chl-a com o IET da concentração do fósforo total.

$$IET_{transparência} = 10 \times \left[6 - \frac{\ln(SD)}{\ln 2} \right] \quad (2.10)$$

$$IET_{fósforo\ total} = 10 \times \left[6 - \left(\frac{-0,27637 \ln(P) + 1,329766}{\ln 2} \right) \right] \quad (2.11)$$

$$IET_{clorofila-a} = 10 \times \left[6 - \left(\frac{-0,2512 \ln(Chl-a) + 0,842257}{\ln 2} \right) \right] \quad (2.12)$$

Tabela 2.5 - Classificação do IET de Cunha e colaboradores para reservatórios tropicais/subtropicais.

Categoria Estado Trófico	Ponderação IET	Fósforo Total (mg/m³)	Clorofila-a (mg/m³)
Ultraoligotrófico	IET ≤ 51,1	P ≤ 15,9	Chl-a ≤ 2,0
Oligotrófico	51,2 - 53,1	16,0 - 23,8	2,1 - 3,9
Mesotrófico	53,2 - 55,7	23,9 - 36,7	4,0 - 10,0
Eutrófico	55,8 - 58,1	36,8 - 63,7	10,1 - 20,2
Supereutrófico	58,2 - 59,0	63,8 - 77,6	20,3 - 27,1
Hipereutrófico	IET ≥ 59,1	P ≥ 77,7	Chl-a ≥ 27,2

Fonte: Cunha et al. (2013).

O método tradicional para se determinar o estado trófico em sistemas aquáticos, como mostrado nos exemplos acima, é oneroso em tempo e recursos financeiros e humanos. Vários processos demorados e trabalhosos são necessários para medir os parâmetros da qualidade da água, como por exemplo a coleta de amostras de água em campanhas de campo, transporte, filtragem de amostras e análise química (DODDS, 2007). Isso prejudica a rápida avaliação e caracterização do estado trófico de águas interiores presentes em ambientes sujeitos a constantes pressões antropogênicas. Além disso, o método tradicional de monitoramento mostra apenas uma visão pontual do estado trófico de um sistema aquático. Vale ressaltar também que este método é inadequado para monitorar águas interiores em grandes escalas devido às distribuições irregulares dos nutrientes e da chl-a no corpo d'água, com escalas espaciais e temporais limitadas (SASS et al., 2007). Assim, de forma a reduzir custos e ampliar a representatividade espacial e temporal do estado trófico de um sistema aquático, o SR vem sendo usado como alternativa para monitorar a qualidade da água (MOUW et al., 2015; PALMER et al., 2015).

Os indicadores tróficos do IET (químico: concentração de fósforo; biológico: concentração da chl-*a*; e físico: transparência da água – disco de Secchi) que podem ser estimados diretamente por métodos de SR são a concentração da chl-*a* e a transparência da água. A concentração de nutrientes, como o fósforo total, não pode ser diretamente derivada por SR, uma vez que é uma substância opticamente inativa, não tendo resposta óptica (KUTSER et al., 1995). Devido à elevada correlação entre a concentração da chl-*a* e de nutrientes (VOLLENWEIDER, 1968), esse pigmento fotossinteticamente ativo, presente em todas as espécies de fitoplâncton (REYNOLDS, 2006), pode ser usado como um *proxy* da condição trófica de um sistema aquático.

No Brasil, estudos que usam o SR para avaliar o estado trófico em sistemas aquáticos vêm sendo realizados em reservatórios tropicais do complexo em cascata construído ao longo do rio Tietê (NOVO et al., 2013; WATANABE et al., 2015). Novo et al. (2013) criaram um índice de estado trófico baseado na estimativa da concentração da chl-*a* a partir do TM/Landsat-5 para o reservatório de Ibitinga (terceiro reservatório do sistema em cascata). Para isso, usando o banco de dados de Londe (2008), os autores aplicaram a simulação Monte Carlo para selecionar o modelo mais adequado para relacionar a concentração da chl-*a* com a reflectância simulada do TM/Landsat-5. A razão TM4/TM3 forneceu o melhor resultado e o modelo foi então invertido para criar uma *look-up-table* (LUT) com as relações entre os intervalos das razões TM4/TM3 e as classes de estado trófico, abrangendo todo o intervalo de valores medido no reservatório na campanha de 2005. Por fim, os autores mapearam a distribuição espacial das classes de estado trófico no reservatório a partir da aplicação da LUT à imagem razão TM4/TM3 do TM/Landsat-5. Os resultados mostraram que cerca de 75% da área do reservatório de Ibitinga em 11 de outubro de 2005 apresentou características supereutróficas e hipereutróficas, com concentração de chl-*a* maior que 30 mg/m³. Entretanto, esse trabalho não avaliou a precisão da estimativa da concentração da chl-*a* usando SR, apenas teve uma análise qualitativa do estado trófico no reservatório a partir da metodologia desenvolvida.

Watanabe et al. (2015) desenvolveram uma pesquisa no reservatório de Barra Bonita, primeiro reservatório do sistema em cascata, com o objetivo de mapear o estado trófico sazonal do reservatório. Os autores usaram duas abordagens: a) baseada na estimativa da

concentração da chl-*a* a partir de imagens OLI/Landsat-8; e b) baseada nas medidas de concentração da chl-*a* e da profundidade do disco de Secchi obtidas durante as duas campanhas de campo (maio e outubro 2014; $19,1 \leq \text{chl-}a \leq 797,8 \text{ mg/m}^3$; $0,4 \leq \text{secchi} \leq 2,3 \text{ m}$). Em ambas abordagens foram usados métodos baseados na classificação adotada pela CETESB. O algoritmo bio-óptico de ajuste polinomial com a razão NIR-*Green* foi o que teve um ajuste satisfatório para as bandas simuladas do OLI/Landsat-8 ($R^2 = 0,71$) e os melhores resultados de validação (RMSE = 82,39%, MAPE = 36,02%, $R^2 = 0,19$) em comparação com os outros modelos testados. Esse modelo foi aplicado em uma série temporal de imagens OLI de maio/2013 a outubro/2014, mas não foi capaz de estimar com precisão a concentração da chl-*a* e, conseqüentemente, o estado trófico. O modelo polinomial NIR-*Green* subestimou as altas concentrações da chl-*a* e superestimou as baixas concentrações, o que prejudicou a classificação do estado trófico. Assim, os mapas dos níveis tróficos produzidos a partir da estimativa da concentração da chl-*a* por SR usando esse modelo não apresentariam a variação confiável que pode ser vista na representação das estações. A classificação do estado trófico usando os dados de campo mostrou que a classificação pelo parâmetro concentração de chl-*a* foi mais rigoroso que pelo parâmetro disco de Secchi. Além disso, a classificação usando a concentração da chl-*a* obteve resultados similares aos do IET das três estações de monitoramento da CETESB inseridas no reservatório, com águas predominantemente supereutróficas e hipereutróficas.

A partir do trabalho de Watanabe et al. (2015) foi possível observar que um único algoritmo bio-óptico pode não ser suficiente para representar e estimar toda a variabilidade da concentração da chl-*a* e, conseqüentemente, do estado trófico em reservatórios opticamente dinâmicos. Augusto-Silva et al. (2014) também chegaram a essa conclusão em um trabalho realizado no reservatório de Funil/RJ. Os autores concluíram que deve haver dois tipos de algoritmos para estimar e fornecer valores mais precisos de concentração de chl-*a*, no caso um algoritmo para o que eles chamam de "condições normais" e outro para "condições de floração".

No sistema de reservatórios em cascata do rio Tietê, a variação das propriedades bio-ópticas, no espaço e no tempo, são regidas, principalmente, pelo funcionamento da

barragem. Dessa forma, há a necessidade de se avaliar os diferentes algoritmos bio-ópticos de estimativa da concentração da chl-*a* presentes na literatura, para assim agrupar os que melhor representam a variação do comportamento espectral da água nesses reservatórios de regulação, em faixas específicas de concentração da chl-*a*.

2.3 Modelos bio-ópticos de estimativa da concentração da chl-*a*

A estimativa da chl-*a* por SR pode ser pautada em três tipos de abordagens baseadas nas várias técnicas de detecção por meio de diferentes caminhos ópticos. O caminho óptico refere-se ao caminho seguido pela luz por meio de uma série de interações com o fitoplâncton que permite a inferência da concentração de chl-*a* a partir do sinal medido, sendo esses caminhos: absorção, fluorescência e espalhamento do fitoplâncton (MATTHEWS, 2017).

2.3.1 Abordagem baseada na absorção

A abordagem baseada na absorção para a estimativa da chl-*a* foca em relações envolvendo suas bandas de máxima absorção, presentes nos comprimentos de onda do azul (440 nm) e do vermelho (675 nm) (SATHYENDRANATH et al., 1987). Para essa estimativa, usa-se a relação da concentração de chl-*a* com coeficiente de absorção do fitoplâncton (a_{phy}) e/ou coeficiente de absorção específico do fitoplâncton (a_{phy}^*), e também com a razão de bandas do azul/ciano/verde e do vermelho/verde.

Essa abordagem inclui, por exemplo, os algoritmos semi-analíticos. Esses algoritmos se baseiam na inversão da teoria da transferência radiativa para estabelecer relações entre as Propriedades Ópticas Aparentes (POAs) e Propriedades Ópticas Inerentes (POIs), calculadas por meio de várias etapas analíticas e empíricas (LEE et al., 2002). Watanabe et al. (2018) desenvolveram um algoritmo semi-analítico para estimar a chl-*a* em reservatórios tropicais produtivos, baseado nas bandas do OLCI/Sentinel-3. Para parametrizar e calibrar o algoritmo foram usadas duas campanhas de campo coletadas no reservatório de Barra Bonita (BB1 e BB2 = $17,7 \leq chl-a \leq 797,8 \text{ mg/m}^3$) e para validar foi usado dados de uma campanha de campo realizada no reservatório de Bariri (segundo reservatório do sistema em cascata do rio Tietê; BA = $25,1 \leq chl-a \leq 694,3 \text{ mg/m}^3$). Os

resultados da validação mostraram um bom desempenho do algoritmo semi-analítico parametrizado a partir dos conjuntos de dados BB1 e BB2 para estimar a concentração da chl-*a*. Foi obtido um NRMSE médio de 19,6% e um MAPE médio de 62,3% para uma faixa de concentração de até 300 mg/m³. Entretanto, o algoritmo semi-analítico não foi capaz de estimar com precisão a chl-*a* para maiores valores de concentração (> 600 mg/m³).

Além disso, Andrade et al. (2018) testaram a adequabilidade de diferentes versões do *Quasi-Analytical Algorithm* (QAA) presentes na literatura para estimar as POIs no reservatório de Ibitinga (dados coletados em julho/2016; $1,37 \leq \text{chl-}a \leq 119,04 \text{ mg/m}^3$). Os resultados mostraram que nenhuma das versões de QAA testadas foi completamente adequada para estimar com precisão os coeficientes de absorção em todos os comprimentos de onda no reservatório. Por exemplo, embora o QAA_{BBHR} tenha sido parametrizado para um reservatório tropical altamente produtivo (reservatório de Barra Bonita), o modelo não estimou com precisão o a_{phy} em 665 nm, que é usado como um proxy para estimar a concentração de chl-*a*. Os resultados do estudo de Andrade et al. (2018) destacam a limitação de um esquema quase-analítico em monitorar no espaço/tempo os COAs no sistema em cascata do rio Tietê. Além disso, mostram que é um desafio lidar com a alta variabilidade óptica nesse sistema.

Um outro tipo de algoritmo que a abordagem baseada na absorção inclui é o semi-empírico. Os algoritmos semi-empíricos usam bandas espectrais selecionadas de acordo com premissas físicas baseadas no comportamento espectral do alvo (MOREL; GORDON, 1980), sendo seus resultados correlacionados com a atividade biológica por meio da análise estatística. Exemplos de algoritmos semi-empíricos englobados nessa abordagem são os de duas bandas azul/verde e vermelho/verde.

Os algoritmos que usam as bandas azul e verde do espectro eletromagnético foram originalmente desenvolvidos para estimar a concentração da chl-*a* em águas oceânicas (AIKEN et al. 1995; CLARK, 1997; O'REILLY et al., 1998). Em águas interiores, o desempenho desses algoritmos é comprometido devido à presença de outros constituintes como o CDOM e as partículas não algais (NAP) (GITELSON et al., 2009), que absorvem

na região do azul e mascararam a feição de absorção da chl-*a* em 440 nm (CARDER et al., 1999). Entretanto, Odermatt et al. (2012), analisando o desempenho de algoritmos para a estimativa dos COAs, concluíram que os modelos OC2-OC4 (*Ocean Color* - razão de bandas azul/verde) quando aplicados em águas opticamente complexas possuem um melhor desempenho na estimativa da chl-*a* na faixa de 0-10 mg/m³. Isso porque as propriedades ópticas da água das áreas de estudo analisadas se assemelham às de águas oceânicas, até certo ponto (ODERMATT et al., 2012). Por exemplo, no estudo desenvolvido por Horion et al. (2010) em um lago oligotrófico na África, os autores relataram que o lago Tanganyika pode ser considerado como água do Caso 1, uma vez que a contribuição do fitoplâncton para a atenuação da luz na região fotossinteticamente ativa (PAR) foi maior que 50%. Nesse trabalho foi utilizado o modelo OC3, no período de 2002 a 2006, para estimar a concentração da chl-*a* utilizando o sensor MODIS, obtendo um R² de 0,7, considerando um valor máximo de chl-*a* superficial de 3,77 mg/m³.

Para exemplificar o modelo de razão de bandas vermelho/verde, Le et al. (2013b) aplicaram o modelo empírico "RGCI - Red-Green-Chla-Index" (LE et al., 2013a) na Baía de Chesapeake (EUA), utilizando os sensores MODIS e SeaWiFS. Os autores utilizaram 2 conjuntos de dados *in situ*, o primeiro foi coletado em julho/2011 (chl-*a* = 7,4-54,3 mg/m³) e o segundo foi coletado mensalmente no período de 1997-2011 (chl-*a* = 1-50 mg/m³), e cobria os períodos de aquisição dos dados MODIS e SeaWiFS. O primeiro conjunto de dados foi utilizado para determinar quais as razões de bandas vermelho/verde tinham melhores resultados para cada sensor, de modo a ser usado como entrada no RGCI. Já o segundo conjunto de dados foi utilizado para calibrar e validar o modelo RGCI para a região de estudo, e assim comparar seu desempenho com os modelos OC3 e OC4. Os autores obtiveram melhor desempenho do RGCI para as razões de bandas 667/531 (MODIS - Equação 2.13) e 670/510 (SeaWiFS - Equação 2.14), com R² igual a 0,77 e 0,71. Quando os modelos RGCI 667/531 e RGCI 670/510 foram calibrados e validados com o segundo conjunto de dados, os algoritmos obtiveram um R² de 0,43. Mesmo com a queda do desempenho, os autores alegam que o RGCI mostrou significativa melhora sobre os algoritmos tradicionais de razão de bandas azul/verde (OC4, OC3), com desempenho consistente para o MODIS (erro relativo médio = 40,9%, razão média = 1,09) e SeaWiFS (erro relativo médio = 45,8%, razão média = 1,09). Embora houve uma

melhora no desempenho do RGCI em comparação com o OC4 e OC3, o erro é bem grande para que o modelo consiga estimar a chl-*a* com precisão.

$$Chla = 10(1,76x + 1,61), \text{ sendo } x = \log_{10}(R_{rs}(667)/R_{rs}(531)) \quad (2.13)$$

$$Chla = 10(1,76x + 1,43), \text{ sendo } x = \log_{10}(R_{rs}(670)/R_{rs}(510)) \quad (2.14)$$


2.3.2 Abordagem baseada na fluorescência

A abordagem baseada na fluorescência para a estimativa da chl-*a* foca em relações envolvendo a banda de fluorescência da chl-*a*, que pode variar dependendo da localização de maior concentração das moléculas de chl-*a* nos fotossistemas presentes na fase clara da fotossíntese (PSI e PSII) (CAMPBELL et al., 1998). As moléculas de chl-*a* contidas nos fotossistemas possuem diferentes características de absorção e emissão de fluorescência, pois estão ligadas a diferentes complexos de proteínas (JOHNSEN; SAKSHAUG, 2007). A fluorescência do PSI ocorre nos comprimentos de onda maiores que 700 nm (SIMIS et al., 2012), enquanto que a banda de fluorescência do PSII é centrada em torno de 685 nm (HUOT; BABIN, 2010).

Com o intuito de derivar a chl-*a* utilizando essa abordagem, desenvolveram-se algoritmos baseados na altura da linha de fluorescência (FLH - *Fluorescence Line Height*), usando o mesmo princípio que a medição do pico de emissão da fluorescência usada em fluorometria *in vivo* (GOWER et al., 1999). Para determinar o FLH (Figura 2.1), primeiramente uma linha de base é formada por uma interpolação linear usando as bandas de ambos os lados do pico de fluorescência (685 nm), sendo uma dessas bandas geralmente centrada no máximo de absorção de chl-*a* (~665 nm) e a outra na região de absorção da água (~700 ou 750 nm). Em seguida, subtrai-se essa linha de base da radiância da banda de fluorescência, obtendo o FLH (XING et al., 2007). A relação entre o FLH e a concentração da chl-*a* pode ser descrita por meio de uma relação linear ou não linear, dependendo do estado trófico da água e da fisiologia do fitoplâncton. Em ambientes oligotróficos, obtêm-se uma melhor performance usando uma relação linear (GOWER et al., 1999) e em ambientes mesotróficos/eutróficos usando uma relação não linear (GOWER et al., 2005).

Vale ressaltar que o FLH possui melhor desempenho em águas costeiras e interiores menos turbidas, com concentrações intermediárias de chl-*a* (1-20 mg/m³), ou em águas onde o fitoplâncton é o componente opticamente dominante. Além disso, requer uma elevada exigência da sensibilidade espectral do sensor e de sensores orbitais com uma resolução espectral sensível e centrada na banda de fluorescência da chl-*a* (MATTHEWS, 2017). Dessa forma, as estimativas de chl-*a* por SR usando o FLH são limitadas a sensores da cor do oceano como MODIS, MERIS e OLCI, que possuem baixa/média resolução espacial (~300 metros), o que dificulta, por exemplo, sua aplicação nos estreitos reservatórios do sistema em cascata do rio Tietê.

Figura 2.1 - Princípio do *Fluorescence Line Height* (FLH), em que λ_F , λ_L e λ_R são respectivamente os comprimentos de ondas centrais da banda de fluorescência e das duas bandas da linha de base. L_F , L_L e L_R são respectivamente as radiâncias da banda de fluorescência e das duas bandas da linha de base.



Fonte: Adaptado de Xing et al. (2007).

Em ambientes eutróficos e águas dominadas por HABs, o pico de fluorescência pode ser totalmente desviado do pico de fluorescência usual, e o algoritmo FLH se tornaria inoperante e inútil nessas condições (XING et al., 2007). Além disso, quando a concentração da chl-*a* aumenta significativamente, parte do sinal da fluorescência em torno de 685 nm é impactado pela ampliação da banda de absorção da chl-*a* em 670 nm. Neste caso, o espectro de reflectância tem um pico máximo em torno de 700 nm (associado ao espalhamento pelo fitoplâncton, sendo o caminho óptico descrito no próximo tópico) e um mínimo em torno de 665 e 680 nm. Dessa forma, usando a ideia do FLH, Gower et al. (2003, 2005) desenvolveram um modelo conhecido como *Maximum Chlorophyll Index* (MCI), em que os comprimentos de onda de 681 nm e 753 nm são a referência para a construção da linha de base e o pico de máxima reflectância é em 709

nm, considerando as bandas do sensor MERIS. Os autores mostraram que o MCI pode fornecer uma sensibilidade considerável e ser uma importante ferramenta de detecção de florações intensas de fitoplâncton, principalmente em concentrações de chl-*a* acima de 30 mg/m³.

Bindings et al. (2011) aplicaram o modelo FLH (Equação 2.15) e MCI (Equação 2.16) para o *Lake of the Woods* (EUA/Canada), durante uma intensa floração superficial de cianobactérias em setembro de 2009, usando o sensor MERIS, em uma faixa de concentração de chl-*a* de 1,9-70,5 mg/m³. Em comparação com medidas *in situ* de chl-*a*, o FLH teve uma correlação moderada ($R^2 = 0,57$) com um RMSE relativo de 50%. Esse resultado está de acordo com os achados de Gons et al. (2008), que documentaram o uso efetivo do produto MERIS FLH em águas oligotróficas dos Grandes Lagos Laurentianos, mas o fracasso (com FLH diminuindo e tornando-se negativo) em águas mesotróficas e eutróficas. Além disso, Bindings et al. (2011) mostraram que o MCI teve um melhor desempenho em comparação ao FLH, tendo uma correlação mais forte com os valores *in situ* de chl-*a* ($R^2 = 0,72$) e um RMSE relativo de 40%.

$$FLH = RL_w(\lambda_2) - \left[RL_w(\lambda_1) + \left(\frac{RL_w(\lambda_3)}{RL_w(\lambda_1)} \times \frac{\lambda_2 - \lambda_1}{\lambda_3 - \lambda_1} \right) \right] \quad (2.15)$$

$$MCI = RL_w(\lambda_2) - \left[RL_w(\lambda_1) + \left((RL_w(\lambda_3) - RL_w(\lambda_1)) \times \frac{\lambda_2 - \lambda_1}{\lambda_3 - \lambda_1} \right) \right] \quad (2.16)$$

Em que RL_w é a reflectância radiância emergente da água e λ_1 , λ_2 e λ_3 são nas Equações 2.15 e 2.16, respectivamente, 665/680/708 nm e 680/708/753 nm.

2.3.3 Abordagem baseada no espalhamento

A abordagem baseada no espalhamento para a estimativa da chl-*a* foca no comportamento espectral de espalhamento do fitoplâncton. A relação entre o retroespalhamento da partícula e a concentração da chl-*a* é específica para cada tipo de fitoplâncton (DUPOUY et al., 2008; WHITMIRE et al., 2010), sendo baseada nas propriedades de partícula das células fitoplanctônicas. O retroespalhamento é causado por estruturas celulares do

fitoplâncton, como a parede celular e inclusões celulares (ex.: cloroplasto, vacúolos), sendo que sua magnitude pode variar amplamente entre gêneros/espécies de fitoplâncton (SVENSEN et al., 2007). Além disso, é importante ressaltar que o retroespalhamento também é causado pelas partículas inorgânicas em suspensão na água, sendo influenciado pela forma, distribuição de tamanhos e índice de refração dessas partículas (MOBLEY, 1994).

Essa abordagem utiliza, preferencialmente, o pico próximo a 700 nm, que se torna bem aparente em elevadas concentrações de fitoplâncton, ao invés do pico próximo à 560 nm, por conta da absorção dos pigmentos acessórios (ex.: carotenóides) e absorção do CDOM nos menores comprimentos de onda. Em geral, a abordagem do espalhamento é limitada a concentrações de chl-*a* acima de $\pm 10 \text{ mg/m}^3$, e é provavelmente o método mais robusto para estimar concentrações de chl-*a* acima de 20 mg/m^3 , levando em consideração o maior sinal relativo de aumento da biomassa na região do vermelho (MATTHEWS, 2017). Além disso, essa abordagem inclui os algoritmos de 3 bandas e de 2 bandas (razão de bandas, *slope* e o *Normalized Difference Chlorophyll Index* (NDCI)).

Gitelson et al. (2011a) estimaram a concentração de chl-*a* utilizando o modelo de 3 bandas (Equação 2.17) e o sensor *Hyperspectral Imager for the Coastal Ocean* (HICO), considerando as bandas espectrais do vermelho e infravermelho (684, 700 e 720 nm), em águas costeiras túrbidas produtivas do Mar Azov (Rússia). O modelo explicou mais de 85% da variação de chl-*a* e permitiu a estimativa de chl-*a* em um range de 17 a 93,14 mg/m^3 , com RMSE abaixo de 10 mg/m^3 . Entretanto, os autores não conseguiram afirmar se o modelo é válido para concentrações inferiores a 40 mg/m^3 , por conta da baixa amostragem nessas concentrações. Gitelson et al. (2011b) aplicaram o modelo de 3 bandas nos Lagos Fremont (Nebraska – EUA), com bandas simuladas do MERIS, e mostraram que esse tipo de modelo tem potencial para ser aplicado em concentrações baixas/medianas. Os autores relataram que o modelo possui sensibilidade ($R^2 = 0.84$) para estimar a concentração da chl-*a* em um range entre 0-30 mg/m^3 .

$$chl_a \propto [R_{rs}(\lambda_1)^{-1} - R_{rs}(\lambda_2)^{-1}] \times R_{rs}(\lambda_3) \quad (2.17)$$

Sendo, λ_1 o comprimento de onda na região do vermelho, λ_2 o comprimento de onda na região do *red-edge* e λ_3 o comprimento de onda na região do infravermelho. Vale ressaltar que λ_1 é uma região espectral tal que $R_{rs}(\lambda_1)$ é altamente sensível à absorção da chl-*a*; entretanto $R_{rs}(\lambda_1)$ também é afetado pela absorção de outros constituintes e pelo retroespalhamento. λ_2 é uma região espectral tal que $R_{rs}(\lambda_2)$ é minimamente sensível à absorção pela chl-*a* e em que a absorção pelos outros constituintes (CDOM e NAP) é quase igual a de λ_1 . A diferença entre $[R_{rs}(\lambda_1)^{-1} - R_{rs}(\lambda_2)^{-1}]$ é relacionada ao conteúdo de concentração de chl-*a*, mas ainda é afetado pelo retroespalhamento, que pode gerar diferentes estimativas de chl-*a* para locais com igual concentração. λ_3 é uma região espectral que pode ser usada para minimizar a influência do retroespalhamento e onde a absorção deve ser associada apenas à água pura (DALL'OLMO et al., 2003; GITELSON et al., 2008).

Gilerson et al. (2010) testou algoritmos de 2 e 3 bandas (Equações 2.18 e 2.19, respectivamente) usando um conjunto de dados sintéticos de espectros de reflectância e POIs simulados com Hydrolight e um conjunto de dados *in situ* de vários lagos em Nebraska (EUA) (chl-*a* = 2-100 mg/m³). Esses algoritmos consideraram as bandas do MERIS centradas em 665, 708 e 753 nm. Os resultados mostraram que esses algoritmos tiveram uma alta correlação entre a concentração da chl-*a* medida em campo e a estimada de maneira analítica pelas equações 2.18 e 2.19, tendo em ambos casos um R² de aproximadamente 0,96, considerando uma faixa de concentração de chl-*a* de 0-80 mg/m³.

$$chla = \left[\left(35,75 \times \frac{R_{rs}(708)}{R_{rs}(665)} \right) - 19,30 \right]^{1,124} \quad (2.18)$$

$$chla = \{ [113,36 \times (R_{rs}(665)^{-1} - R_{rs}(708)^{-1}) \times R_{rs}(753)] + 16,45 \}^{1,124} \quad (2.19)$$

Mishra e Mishra (2010) desenvolveram um algoritmo de diferença de banda espectral para estimar a concentração de chl-*a* no lago Pontchartrain (EUA), no caso o algoritmo *slope* (Equação 2.20), usando dados *in situ* de concentração de chl-*a* e de R_{rs} obtida depois da correção atmosférica dos dados do MODIS. O algoritmo explorou a relação entre as mudanças no *slope* usando a R_{rs} das bandas do verde e vermelho do MODIS (553 e 645 nm) com as mudanças da concentração da chl-*a* nas águas do lago. Os resultados

mostraram que o algoritmo teve um desempenho razoável, com $R^2 = 0,65$ e $RMSE = 11 \text{ mg/m}^3$ no processo de calibração ($chl-a = 14,14-70,97 \text{ mg/m}^3$) e $RMSE = 9,43 \text{ mg/m}^3$ no processo de validação ($chl-a \sim 20-60 \text{ mg/m}^3$). Mesmo assim, o algoritmo *slope* foi capaz de capturar a tendência, extensão e duração da floração no lago.

$$Slope = \frac{R_{rs}(645) - R_{rs}(553)}{645 - 553} \quad (2.20)$$

Em outro trabalho, Mishra e Mishra (2012) propuseram o algoritmo NDCI (Equação 2.21) para estimar a concentração da *chl-a* em águas produtivas túrbidas costeiras e estuarinas. O NDCI foi desenvolvido levando em consideração a diferença entre as bandas espectrais 708 nm e 665 nm (bandas do MERIS), sendo normalizado pela soma de suas reflectâncias para eliminar qualquer incerteza na estimativa da R_{rs} , diferenças sazonais de azimute solar e contribuições atmosféricas nesses comprimentos de onda. Os resultados de validação com dados de campo baseados na região geográfica (Baía Mobile e delta do rio Mississippi – dados *in situ* de *chl-a* e R_{rs} extraída das imagens MERIS) mostraram que o algoritmo teve um bom desempenho em estimar a concentração da *chl-a* ($RMSE = 1,43 \text{ mg/m}^3$ e um $R^2 = 0,94$), podendo ser usado com confiabilidade para estimar a *chl-a* até $28,17 \text{ mg/m}^3$. Além disso, a validação usando dados simulados mostrou que o NDCI também teve bom desempenho ($R^2 = 0,93$ e $RMSE = 4,83 \text{ mg/m}^3$), considerando uma faixa de *chl-a* $1-60 \text{ mg/m}^3$.

$$NDCI = \frac{R_{rs}(708) - R_{rs}(665)}{R_{rs}(708) + R_{rs}(665)} \quad (2.21)$$

Usando os modelos de duas e três bandas (GITELSON et al., 2008), *slope* (MISHRA; MISHRA, 2010) e NDCI (MISHRA; MISHRA, 2012), Watanabe et al. (2017) estimaram a concentração de *chl-a* no reservatório tropical hidroelétrico altamente produtivo de Barra Bonita/SP. Para isso, usaram os sensores OLI/Landsat-8 e MSI/Sentinel-2A, considerando os comprimentos de onda 560 e 655 nm para o OLI e 665, 705 e 740 nm para o MSI. Para a calibração dos algoritmos foram usados dados dos campos realizados em maio/2014 e em outubro/2014 ($n = 40$; $chl-a = 17,7-797,8 \text{ mg/m}^3$) e para a validação utilizou os dados obtidos no campo de setembro/2015 ($n = 24$; $chl-a = 62,8-245,7 \text{ mg/m}^3$).

Os resultados mostraram que o modelo de duas bandas não funcionou para o OLI e o *slope*, embora não apresentou os melhores resultados na validação (NRMSE = 46,4% e MAPE = 47,1%), exibiu desempenho satisfatório no mapeamento da chl-*a*. Para o MSI/Sentinel-2A, os algoritmos com melhores resultados na validação foram o *slope* com ajuste linear (MAPE = 49,02%; NRMSE = 69,65%; $R^2 = 0,76$), o NDCI com ajuste linear (MAPE = 57,41%; NRMSE = 40,62%; $R^2 = 0,82$) e o algoritmo de 2 bandas com ajuste polinomial (MAPE = 58,18%; NRMSE = 43,85%; $R^2 = 0,83$). De forma geral, notou-se que os algoritmos subestimaram a concentração da chl-*a*, para ambos os sensores, e mostraram uma baixa performance para valores elevados de chl-*a*. Por fim, os resultados indicaram que a aplicação de um único modelo não é suficiente para explicar a variação da chl-*a* em todo o reservatório.

Um outro trabalho realizado em um dos reservatórios do sistema em cascata do rio Tietê foi o de Londe (2008). A autora mediu o fator de reflectância bidirecional (FRB) em simultâneo com 51 amostras de águas superficiais para caracterizar o comportamento espectral do fitoplâncton no reservatório de Ibitinga. A coleta *in situ* foi realizada durante 5 dias no mês de outubro de 2005, quando o reservatório se encontrava coberto por grandes extensões de florações de cianobactérias (dominada por *Microcystis aeruginosa*). As concentrações de chl-*a* medidas variaram amplamente de montante (de 6 a 15 mg/m³) para jusante (de 1500 a 76809 mg/m³). A autora testou várias razões espectrais de acordo com a literatura para seu conjunto de dados e selecionou as duas com melhores resultados, no caso FRB(895/698) (Equação 2.22) e FRB(NIR/Red) (Equação 2.23; considerando máximo valor de FRB na região do NIR e o mínimo valor de FRB na região do vermelho), para serem usadas no desenvolvimento de modelos empíricos de estimativa da concentração da chl-*a* para o reservatório. O algoritmo FRB(895/698) apresentou R^2 de 0,85, entretanto como havia um intervalo muito grande de valores entre as amostras analisadas o modelo perdeu em acurácia. Para amostras com até 65 mg/m³ de chl-*a*, os valores foram subestimados, e para amostras contendo valores a partir de 194 mg/m³ de chl-*a*, os valores foram superestimados. Já o algoritmo FRB(NIR/Red) apresentou um R^2 de 0,67, sendo que seu baixo desempenho também foi devido ao amplo intervalo de valores das amostras.

$$chl-a = 13027 \times [FRB(895)/FRB(698)] - 6086,3 \quad (2.22)$$

$$LogN(chl-a) = 2,5231 \times Ln[FRB(NIR)/FRB(Red)] + 2,9052 \quad (2.23)$$

Durante a revisão da literatura, foi possível observar que os modelos bio-ópticos de estimativa da concentração da chl-*a* explicam melhor a variação da chl-*a* nos sistemas aquáticos opticamente complexos em faixas específicas de concentração. Isso porque cada tipo de modelo bio-óptico representa melhor cada conjunto de comportamento espectral proveniente da variação da concentração da chl-*a* na água, comprometendo seu desempenho em regiões com características limnológicas e ópticas variáveis. Esses resultados dão suporte teórico para o desenvolvimento de uma abordagem operacionalmente definida como híbrida (descrita na próxima seção) para estimar a concentração da chl-*a*, que visa obter um algoritmo que seja adaptável a diferentes condições tróficas dos sistemas aquáticos.

2.4 Abordagem híbrida para a estimativa da concentração da chl-*a*

A abordagem híbrida surgiu com o intuito de beneficiar o monitoramento operacional da concentração da chl-*a* por SR de sistemas aquáticos opticamente dinâmicos, sujeitos a grande variabilidade de estado trófico. Isso porque essa abordagem permite combinar algoritmos específicos para diferentes intervalos de concentração da chl-*a*, tendo, por exemplo, um algoritmo para representar cada conjunto de comportamento espectral proveniente, principalmente, da variação da chl-*a* na água.

Recentemente, Smith et al. (2018) desenvolveram um tipo de modelo híbrido que seleciona e combina dois tipos diferentes de algoritmos bio-ópticos para estimar a concentração da chl-*a* em águas do Caso1/Caso2 ao longo da costa oeste da África do Sul, em que o estado trófico pode variar de oligotrófico em águas oceânicas a hipereutrófico próximo à costa. Um algoritmo empírico do tipo *blue-green ratio* (HU et al., 2012) foi usado em águas com chl-*a* ≤ 10 mg/m³ e do tipo *red-NIR ratio* (GILERSON et al., 2010) em águas com chl-*a* > 25 mg/m³, sendo que entre esses valores (10 < chl-*a* ≤ 25 mg/m³) os algoritmos foram combinados. A seleção e combinação desses algoritmos no modelo híbrido foi baseada nos valores da razão da reflectância nos comprimentos de

onda de 708 e 665 nm, correspondentes aos percentis 25% e 75% dos dados *in situ* que abrangiam a faixa de $10 < chl-a \leq 25 \text{ mg/m}^3$. Assim, o algoritmo *blue-green ratio* era selecionado quando a razão de reflectâncias preenchia o critério $R(708)/R(665) \leq 0,75$, o algoritmo *red-NIR ratio* era selecionado quando a razão de reflectância $R(708)/R(665) > 1,15$, enquanto entre esses valores ($0,75 < R(708)/R(665) \leq 1,15$) os dois algoritmos foram combinados usando uma abordagem ponderada (Equação 2.24). Os resultados desse trabalho mostraram que o modelo híbrido teve melhor desempenho na validação com dados *in situ* (MARD (*median absolute relative difference*) = 36,4%) do que se tivesse usado os modelos *blue-green ratio* (MARD = 69,3%) ou *red-NIR ratio* (MARD = 44,5%) para todo o conjunto de dados (ampla faixa de concentração de chl-a).

$$Chla_{blend}(mg/m^3) = (\alpha_1 * chla_{G2B}) + (\alpha_2 * chla_{OCI}) \quad (2.24)$$

Em que, $\alpha_1 = (\phi - 0,75)/(1,15 - 0,75)$; $\alpha_2 = (1,15 - \phi)/(1,15 - 0,75)$; $\phi = R_{rs}(708)/R_{rs}(665)$; G2B é referente ao modelo *red-NIR ratio* de Gilerson et al. (2010) e OCI é referente ao modelo *blue-green ratio* de Hu et al. (2012).

Além disso, Matsushita et al. (2015) propuseram um modelo híbrido para estimar a concentração da chl-a ao longo de 5 lagos asiáticos, com uma ampla variedade de níveis tróficos ($chl-a = 1,8-153,9 \text{ mg/m}^3$). Esse modelo híbrido englobou três algoritmos previamente desenvolvidos para estimar a concentração da chl-a em águas claras (*blue-green ratio* - OC4E; O'REILLY et al., 2000), águas turbidas (razão de 2 bandas com *red-NIR ratio* - RN2-Gil10; GILERSON et al., 2010) e águas extremamente turbidas (modelo semi-analítico – SAMO-LUT; YANG et al., 2010). Para selecionar o algoritmo mais adequado a cada faixa de concentração ($chl-a \leq 10 \text{ mg/m}^3$, $10 < chl-a \leq 25 \text{ mg/m}^3$ e $chl-a > 25 \text{ mg/m}^3$), os autores utilizaram valores do algoritmo MCI correspondentes às respectivas faixas de concentração. No caso, se (a) $MCI \leq 0,0001$, o algoritmo OC4E era selecionado; (b) se $0,0001 < MCI \leq 0,0016$, o algoritmo RN2-Gil10 era selecionado; e (c) se $MCI > 0,0016$, o algoritmo SAMO-LUT era selecionado. Os resultados mostraram que os algoritmos tiveram melhor desempenho quando aplicados para faixas específicas de concentração (OC4E: $R^2 = 0,54$, RMSE (*root mean square error*) = $0,30 \text{ mg/m}^3$, NMAE (*normalized mean absolute error*) = 9,4%; RN2-Gil10: $R^2 = 0,75$, RMSE = $3,48$

mg/m³, NMAE = 16% ; SAMO-LUT: R² = 0,90, RMSE = 10,29 mg/m³; NMAE = 12,8%) que para uma faixa mais ampla (OC4E: R² = 0,19, RMSE = 50,20 mg/m³, NMAE = 61,3%; RN2-Gil10: R² = 0,90, RMSE = 20,84 mg/m³, NMAE = 40,4% ; SAMO-LUT: R² = 0,94, RMSE = 8,83 mg/m³; NMAE = 30,2%). Além disso, observou-se que o modelo híbrido foi superior (R² = 0,94, RMSE = 8,63 mg/m³; NMAE = 13,3%) a todos os algoritmos únicos testados, quando considerado toda a faixa observada de propriedades ópticas da região de estudo.

Um outro exemplo dessa abordagem híbrida pode ser a ideia do algoritmo MPH (*Maximum Peak-Height*), desenvolvido por Matthews et al. (2012) para um conjunto de dados de 4 sistemas aquáticos africanos com elevada variabilidade do estado trófico (74 estações no total, no período de 2003 a 2011; chl-*a* = 1-1000 mg/m³). O MPH (Equação 2.25) é semelhante em forma ao modelo FLH, mas ao invés de ser limitado por um pico fixo, procura a posição e a magnitude do pico dominante ao longo das bandas do vermelho e infravermelho do MERIS (681, 709 ou 753 nm). O MPH foi utilizado para selecionar os algoritmos que iriam ser usados para estimar a concentração da chl-*a* em cada condição trófica, variando de águas oligotróficas/mesotróficas (biomassa baixa/média, chl-*a* < 20 mg/m³), a águas eutróficas/hipereutróficas (biomassa elevada, chl-*a* > 20 mg/m³) e condições de *surface scums* ou alga/vegetação flutuante (biomassa extremamente elevada, chl-*a* > ±350 mg/m³). No caso, para cada pico de máxima reflectância na região do vermelho/infravermelho (681 nm, 709 nm ou 754 nm) um algoritmo empírico era indicado. Vale ressaltar que para derivar esses algoritmos empíricos em cada subconjunto referente ao pico de máxima reflectância, a variável MPH foi calculada usando os dados do MERIS e em seguida relações empíricas foram identificadas entre a variável MPH e as medidas da chl-*a in situ*, testando ajustes linear, exponencial, potencial e polinomial. Além disso, o MPH também foi usado para diferenciar águas dominadas por cianobactérias daquelas dominadas por espécies de algas eucarióticas (dinoflagelados/diatomáceas). A limitação de aplicação a sensores que não sejam considerados de cor da água é que o algoritmo MPH pode ser aplicado apenas em sensores orbitais que tenham bandas suficientes no vermelho, como por exemplo os sensores MERIS e OLCI.

$$MPH = \rho_{BRmax} - \rho_{BR664} \left[(\rho_{BR885} - \rho_{BR664}) \times \frac{\lambda_{max} - 664}{885 - 664} \right] \quad (2.25)$$

Sendo ρ_{BRmax} os valores máximos de reflectância nos comprimentos de onda de 681 nm, 709 nm ou 753 nm; ρ_{BR664} o valor de reflectância em 664 nm, ρ_{BR885} o valor de reflectância em 885 nm e λ_{max} o comprimento de onda máximo em 681 nm, 709 nm ou 753 nm.

Além dos exemplos citados acima, alguns autores (GÓMEZ et al., 2011; LE et al., 2011; MOORE et al., 2014; SHI et al., 2013) também desenvolveram a ideia dos modelos híbridos (não sendo chamado assim por eles) classificando opticamente as águas costeiras ou interiores e desenvolvendo algoritmos específicos para estimar a concentração da chl-*a* em cada classe óptica estabelecida. Um primeiro exemplo dessa abordagem é o uso de dois índices de diferença normalizada (bandas 705 e 665 nm; bandas 560 e 442 nm) para dois tipos ópticos de lagos mediterrâneos da Europa, permitindo que diferentes algoritmos fossem aplicados em cada tipo de água para estimar a concentração da chl-*a* (GÓMEZ et al., 2011). Além disso, Moore et al. (2014) usaram uma estrutura de tipos ópticos de água (OWT) para selecionar e combinar dois algoritmos de estimativa da concentração da chl-*a* (*blue-green ratio* e um algoritmo *red-NIR* de 3 bandas). Primeiro, sete OWTs foram definidos usando o algoritmo *fuzzy c-means* a partir de um conjunto de dados de R_{rs} *in situ* que englobava lagos espanhóis e americanos e também dados marinhos costeiros do SeaBASS (*SeaWiFS Bio-optical Archive and Storage System*). Uma vez que os *clusters* foram identificados, os espectros de R_{rs} foram classificados nos respectivos subconjuntos e funções de associação foram desenvolvidas para cada OWT usando a distância Mahalanobis entre a observação e o vetor médio de cada classe. Essas funções de associação representam o grau de proximidade da observação em relação à média, e foram usadas como base de fatores de ponderação para combinar dois tipos diferentes de algoritmos e assim estimar a concentração da chl-*a*.

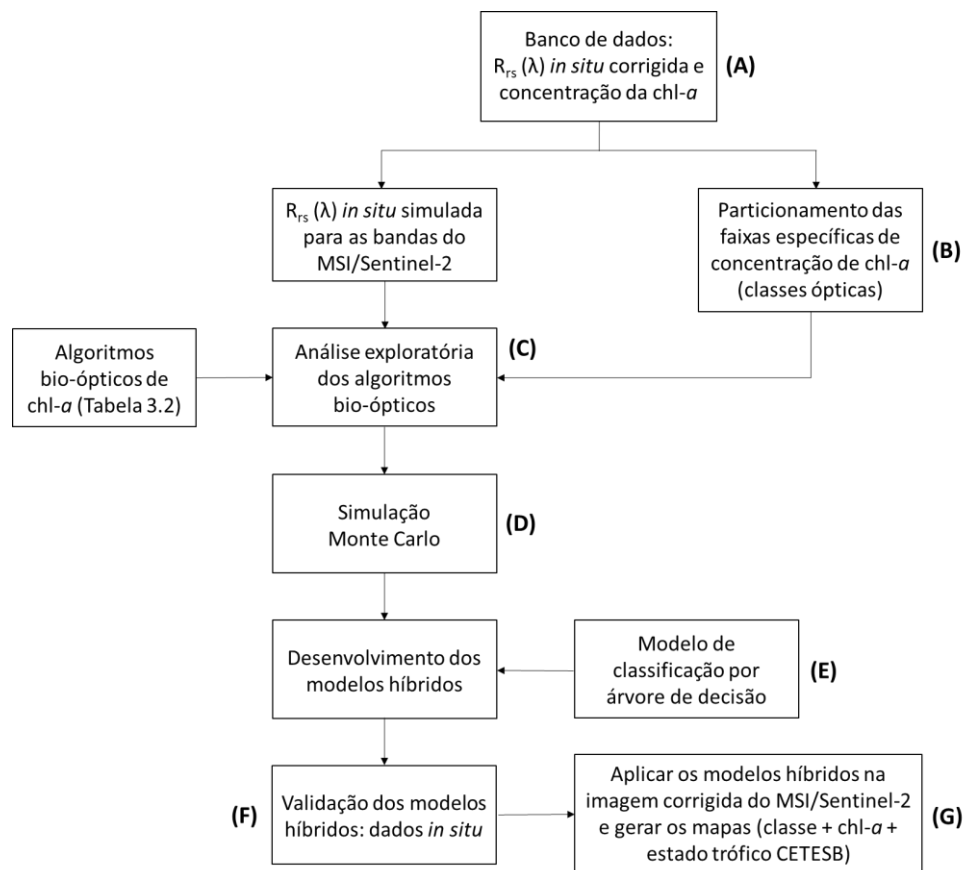
Todos os exemplos citados acima indicam que a abordagem híbrida seria mais adequada para estimar a concentração da chl-*a* em reservatórios tropicais, principalmente no sistema de reservatórios em cascata do rio Tietê. Isso porque o estado trófico e a dinâmica óptica dos reservatórios desse sistema variam amplamente no espaço e no tempo, em

função de forçantes climáticas, hidrológicas, hidrodinâmicas e antropogênicas (ANDRADE et al., 2018; CAIRO, 2015; CAIRO et al., 2017, 2020; NOVO et al., 2013; LONDE, 2008; LONDE et al., 2016; WATANABE et al., 2017, 2018).

3 MATERIAL E MÉTODOS

A metodologia desenvolvida nesta tese está resumida no fluxograma (Figura 3.1) e suas etapas estão descritas nas seções 3.2 a 3.8.

Figura 3.1 - Fluxograma da metodologia desenvolvida na tese.



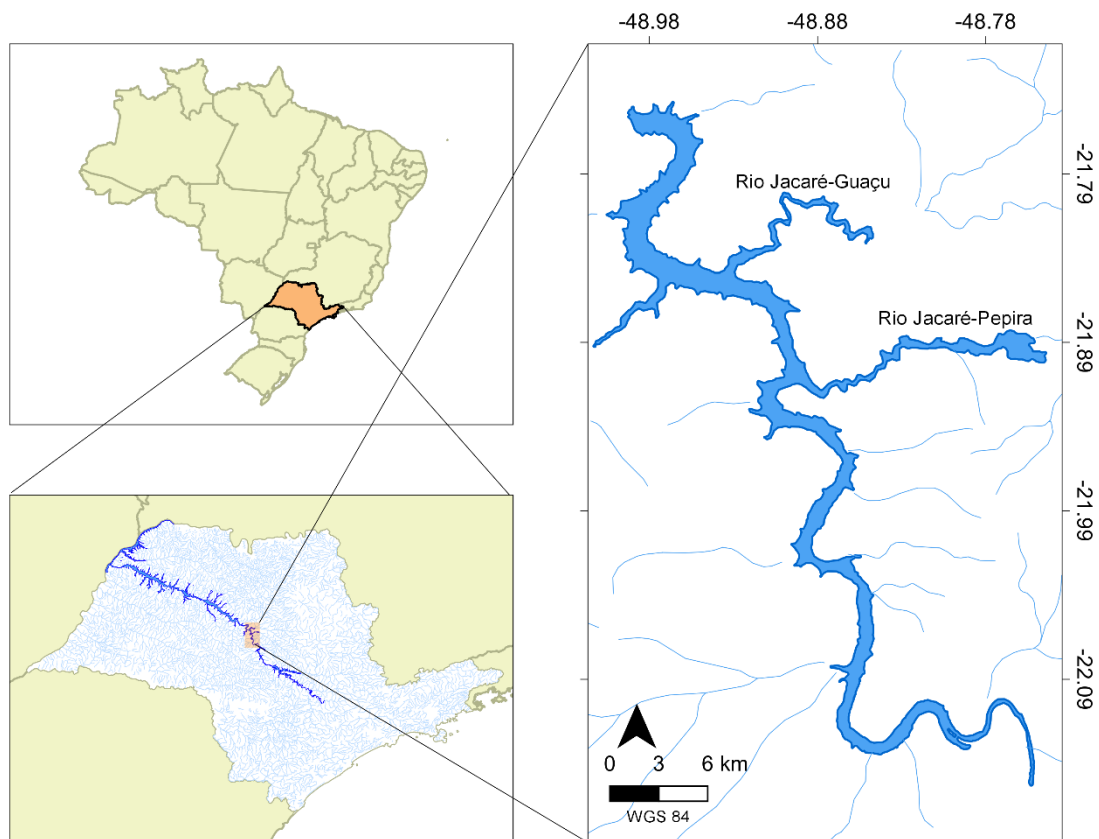
As principais etapas metodológicas são: A) organização do banco de dados composto por medidas de concentração da chl-a até 1000 mg/m³ e espectros de R_{rs} com correção do *glint*, obtidas em oito campanhas de campo realizadas no reservatório de Ibitinga nos anos de 2005, 2013, 2014 e 2018; B) uso de métodos limnológico e óptico de classificação para identificar classes ópticas de faixas específicas de concentração da chl-a; C) análise exploratória dos algoritmos bio-ópticos de chl-a, de forma a selecionar os mais adequados para cada classe óptica, definidas em “B”; D) calibração e validação dos algoritmos bio-ópticos (selecionados em “C”) em cada faixa específica de concentração da chl-a usando a simulação Monte Carlo a partir de medidas de R_{rs} *in situ* simuladas para as bandas do MSI/Sentinel-2; E) desenvolvimento dos modelos híbridos com base no algoritmo de

classificação por árvore de decisão; F) validação dos modelos híbridos usando dados *in situ*; e G) aplicação dos modelos híbridos na imagem MSI/Sentinel-2 com correção atmosférica e correção de *glint*, validação dos modelos híbridos usando a imagem, e geração dos mapas temporais de classes ópticas, de concentração de chl-*a* e de classificação do estado trófico da CETESB.

3.1 Área de estudo

O reservatório hidroelétrico de Ibitinga (Figura 3.2) está localizado no médio Tietê, região central do estado de São Paulo (21°45'S, 48°59'W). Esse reservatório faz parte de um conjunto de reservatórios em cascata construído ao longo do rio Tietê, que funciona como sistemas de regulação, sendo que grande parte da dinâmica óptica, limnológica, hidráulica e trófica do sistema aquático é influenciada pelo funcionamento da barragem. Além disso, o reservatório apresenta vazão média de 525 m³/s, profundidade média de 9 m e tempo de residência da água (média anual) de 21,6 dias (GUIMARÃES JR et al., 1998).

Figura 3.2 - Localização do reservatório de Ibitinga/SP e seus principais afluentes.



Desde o início do século XXI, a bacia de drenagem do reservatório vem sendo submetida a uma grande expansão de cana-de-açúcar (RUDORFF et al., 2010). Dados de monitoramento de expansão da agricultura canavieira entre 2003 e 2014 (CANASAT, 2017) mostram que a região ao redor do reservatório (municípios Ibitinga, Iacanga, Itaju e Arealva) sofreu expansão de 300% em sua área plantada, variando de 15.061 ha à 63.510 ha em cerca de 11 anos. Essa rápida mudança do uso e cobertura do solo pode ter agravado a ocorrência de episódios das chamadas florações de cianobactérias na época do verão no Brasil, levando à redução da quantidade de oxigênio dissolvido na água e à morte de toneladas de peixes (CETESB, 2019). O aumento da temperatura no verão, associado à maior disponibilização de nutrientes no reservatório, devido ao carreamento proporcionado pelo aumento da frequência de chuvas, estimula o processo de eutrofização no sistema aquático, o que favorece o desenvolvimento do fitoplâncton (REYNOLDS, 2006).

Além disso, a qualidade da água no reservatório também é afetada pelo despejo de esgoto sem tratamento adequado. A bacia de drenagem no rio Tietê é uma das mais industrializadas e densamente povoadas do Brasil, e onde as questões de qualidade da água são críticas (BUDDS et al., 2005; CAMPANHA et al., 2015; EMPINOTTI et al., 2019; FILOSO et al., 2003; MARTINELLI; FILOSO, 2008). O rio Tietê recebe o esgoto (bruto e tratado) da cidade de São Paulo, a maior área metropolitana da América do Sul. Considerando os dois principais afluentes do reservatório de Ibitinga (Figura 3.2), a bacia do rio Jacaré-Guaçu, que recebe esgoto de Ibitinga, é mais povoada e menos preservada que o rio Jacaré-Pepira. A bacia do rio Jacaré-Pepira está localizada dentro da Área de Proteção Ambiental de Ibitinga (APA-Ibitinga) (SIGRH, 2014; CBH-TJ, 2016).

Estudos anteriores de Vieira et al. (2002) e Guimarães Jr et al. (1998) apontam que o uso da terra da bacia de drenagem do reservatório contribuiu para o aumento a longo prazo do nível trófico do reservatório devido às entradas de esgoto urbano e de nutrientes derivados da agricultura. Tundisi et al. (2008) identificaram muitos problemas relativos à bacia de drenagem de Ibitinga, como o aumento das fontes de fósforo e nitrogênio relacionadas à expansão da cana-de-açúcar e à degradação dos rios urbanos associados ao crescimento populacional. Em decorrência desse quadro, alguns estudos apontam que

o reservatório de Ibitinga possui uma grande variabilidade espacial e temporal do seu estado trófico. Novo et al. (2013) relataram com base em métodos de SR que o reservatório pode ser classificado como mesotrófico em algumas regiões e hipereutrófico em outras, dependendo da localização da estação amostral. Estes resultados corroboraram pesquisas anteriores realizados por Luzia (2009) que classificaram o reservatório como hipereutrófica na estação chuvosa de janeiro de 2006 e eutrófica durante a estação seca de junho de 2005.

3.2 Conjunto de dados *in situ*

Neste estudo foram utilizados dados adquiridos em oito campanhas de campo (Tabela 3.1 e Figura 3.3) no reservatório de Ibitinga (obtidos no corpo principal do reservatório devido a limitações logísticas). Com relação as estações amostrais presentes na Figura 3.3A, Londe (2008) procurou fazer as medições em pontos que representassem um gradiente de diferentes concentrações de chl-*a*, com ênfase para os pontos mais eutrofizados do reservatório. Já na Figura 3.3B, a escolha do local de amostragem, no caso entre a barragem e a foz do rio Jacaré Pepira, foi de acordo com a maior recorrência de florações entre essas duas regiões em períodos de maior residência hidráulica (setembro e outubro) (Cairo, 2015).

De todos os dados coletados nessas campanhas, foram usadas as medidas de concentração da chl-*a* e os dados radiométricos para o desenvolvimento desta tese (metodologia de obtenção das medidas de campo descrita em Londe (2008) e Cairo (2015)). A concentração de chl-*a* foi obtida pela metodologia de Nusch (1980) (metodologia do autor descrita em Cairo (2015)) e os dados radiométricos foram coletados usando diferentes equipamentos e protocolos. Londe (2008) coletou os dados radiométricos usando *ASD FieldSpec Hand Held*, já nos campos de Cairo (2015), novembro/2013, setembro/2014 e agosto/2018 foram utilizados o radiômetro TriOs. Nas medidas de Londe (2008), para cada estação amostral, foram feitas a calibração com a placa de referência e pelo menos três medições sucessivas do fator de reflectância bidirecional (FRB – Equação 3.1) da água, para que fosse possível descartar espectros com problemas durante a análise dos dados. Já para o TriOs, uma série de medidas de radiância e irradiância (*above-water* e

in-water) foram coletadas para cada estação amostral (metodologia de aquisição e processamento dos dados descrita em Cairo (2015) e Cairo et al. (2017)).

$$FR(\theta_i, \phi_i; \theta_o, \phi_o; \lambda) = \frac{La(\theta_i, \phi_i; \theta_o, \phi_o; \lambda)}{Lr(\theta_i, \phi_i; \theta_o, \phi_o; \lambda)} \quad (3.1)$$

Em que FR é o fator de reflectância, La é a radiância da amostra e Lr é a radiância de uma superfície lambertiana ideal, ambas nas mesmas condições de iluminação e observação. Vale ressaltar que esse fator é considerado bidirecional quando os ângulos sólidos envolvidos na medição são menores que 20° (MILTON, 1987).

A R_{rs} foi calculada para os dados de Cairo (2015) e dos campos de novembro/2013, setembro/2014 e agosto/2018 usando a equação presente em Kirk (2011) (Equação 3.2). Para transformar as medidas de FRB de Londe (2008) (com resolução espectral de 1 nm) em R_{rs} , dividiu-as por π (OOWB, 2020). Além disso, foi aplicado um filtro de média com tamanho de janela 9 nos espectros de R_{rs} de Londe (2008) para minimizar ruído.

$$R_{rs}(\theta, \Phi, \lambda) = \frac{L_w(\theta, \Phi, \lambda)}{E_s(\lambda)} \quad (3.2)$$

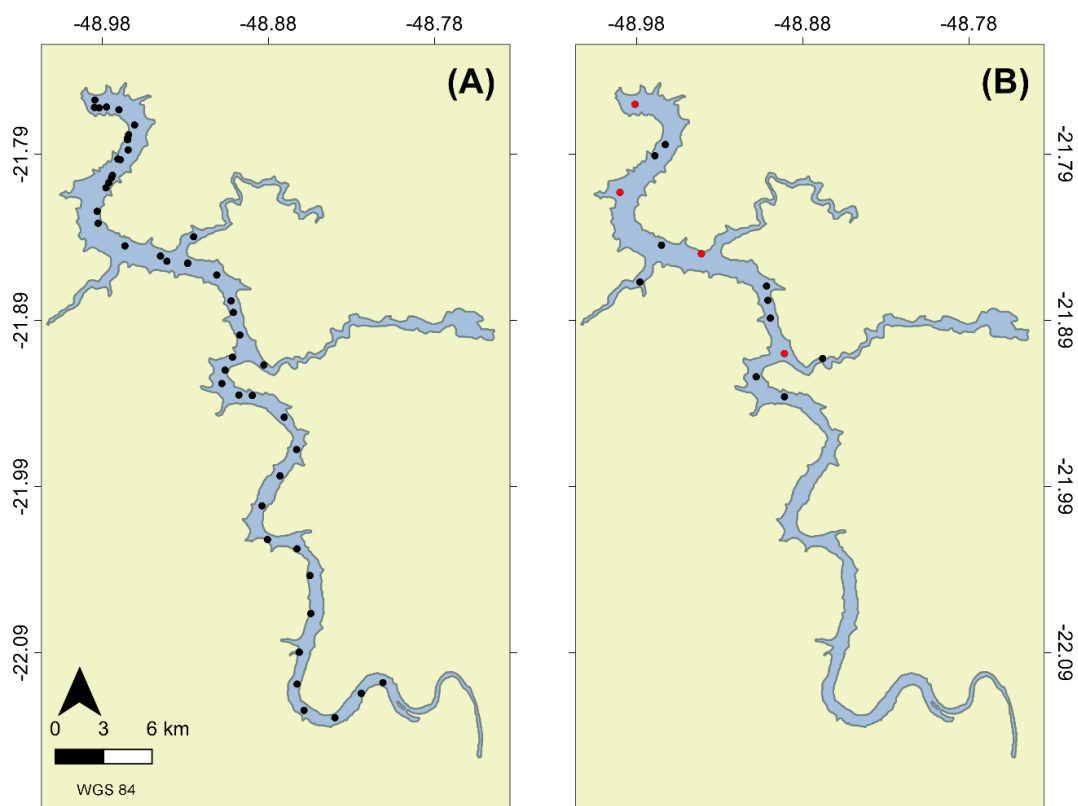
Sendo $L_w(\theta, \Phi, \lambda)$ a radiância espectral emergente da coluna água na direção (θ, Φ) medida acima da superfície e detectada pelo sensor fixo ao barco apontado para a água e $E_s(\lambda)$ é a irradiância incidente na superfície da água (MUELLER et al., 2003).

Como os dados radiométricos foram coletados com equipamentos e protocolos distintos, a R_{rs} calculada foi corrigida usando diferentes métodos de correção especular (*glint*). Para a R_{rs} obtida pelos dados de Londe (2008) aplicou-se a metodologia de Kutser et al. (2013), pois durante a campanha de campo não foi medida em cada estação amostral a radiância difusa na atmosfera (L_s), que é considerada na correção do Mobley (1999, 2015). Já na R_{rs} obtida pelos dados do TriOs aplicou-se o método de Mobley (2015).

Tabela 3.1 - Informações sobre as campanhas de campo.

Campanhas de campo	Data	Total de estações amostrais	Varição da concentração da chl- <i>a</i> (mg/m ³)
Londe (2008)	24-28 de Outubro, 2005	51	6,14 – 76.804,84
	6 de Fevereiro, 2014		
Cairo (2015)	26 de Março, 2014	16	3,72 – 180,40
	13 de Maio, 2014		
	16 de Julho, 2014		
Nov/2013	1-2 de Novembro, 2013	10	2,89 – 32,10
Set/2014	18 de Setembro, 2014	4	54,17 – 258,83
Ago/2018	12-13 de Agosto, 2018	8	14,96 – 59,19

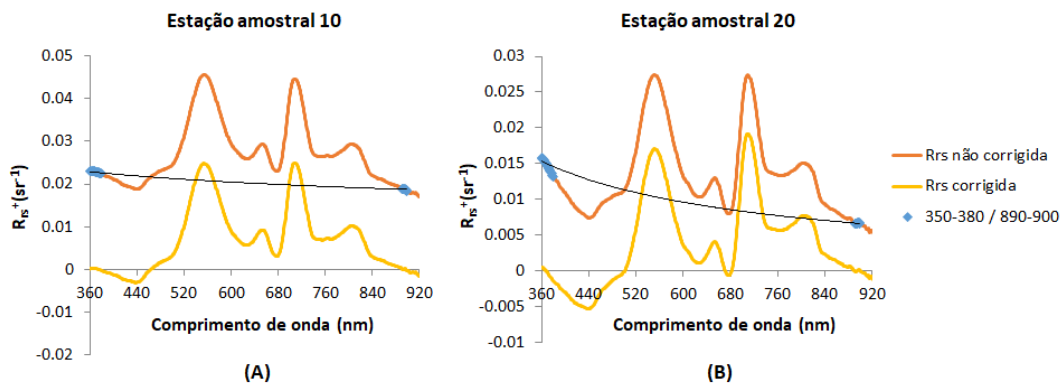
Figura 3.3 - Campanhas de campo da (A) Londe (2008) e da (B) Cairo (2015), nov/2013, set/2014 e ago/2018. Os pontos vermelhos em (B) são estações amostrais coletadas em todas as campanhas de 2013, 2014 e 2018.



Em cerca de 78% dos dados da Londe (2008) a correção do Kutser et al. (2013) superestimou o efeito de *glint*, o que resultou em valores de R_{rs} negativos em algumas regiões do espectro, principalmente na região do azul e do NIR, e também o espectro como um todo teve redução em magnitude, afetando bastante a região do vermelho e NIR. As razões por trás disso, segundo os autores, são o *match* não perfeito da função de potência na faixa espectral de 350-380 nm (comprimento de onda de referência que determina o *slope* da função de potência) e a existência de sinal emergente da água em torno de 900 nm devido a presença de águas opticamente rasas ou muito turvas (a suposição é que nessa região o sinal deveria ser próximo de 0).

Além disso, também ocorreram supercorreções (Figura 3.4) quando o espectro do *glint*, descrito pela função de potência gerada para os comprimentos de onda de referência (350-380 nm e 890-900 nm), era *flat* (*slope* insignificante – Figura 3.4A) e/ou quando o espectro do *glint* atravessava o espectro de R_{rs} *in situ* sem correção na região do azul (na maioria das vezes – Figura 3.4B). Isso acontece, principalmente, pelos espectros da Londe (2008) terem a presença marcante da absorção da chl-*a* em torno de 440 nm (elevadas concentrações de chl-*a*), o que é uma das grandes diferenças entre os espectros da autora e de Kutser et al. (2013). Outra questão que também dificultou a correção dos espectros de R_{rs} pela metodologia de Kutser et al. (2013) foi que vários espectros da Londe (2008) eram provenientes de *superblooms* (comportamento espectral de vegetação), e os autores relatam que o procedimento de correção do *glint* não funciona em circunstâncias em que os valores de reflectância na região do infravermelho são maiores que na região do visível.

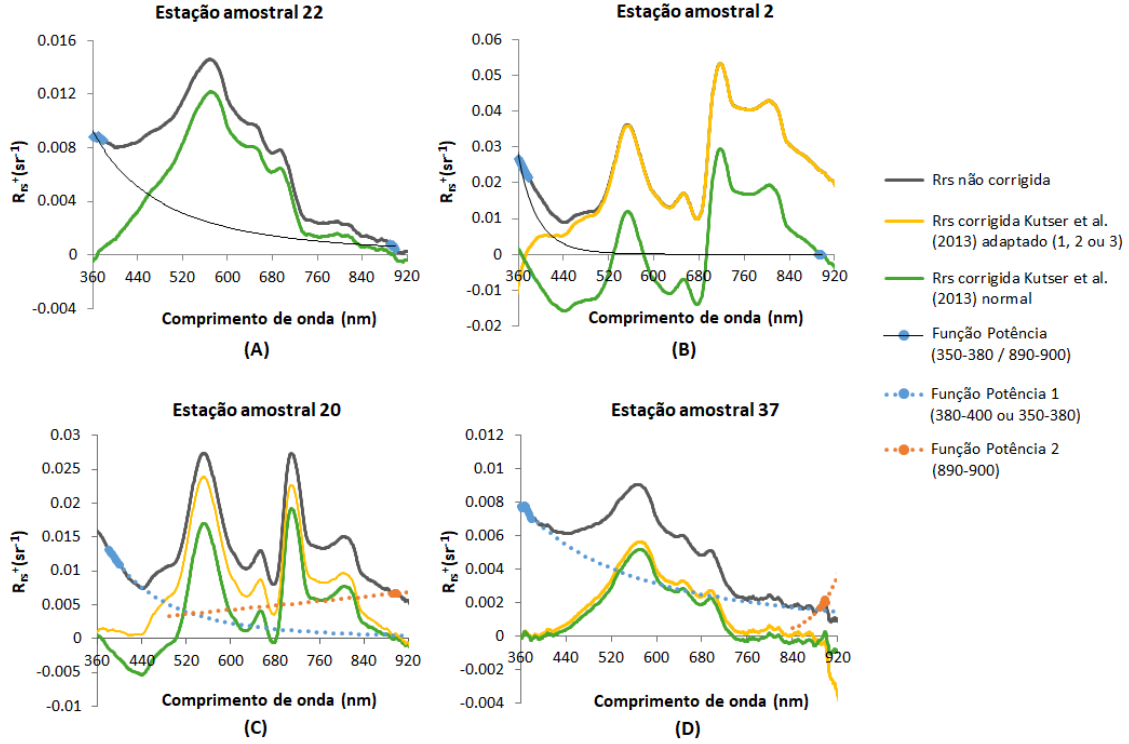
Figura 3.4 - Exemplos de supercorreções nas estações amostrais 10 (A) e 20 (B) dos dados de R_{rs} (λ) da Londe (2008), utilizando a metodologia proposta por Kutser et al. (2013). A linha contínua preta é a curva de potência ajustada entre os comprimentos de onda de referência (350-380 / 890-900 nm).



Como as regiões do vermelho e NIR são de interesse em algoritmos de estimativa da concentração da chl-*a* em águas opticamente complexas, uma vez que têm menor influência das absorções por CDOM e por NAP e maior correlação com a concentração da chl-*a* (GITELSON, 1992), foram testadas várias adaptações (Figura 3.5) do método de Kutser et al. (2013) de modo a reduzir esse efeito deletério. As adaptações se referem a mudança no intervalo do comprimento de onda de referência e/ou a quantidade de funções de potência utilizadas para a remoção do *glint*, e são indicadas para corrigir o *glint* em águas com maior contribuição de chl-*a*.

A primeira adaptação (Figura 3.5B) é usada quando o espectro é proveniente de *superbloom*, sendo que as faixas de comprimento de onda de referência de 350-380 nm e 890-900 nm são mantidas, mas os valores de 890-900 nm são considerados próximos de 0 para que a função de potência consiga ser construída e subtraída do espectro bruto. A segunda adaptação (Figura 3.5C) modifica a primeira faixa de comprimento de onda de referência de 350-380 nm para 380-400 nm, pois a maioria dos espectros possuem absorção em 440 nm e a faixa antiga de referência faz com que a função de potência atravesse o espectro de R_{rs} nessa região. Além disso, são considerados duas funções de potência para a subtração do espectro sem correção, a primeira é gerada apenas com os valores da faixa de comprimento de onda de referência de 380-400 nm e a segunda é gerada apenas com os valores da faixa de 890-900 nm. As duas funções de potência geradas se cruzam em um determinado comprimento de onda, assim cada uma é subtraída do espectro sem correção até ou a partir do ponto de cruzamento. A terceira adaptação (Figura 3.5D) segue a mesma linha de raciocínio que a segunda, a única diferença é que a faixa de comprimento de onda de referência é a mesma considerada pelos autores (350-380 nm e 890-900 nm). Tais adaptações de Kutser et al. (2013) reduziram os efeitos de supercorreção dos espectros, impedindo ou minimizando o surgimento de valores negativos na região do azul e do NIR e/ou minimizando a redução brusca da magnitude do espectro na região do vermelho e do NIR.

Figura 3.5 - Exemplos de correções da $R_{rs}(\lambda)$ *in situ* de algumas estações amostrais da Londe (2008) pela metodologia de: (A) Kutser et al. (2013) normal, (B) Kutser et al. (2013) adaptação 1, (C) Kutser et al. (2013) adaptação 2 e (D) Kutser et al. (2013) adaptação 3.



Vale ressaltar também que para determinar o espectro de R_{rs} corrigido mais representativo do conjunto de medidas obtidas pelo TriOs para cada estação amostral (total de 38 estações amostrais), calculou-se a mediana de cada conjunto, sendo escolhido para representar a amostra o espectro de R_{rs} mais próximo da mediana. Além disso, os espectros de R_{rs} que possuíam alguma inconsistência visível foram excluídos do conjunto de dados. Por fim, as bandas do sensor MSI/Sentinel-2 foram simuladas com uso dos dados de R_{rs} *in situ* corrigidos (69 estações amostrais), baseado na função de resposta espectral do sensor (ESA, 2018), de acordo com a Equação 3.3.

$$R_{rs_{simul}}(B_i) = \frac{\int_{\lambda_n}^{\lambda_m} SRF(\lambda) \times R_{rs_{insitu}} d\lambda}{\int_{\lambda_n}^{\lambda_m} SRF(\lambda) d\lambda} \quad (3.3)$$

Em que $R_{rs_{simul}}(B_i)$ é a R_{rs} simulada para a i -ésima faixa espectral do sensor MSI/Sentinel-2, $SRF(\lambda)$ é a função de resposta espectral do sensor MSI/Sentinel-2 em

um comprimento de onda específico e a R_{rs_insitu} é a R_{rs} medida em campo para o intervalo $n \rightarrow m$ que compõe a faixa espectral do sensor MSI/Sentinel-2. Vale ressaltar que o sensor MSI/Sentinel-2 foi considerado neste trabalho por apresentar resoluções temporal, espectral e espacial adequadas para o monitoramento da chl-*a* por SR na região de estudo.

3.3 Classificação limnológica e espectral

A partição da faixa de valores de concentração de chl-*a* em intervalos adequados para a calibração dos algoritmos bio-ópticos, considerando valores de até 1000 mg/m³, foi realizada usando dois tipos de métodos, no caso o limnológico e o óptico. A partir desses métodos, os espectros de R_{rs} *in situ* foram agrupados em classes ópticas de faixas específicas de concentração da chl-*a*.

No método limnológico, a divisão das faixas de concentração de chl-*a* foi baseada nos intervalos de concentração de chl-*a* do IET para reservatórios da CETESB (CETESB, 2017). No caso, agrupou-se os estados tróficos “oligotrófico e mesotrófico”, “eutrófico e supereutrófico” e “hipereutrófico” para gerar três faixas específicas de concentração da chl-*a* que indicam, respectivamente, corpos d’água com: i) “OligoMeso” - baixo à moderado enriquecimento por nutrientes; com possíveis implicações sobre a qualidade da água, mas em níveis aceitáveis; sem comprometer a existência da vida no ecossistema aquático; ii) “EutroSuper” - elevado enriquecimento por nutrientes; com redução da transparência; tendo com certa frequência alterações indesejáveis na qualidade da água, como episódios de florações de algas, e interferência nos múltiplos usos; redução do oxigênio dissolvido na água; e iii) “Hiper” - máximo enriquecimento por nutrientes; qualidade da água afetada de forma significativa, com produtividade excessiva de algas e plantas aquáticas; comprometimento acentuado dos múltiplos usos; redução drástica do oxigênio dissolvido, provocando a mortandade de peixes. Vale ressaltar que a definição das faixas de chl-*a* foi qualitativa, ou seja, não foi baseada nos dados quantitativos dos parâmetros mencionados. No final, os espectros de R_{rs} do conjunto de dados foram agrupados em cada faixa específica de concentração da chl-*a*, estabelecida acima, de acordo com seu valor de chl-*a* associado, obtendo assim três classes ópticas de faixas específicas de concentração da chl-*a*.

No método óptico, a divisão das faixas de concentração de chl-*a* foi baseada no formato dos espectros de R_{rs} *in situ*. Para isso, usou-se a técnica *Spectral Angle Mapper* (SAM) (KRUSE et al., 1993) com classificação supervisionada. SAM é um algoritmo que procura encontrar semelhanças entre as curvas espectrais e espectros de referência, cujas propriedades óticas são previamente conhecidas (BARBOSA et al., 2019). A semelhança é calculada em função da proximidade geométrica dos dois espectros. Os espectros são tratados como vetores em um espaço de dimensão igual ao número de bandas existentes nos dados. O cálculo da distância entre as duas curvas é uma medida geométrica dada pelo valor do arco-cosseno do produto escalar do vetor da imagem e do espectro de referência; ou seja, o algoritmo SAM determina o grau de similaridade d de um determinado espectro teste t com relação a um espectro de referência r , aplicando a Equação 3.4.

$$d = \cos^{-1} \left(\frac{\vec{t} \cdot \vec{r}}{\|\vec{t}\| \cdot \|\vec{r}\|} \right) \quad (3.4)$$

Numericamente, a Equação 3.3 pode ser representada pela Equação 3.5,

$$d_{i,j} = \cos^{-1} \left(\frac{\sum_{k=1}^n (t_{i,k} r_{j,k})}{\sqrt{\sum_{k=1}^n t_{i,k}^2 \sum_{k=1}^n r_{j,k}^2}} \right), \quad (3.5)$$

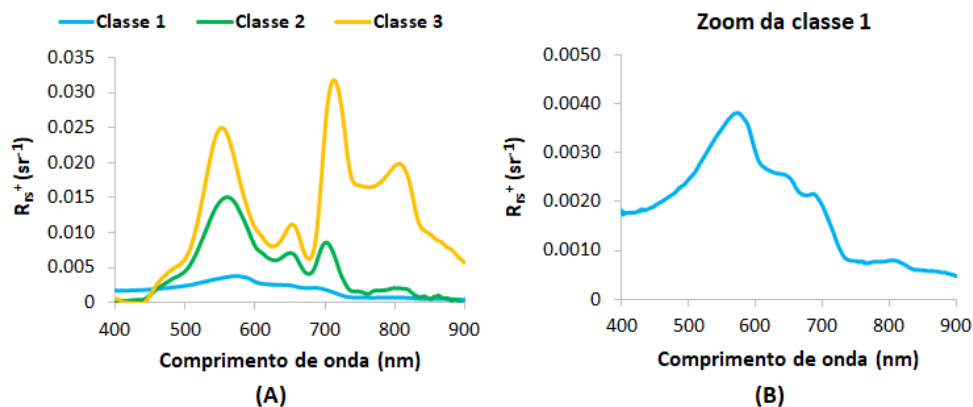
em que i é o número de espectros contidos no conjunto de amostras, j o número de espectros de referência que serão utilizados para comparação e k é o número de elementos, ou bandas da curva espectral; assume-se que as curvas espectrais e de referência possuem o mesmo número de bandas espectrais. Cada amostra será atribuída à classe com menor distância em relação ao espectro de referência. Esta técnica não é sensível às diferenças de magnitudes das curvas, pois o ângulo entre os dois vetores é invariante aos seus comprimentos. Isto faz com que o algoritmo seja pouco sensível aos efeitos de iluminação e albedo.

No cálculo do SAM foi considerada a faixa espectral de 600 à 825 nm dos espectros de R_{rs} *in situ*, por 3 motivos: A) é a faixa espectral na qual ocorre a maior mudança na forma

do espectro em função do aumento da concentração da chl-*a* em águas opticamente complexas; B) os algoritmos bio-ópticos testados nesse trabalho focam em comprimentos de onda presentes nessa faixa espectral; e C) trabalhos que usam classificação óptica na estimativa da concentração da chl-*a* em águas opticamente complexas também focam em comprimentos de onda presentes nessa faixa espectral (LE et al., 2011; SHI et al., 2013).

O método óptico é o processo inverso do método limnológico, visto que primeiro são estabelecidas as classes ópticas e a partir delas as faixas específicas de concentração. Assim, para gerar a classificação pelo SAM, primeiramente, definiram-se três espectros de referência (Figura 3.6) representativos de valores baixos, médios e elevados de concentração de chl-*a* do conjunto de dados. Considerou-se a divisão de três classes ópticas de faixas específicas de concentração da chl-*a* tendo em vista a necessidade dos sistemas de monitoramento em classificar as águas em níveis de floração associados a concentrações baixas, médias e altas de chl-*a*. O espectro de referência da classe 1 é equivalente a uma concentração de chl-*a* de aproximadamente 3 mg/m³, da classe 2 de 40 mg/m³ e da classe 3 de 380 mg/m³. Por fim, o SAM agrupou os espectros de R_{rs} *in situ* em três classes ópticas de acordo com os espectros de referência e as faixas específicas de concentração da chl-*a* foram determinadas considerando os valores mínimo e máximo de chl-*a* de cada classe. Vale ressaltar que foram testados outros espectros de referência do conjunto de dados para o cálculo do SAM com classificação supervisionada, mas os espectros de referência mostrados na Figura 3.6A foram os que geraram melhores resultados (melhor divisão das classes ópticas).

Figura 3.6 - (A) Classes de referência utilizadas no SAM; (B) o zoom na classe 1 foi com o objetivo de focar na forma do espectro de referência, e assim conseguir comparar com a forma das outras duas classes.



Vale ressaltar também que foi testado o SAM com classificação não-supervisionada pelo método do *K-means* (BARBOSA, 2005), considerando 3 classes. Entretanto, o agrupamento dos espectros foi desigual, gerando classe com no máximo 8 espectros, o que inviabilizava a calibração/validação dos algoritmos bio-ópticos na respectiva classe com esse número amostral.

3.4 Algoritmos bio-ópticos de estimativa da concentração da chl-*a*

A análise da literatura ajudou a identificar uma série de algoritmos bio-ópticos cuja eficácia para a estimativa da concentração da chl-*a* já fora comprovada no estudo de águas opticamente complexas. Esses algoritmos foram então avaliados (Tabela 3.2), incluindo aqueles já testados em abordagens híbridas (MATSUSHITA et al., 2015; SMITH et al., 2018).

Tabela 3.2 - Tipos e equações dos algoritmos bio-ópticos para a estimativa da concentração da chl-*a* baseado nas bandas do MSI/Sentinel-2, em que λ_1 , λ_2 , λ_3 , e λ_4 são B3 (560 nm), B4 (665 nm), B5 (705 nm) e B6 (740 nm), respectivamente. λ_x e λ_y se referem a combinação de bandas “B4 e B3”, “B5 e B3”, “B5 e B4”, “B6 e B3”, e “B6 e B4”.

Tipos de Algoritmos	Equações
Razões simples de bandas	$\frac{R_{rs}(\lambda_2)}{R_{rs}(\lambda_1)}, \frac{R_{rs}(\lambda_3)}{R_{rs}(\lambda_1)}, \frac{R_{rs}(\lambda_3)}{R_{rs}(\lambda_2)}, \frac{R_{rs}(\lambda_4)}{R_{rs}(\lambda_1)}, \frac{R_{rs}(\lambda_4)}{R_{rs}(\lambda_2)}$
Gilerson et al. (2010)	$chl_a = \left(\left(35.75 \times \frac{R_{rs}(\lambda_3)}{R_{rs}(\lambda_2)} \right) - 19.3 \right)^{1.124}$
Gitelson et al. (2011a)	$chl_a \approx \left(\left(\frac{1}{R_{rs}(\lambda_2)} - \frac{1}{R_{rs}(\lambda_3)} \right) \times R_{rs}(\lambda_4) \right)$
Mishra e Mishra (2010)	$Slope = \frac{R_{rs}(\lambda_x) - R_{rs}(\lambda_y)}{\lambda_x - \lambda_y}$
Mishra e Mishra (2012)	$NDCI = \frac{R_{rs}(\lambda_x) - R_{rs}(\lambda_y)}{R_{rs}(\lambda_x) + R_{rs}(\lambda_y)}$
Gower et al. (2005)	$MCI = R_{rs}(\lambda_3) - R_{rs}(\lambda_2) - \left[\left(\frac{\lambda_3 - \lambda_2}{\lambda_4 - \lambda_2} \right) \times (R_{rs}(\lambda_4) - R_{rs}(\lambda_2)) \right]$

As razões de bandas usadas nesse estudo (Tabela 3.2) foram ajustadas para corresponderem às bandas do MSI/Sentinel-2 (ESA, 2019; Tabela 3.3), pois muitos desses algoritmos foram desenvolvidos para dados *in situ* ou para outros sensores. Portanto, as combinações de bandas aplicadas foram B4-B3, B5-B3, B5-B4, B6-B3 e B6-B4. Essas bandas foram escolhidas primeiro de acordo com a literatura (GITELSON et al., 2011a; HA et al., 2017; LINS et al., 2017; MATSUSHITA et al., 2015; MISHRA; MISHRA, 2010, 2012; WATANABE et al., 2017), em seguida, novas combinações foram testadas (B5-B3, B6-B3, B6-B4) para condições de eutrofização extremamente críticas. Essas bandas foram consideradas, dado que quanto maior a concentração de chl-*a*, mais significativas são as diferenças entre os valores de bandas B5-B3 (705 nm e 560 nm), B6-B3 (740 nm e 560 nm) e B6-B4 (740 nm e 665 nm). Em áreas com alta concentração de chl-*a*, a R_{rs} é muito maior nos comprimentos de onda de 705 nm e 740 nm do que a medida em áreas com concentrações mais baixas de chl-*a* (KIRK, 2011).

Tabela 3.3 – Especificações das bandas do sensor MSI/Sentinel-2. SNR é a relação sinal ruído, e L_{ref} é a radiância de referência.

Bandas	Intervalo das bandas espectrais (nm)	Comprimento de onda central (nm)	Resolução espacial (m)	Resolução radiométrica (bits)	SNR na L_{ref}
B3 (<i>green</i>)	537,3 – 582,3	560	10	12	168
B4 (<i>red</i>)	645,6 – 683,3	665	10	12	142
B5 (<i>red-edge</i>)	694,6 – 713,6	705	20	12	117
B6 (<i>red-edge</i>)	731,5 – 749,5	740	20	12	89
B11 (SWIR)	1542,2 – 1685,2	1614	20	12	100
B12 (SWIR)	2081,4 – 2323,4	2202	20	12	100

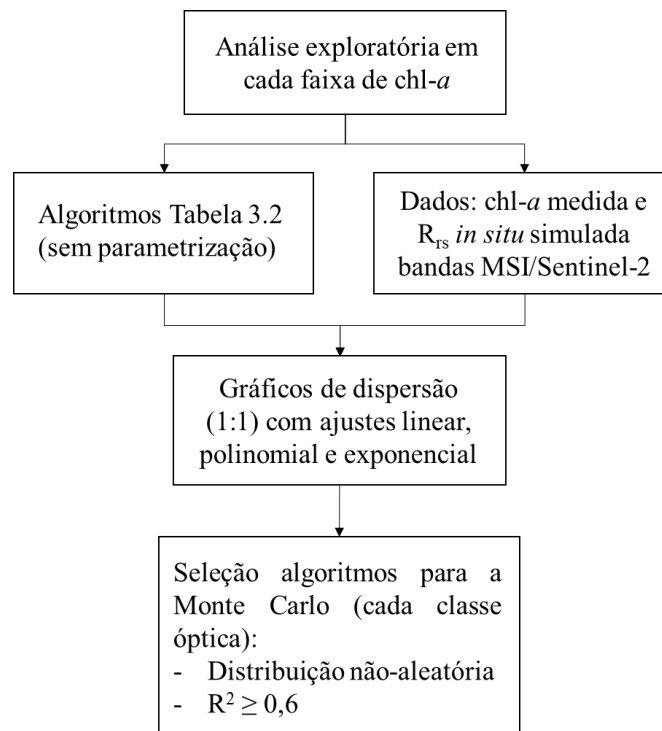
Fonte: ESA (2019).

3.5 Calibração e validação dos algoritmos bio-ópticos

Antes de calibrar/validar os algoritmos, uma análise exploratória (Figura 3.7) de todos os algoritmos bio-ópticos listados na Tabela 3.2 foi realizada de forma a selecionar os mais adequados para cada faixa específica de concentração da chl-*a*, reduzindo assim o número de algoritmos testados na simulação Monte Carlo. Para isso, foram feitos gráficos de

dispersão, em cada intervalo de chl-*a*, entre os valores de chl-*a* medidos e seus respectivos valores determinados a partir dos dados de R_{rs} *in situ* simulados para as bandas do MSI/Sentinel-2, usando o conjunto de dados de cada faixa. Os algoritmos bio-ópticos (Tabela 3.2) foram utilizados em sua forma original, sem qualquer parametrização dos coeficientes. Ajustes linear ($y = ax + b$), exponencial ($y = ae^{bx}$) e polinomial ($y = ax^2 + bx + c$) foram aplicados em cada gráfico de dispersão, e os respectivos coeficientes de determinação (R^2) foram computados. Os critérios para a seleção dos algoritmos submetidos à simulação Monte Carlo foram: i) existência de uma tendência na dispersão “chl-*a* medida *versus* chl-*a* modelada” (dispersão mais próxima da linha 1:1), não sendo, portanto, uma distribuição aleatória; ii) $R^2 \geq 0,6$ em pelo menos um dos três ajustes testados. Cabe lembrar que como os algoritmos bio-ópticos presentes na Tabela 3.2 não foram gerados para as bandas do MSI/Sentinel-2, então possíveis erros ou diferenças podem ser esperados na comparação com as medidas *in situ*.

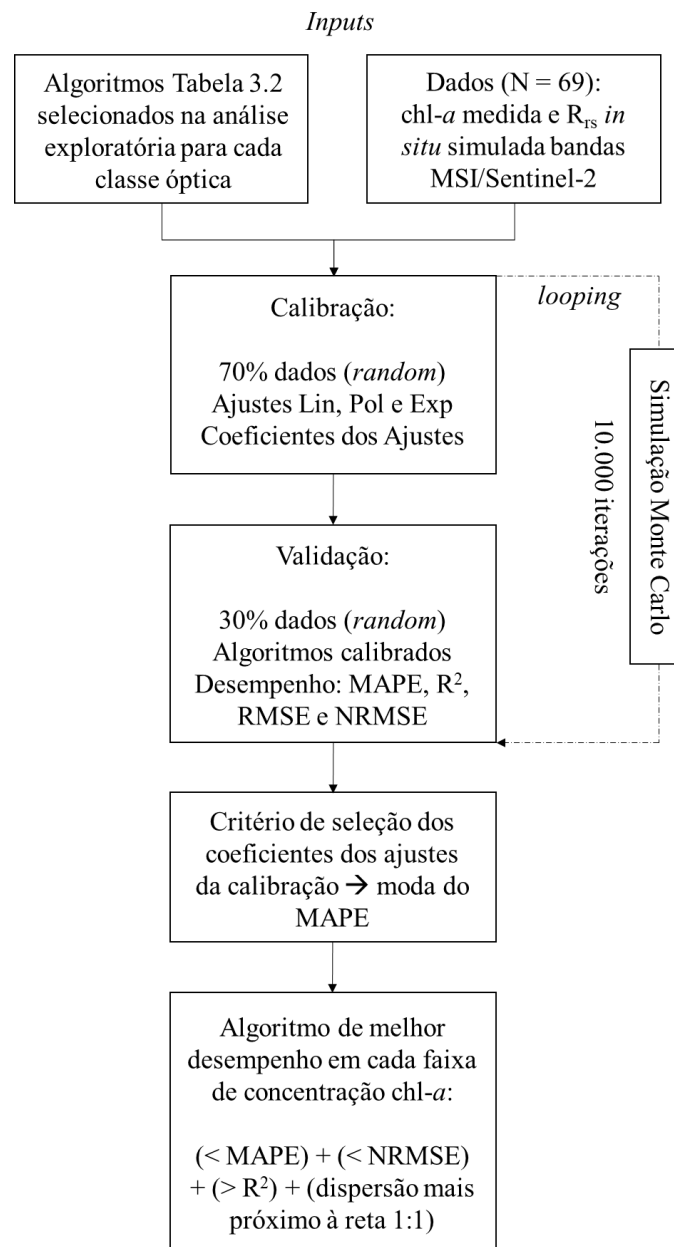
Figura 3.7 – Fluxograma da análise exploratória.



Para o processo de calibração/validação dos algoritmos bio-ópticos selecionados pela análise exploratória para cada classe óptica de faixa específica de concentração de chl-*a*, utilizou-se a simulação Monte Carlo (Figura 3.8) com 10.000 iterações, considerando os

valores de R_{rs} *in situ* simulados para as bandas do MSI/Sentinel-2. O objetivo do uso da Monte Carlo foi de superar o número limitado de estações amostrais (69 estações amostrais) para a calibração/validação dos algoritmos.

Figura 3.8 - Fluxograma da simulação Monte Carlo.



Para cada iteração, a etapa de calibração usou 70% de todo o conjunto de dados (Tabela 3.1), sendo as amostras escolhidas de forma aleatória e regredidas usando os mesmos ajustes linear, polinomial e exponencial da análise exploratória. Além disso, os valores

dos coeficientes dos ajustes foram gravados ao final de cada regressão. Na etapa de validação, usaram-se os 30% restantes das amostras para comparar os valores de chl-*a* medidos com os estimados pelos algoritmos bio-ópticos calibrados, sendo que as métricas estatísticas de desempenhos usadas foram: Erro Médio Absoluto Percentual (MAPE – Equação 3.6), R², Raiz do Erro Médio Quadrático (RMSE – Equação 3.7) e Raiz do Erro Médio Quadrático Normalizado (NRMSE – Equação 3.8).

$$MAPE = 100 \times \frac{\sum_{i=1}^n \left| \frac{(y_i - x_i)}{x_i} \right|}{N} \quad (3.6)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^n (x_i - y_i)^2} \quad (3.7)$$

$$NRMSE = \left(\frac{RMSE}{(x_{max} - x_{min})} \right) \times 100 \quad (3.8)$$

Em que x_i é o valor da concentração da chl-*a* obtido *in situ* para a estação i , y_i é o valor estimado da concentração da chl-*a* para a estação i , x_{max} e x_{min} são os valores máximo e mínimo de concentração da chl-*a* do conjunto de dados.

O critério de seleção utilizado na determinação dos coeficientes dos ajustes mais representativos da calibração foi baseado no cálculo da moda do MAPE das 10.000 iterações, gerado para cada ajuste de cada algoritmo bio-óptico. Vale ressaltar que o MAPE foi escolhido pois fornece erros percentuais absolutos que permitem a comparação entre diferentes algoritmos independentemente do conjunto de dados utilizado e faixas de concentração (MAKRIDAKIS, 1993).

De todos os algoritmos bio-ópticos otimizados na simulação Monte Carlo (moda do MAPE) para cada faixa de concentração da chl-*a*, os de melhor desempenho foram selecionados de acordo com duas etapas. Na primeira etapa, em cada classe óptica, escolheram-se os algoritmos com o menor MAPE e NRMSE bem como com maior R²

(resultado da validação). Na segunda etapa, cada conjunto de algoritmos selecionado para cada faixa de chl-*a* foi aplicado ao conjunto de dados da respectiva faixa, resultando em gráficos de dispersão (chl-*a* medida *versus* estimada, linha 1:1). Ao final, o algoritmo de melhor desempenho para cada faixa específica de chl-*a* foi aquele que resultou em uma dispersão mais próxima da linha 1:1.

Além disso, os modelos de melhor desempenho para cada classe óptica dos métodos limnológico e óptico também foram calibrados e validados em intervalos de concentrações de chl-*a* mais amplos, como valores até 600 mg/m³ e até 1000 mg/m³, usando dados de R_{rs} *in situ* simulados para as bandas do MSI/Sentinel-2. Essa etapa teve como objetivo comparar o desempenho dos modelos em faixas mais amplas e em faixas mais específicas de concentração.

3.6 Construção dos modelos híbridos

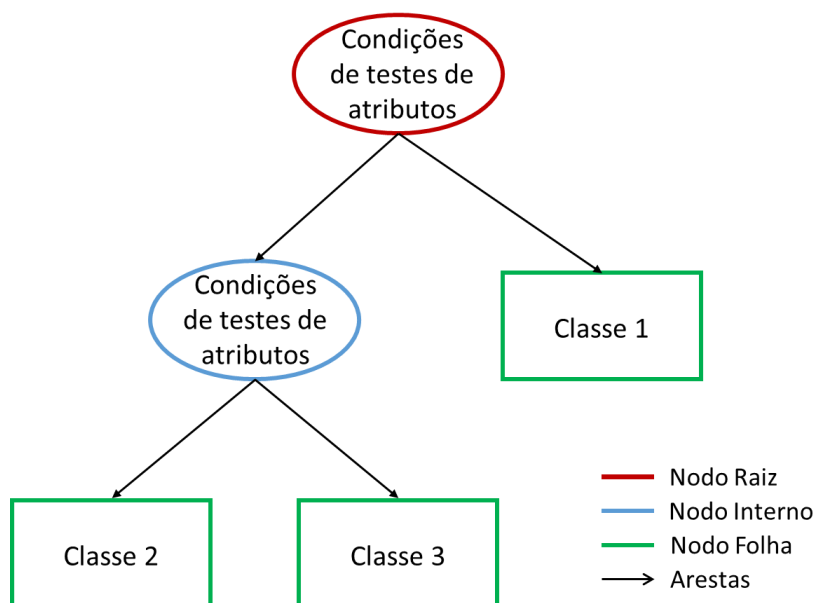
Foram desenvolvidos dois tipos de modelos híbridos de acordo com os métodos usados para particionar o conjunto de valores de concentração de chl-*a* em faixas específicas de concentração, descritos na seção 3.3, no caso o Modelo Híbrido Limnológico (MHL) e o Modelo Híbrido Óptico (MHO). Para a construção dos modelos híbridos, usou-se o modelo de classificação por árvore de decisão (TAN et al., 2006), que atribui um algoritmo específico a cada pixel da imagem, de acordo com a classe óptica estabelecida para cada pixel, usando regras de decisão definidas por valores limiares.

De maneira geral, uma técnica de classificação é uma abordagem sistemática para a construção de modelos de classificação a partir de um conjunto de dados de entrada. Os dados de entrada são um conjunto de registros, sendo que cada registro é caracterizado por uma dupla (x,y) , em que x é o conjunto de atributos (atributos discretos ou contínuos, podendo ser binários, nominais, ordinais e contínuos) e y o rótulo da classe (atributo discreto). Cada técnica de classificação emprega um algoritmo de aprendizagem para identificar um modelo que seja mais apropriado para o relacionamento entre o conjunto de atributos e o rótulo da classe dos dados de entrada. O modelo gerado deve se adaptar bem aos dados de entrada e prever corretamente os rótulos de classes de registros desconhecidos. Para isso, o conjunto de dados de entrada deve ser dividido em conjunto

de treinamento e conjunto de teste. Primeiramente, o conjunto de treinamento é usado para construir um modelo de classificação, e subsequentemente é aplicado ao conjunto de teste para avaliar seu desempenho. A avaliação do desempenho de um modelo de classificação é baseada nas contagens de registros de testes previstos correta e incorretamente pelo modelo, sendo tabuladas em uma tabela conhecida como matriz de confusão. Além disso, também podem ser usados métricas de desempenho como por exemplo a precisão, recall, acurácia e taxa de erro (TAN et al., 2006).

A árvore de decisão possui uma estrutura hierárquica que consiste de nodos e arestas direcionadas (Figura 3.9). Os nodos podem ser: a) raiz – não possui arestas chegando, possui arestas saindo; b) internos – possui exatamente uma aresta chegando e duas ou mais saindo; e c) folha – possui uma aresta chegando e nenhuma saindo. Vale ressaltar que os nodos raiz e internos contêm condições de testes de atributos para separar registros que possuam características diferentes, e os nodos folha recebem um rótulo de classe. Além disso, a dinâmica da árvore de decisão é bem simples e direta. Inicia-se do nodo raiz, aplicando a condição de teste ao registro, e assim segue-se a ramificação baseado no resultado do teste. Isso conduzirá a um outro nodo interno, para o qual uma nova condição de teste é aplicada, ou então a um nodo folha, em que o rótulo da classe associado é atribuído ao registro.

Figura 3.9 - Exemplo da estrutura hierárquica de uma classificação por árvore de decisão.



Um algoritmo de aprendizagem que geralmente é usado no processo de construção de uma árvore de decisão é o algoritmo de Hunt (TAN et al., 2006). Nesse algoritmo, uma árvore de decisão cresce de uma forma recursiva pelo particionamento dos registros de treino em sucessivos subconjuntos mais puros. Cada passo recursivo do processo de crescimento da árvore deve selecionar uma condição de teste de atributo para dividir os registros em subconjuntos menores. No caso, o algoritmo fornece um método para a especificação da condição de teste, que varia de acordo com o tipo de atributo (binários, nominais, ordinais e/ou contínuos), e também uma métrica objetiva para a avaliação da qualidade de cada condição de teste. Vale ressaltar que uma condição de parada é necessária para terminar o processo de crescimento da árvore.

No estudo aqui apresentado, os dados de entrada para a árvore de decisão foram divididos em 70% como conjunto de treinamento e 30% como conjunto de teste, escolhidos aleatoriamente. Os atributos de entrada foram baseados nas abordagens híbridas de Le et al. (2011), Matsushita et al. (2015), Shi et al. (2013) e Smith et al. (2018): i) dados de R_{rs} *in situ* simulados para as bandas do MSI/Sentinel-2 (B3, B4, B5 e B6); ii) suas respectivas razões de bandas (como por exemplo B4/B3, B5/B3, B5/B4, B5/B6, B6/B3, B6/B4, B6/B5); iii) o *slope* entre as bandas “B3 e B4”, “B4 e B5” e “B5 e B6”; e iv) o *Maximum Chlorophyll Index* (MCI – Tabela 3.2). Esses tipos de atributos de entrada foram considerados com o intuito de aplicar o modelo híbrido pixel a pixel nas imagens MSI/Sentinel-2 de maneira simples e rápida.

Como os atributos de entrada (A) foram do tipo contínuo (ex.: números), a condição de teste do conjunto de treinamento foi expressa como um teste de comparação ($A \leq v$) ou ($A > v$) com resultados binários, sendo que o algoritmo da árvore de decisão considerou todas as divisões v possíveis, selecionando a que produziu a melhor partição. De maneira resumida, a condição de teste da árvore de decisão (valores limiares) é estabelecida seguindo os passos (Figura 3.10): a) ordenação crescente dos registros de treinamento; b) identificação das posições candidatas de divisão (v) a partir dos pontos intermediários entre dois valores ordenados adjacentes (55, 65, 72 e etc); c) contagem da quantidade de classes 1 e 2 que se encaixam em cada condição (“ \leq ” e “ $>$ ”); e d) cálculo do índice *Gini* para cada posição candidata. Esse processo é repetido para cada atributo de entrada

considerado (listados no parágrafo acima). Vale ressaltar que o índice *Gini* (Equação 3.9) foi usado para selecionar a melhor partição, pois essa métrica mede a probabilidade de uma variável específica ser classificada incorretamente quando é escolhida aleatoriamente (TAN et al., 2006). O *Gini* varia entre 0 e 1, em que 0 indica que todos os elementos pertencem a uma classe específica (maior separabilidade entre classes) e 1 indica que os elementos são distribuídos aleatoriamente por várias classes (menor separabilidade entre classes). Assim, a melhor posição de divisão corresponde à que produz o menor valor do índice *Gini*. Por fim, o treinamento da árvore de decisão foi interrompido quando classificou pelo menos 95% dos dados de treinamento.

Figura 3.10 – Exemplo de divisão dos atributos de entrada (A) contínuos, usando a razão de bandas B5/B4 com valores fictícios. Esse processo é repetido para todos os registros de treinamento, no caso todas as razões de bandas consideradas.

Classe	B5/B4																					
Valores ordenados →	60	70	75	85	90	95	100	120	125	220												
Posições Divididas →	55	65	72	80	87	92	97	110	122	172	230											
	<=	>	<=	>	<=	>	<=	>	<=	>	<=	>										
Classe 1	0	3	0	3	0	3	0	3	1	2	2	1	3	0	3	0	3	0	3	0	3	0
Classe 2	0	7	1	6	2	5	3	4	3	4	3	4	3	4	4	3	5	2	6	1	7	0
Gini	0.420	0.400	0.375	0.343	0.417	0.400	<u>0.300</u>	0.343	0.375	0.400	0.420											

Fonte: Adaptado de Tan et al. (2006).

O desempenho da classificação foi avaliado a partir da análise da matriz de confusão, da precisão (Equação 3.10) e do *recall* (Equação 3.11). A precisão é uma medida da relevância dos resultados e o *recall* é uma medida da sensibilidade do algoritmo de classificação. Assim, valores elevados para os dois tipos de métricas de desempenho mostram que o classificador está retornando resultados precisos (alta precisão), e também com maior frequência de resultados positivos (algoritmo com alta sensibilidade).

$$Gini(t) = 1 - \sum_{i=0}^{c-1} [p(i/t)]^2 \quad (3.9)$$

$$Precisão = \frac{T_p}{T_p + F_p} \quad (3.10)$$

$$Recall = \frac{T_p}{T_p + F_n} \quad (3.11)$$

em que $p(i/t)$ é a fração de registros que pertencem à classe i em um determinado nodo t , T_p é o número de positivos verdadeiros, F_p é o número de positivos falsos e F_n é o número de falsos negativos.

3.7 Validação dos modelos híbridos com dados *in situ*

Para a validação dos modelos híbridos (MHL e MHO), com base em dados *in situ*, utilizaram-se os dados referentes aos 30% escolhidos de forma *random* na validação da Monte Carlo para cada faixa de concentração de chl-*a*. Além disso, o desempenho dos modelos híbridos foi avaliado usando as estatísticas MAPE, R² e NRMSE, como mencionado acima.

3.8 Aplicação dos modelos híbridos na imagem MSI/Sentinel-2

3.8.1 Correção atmosférica e correção do glint - validação

A imagem do sensor MSI/Sentinel-2 adquirida simultaneamente à campanha de campo de 13 de agosto de 2018 foi obtida no site da *United States Geological Service* (USGS) e corresponde ao tile T22KGA. A correção atmosférica baseou-se no modelo 6S (*Second Simulation Of The Satellite Signal In The Solar Spectrum*) (VERMOTE et al., 1997), parametrizado conforme descrito em Martins et al. (2017). Uma versão modificada do Py6S (WILSON, 2013) desenvolvida no Laboratório de Instrumentação de Sistemas Aquáticos (LabISA - <http://www.dpi.inpe.br/labisa/> - AtmosPy) foi usada para aplicar o 6S (CARLOS et al., 2019), que é um algoritmo de correção atmosférica de base física; seu bom desempenho em ecossistemas aquáticos interiores tropicais para recuperação de R_{rs} foi demonstrado por alguns autores (MACIEL et al., 2019; MARTINS et al., 2017). Em seguida, a imagem da reflectância da superfície foi dividida por π para obter a reflectância de sensoriamento remoto corrigida atmosfericamente ($R_{rs_atmcorr}$). Por fim, as bandas MSI/Sentinel-2 foram reamostradas para uma resolução espacial de 20 metros (somente as bandas que tinham resolução espacial diferente de 20 metros).

A validação da correção atmosférica foi executada da seguinte forma: i) o $R_{rs_atmcorr}$ foi determinado a partir da imagem (13 de agosto de 2018) como o valor médio dos pixels extraídos de uma janela de 3×3 pixels em cada estação amostral (lat/long; 8 estações) para reduzir os efeitos da relação sinal-ruído (*signal-to-noise ratio* - SNR) (JORGE et al., 2017); ii) a avaliação do desempenho da correção atmosférica foi baseada nas métricas estatísticas MAPE, R^2 e NRMSE, comparando o $R_{rs_atmcorr}$ extraído com o R_{rs} *in situ* simulado. Da mesma forma, o desempenho da correção atmosférica foi avaliado após a aplicação da correção do *glint* sobre a imagem, usando uma metodologia de subtração da banda do *shortwave infrared* (SWIR) proposta por Wang e Shi (2007), no caso considerando as bandas B11 e B12 do MSI/Sentinel-2.

Vale ressaltar que a correção do efeito de adjacência não foi considerada neste trabalho, mas é uma importante etapa a ser testada em trabalhos futuros, visto que o espalhamento múltiplo dos fótons das áreas adjacentes pode modificar o sinal espectral do pixel alvo (TANRE et al., 1981). Como o reservatório possui margens continentais próximas, compostas por regiões de cultivo e fragmentos de vegetação, a resposta espectral da água a partir da imagem pode ser afetada pelo efeito de adjacência das margens, que possuem uma reflectância muito maior que a água.

3.8.2 Validação dos modelos híbridos na imagem MSI/Sentinel-2

O MHL e MHO foram aplicados na imagem corrigida, gerando para cada modelo híbrido um mapa de classes ópticas e um mapa de estimativa da concentração da chl-*a*. Para a validação dos modelos híbridos na imagem, o valor estimado da chl-*a* foi extraído do mapa a partir da mediana de uma janela 3x3 pixels em cada estação amostral (lat/long) coletada na campanha de campo de Agosto/2018 (n = 8). Depois, as estatísticas R^2 , MAPE e NRMSE foram calculadas comparando esses valores estimados com as medidas *in situ* de concentração de chl-*a* dessa mesma campanha de campo. Vale ressaltar que essa etapa também foi testada considerando o valor estimado da chl-*a* extraído do mapa a partir da média de uma janela 3x3 pixels e a partir do valor do pixel (sem estabelecer uma janela), e o melhor resultado da validação foi usando a mediana de uma janela 3x3 pixels.

No mapa de classes ópticas, a classificação de cada estação amostral foi estabelecida a partir da moda de uma janela de 3x3 pixels, de modo a avaliar se a árvore de decisão classificou cada estação amostral de acordo com as classes ópticas determinadas a partir dos métodos limnológico e óptico presentes na seção 3.3. Nesse caso, optou-se por usar a moda pois desejava saber qual a classe óptica mais representativa da janela 3x3 pixels (a classe que mais aparecia).

3.8.3 Análise temporal das classes ópticas, da concentração da chl-a e do estado trófico

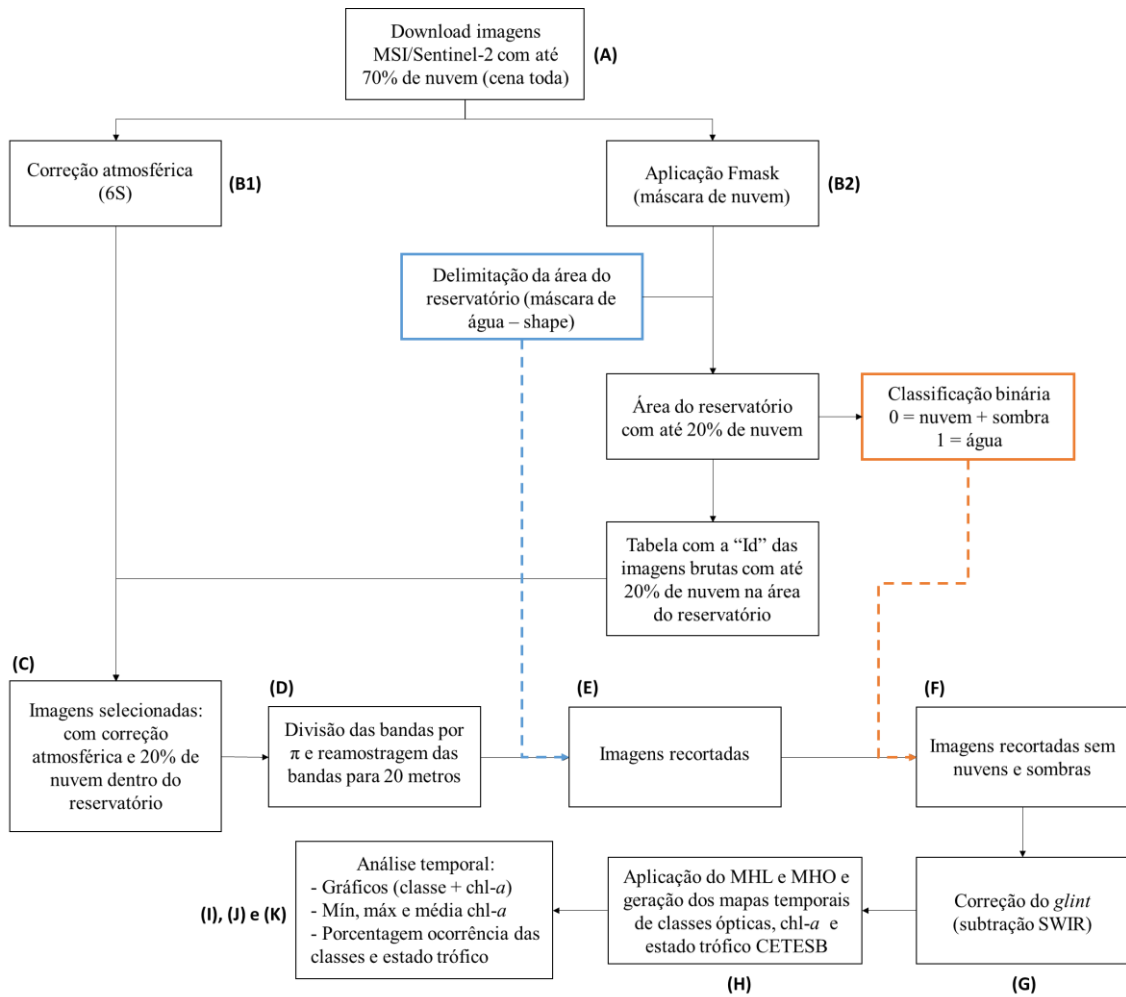
Para a análise temporal das classes ópticas, da chl-a e do estado trófico da CETESB, todas as imagens disponíveis do MSI/Sentinel-2 (A e B) de 2015 até Outubro/2019 para o reservatório de Ibitinga foram submetidas às correções atmosférica e do *glint* citadas anteriormente.

Para operacionalizar a análise temporal, permitindo o processamento em *batch*, desenvolveu-se uma rotina (na linguagem de programação Python) conforme (Figura 3.11) descrito:

- A) Download das imagens disponíveis do MSI/Sentinel-2 com menos de 70% de nuvem (na cena toda);
- B) Esta etapa foi dividida em duas sub-etapas. A sub-etapa B1 corresponde à aplicação da correção atmosférica nas imagens (usando *AmosPy*). Já a sub-etapa B2 corresponde à aplicação da ferramenta *python-Fmask* nas imagens. Em B2, foram geradas máscaras de nuvens para cada imagem considerando a área do reservatório (máscara de água) e um filtro de no máximo 20% de nuvem dentro do reservatório. Essa parte forneceu dois tipos de resultados. O primeiro resultado foi um *shape* do reservatório com classificação binária, sendo que foi atribuído para as classes nuvem e sombra o valor 0 e para a classe água o valor 1. O segundo resultado foi uma tabela com a identificação (“Id”) das imagens brutas com até 20% de nuvem na área do reservatório. Vale ressaltar que a máscara de água (delimitação da área do reservatório) foi gerada usando o *Modified Normalized Difference Water Index* (MNDWI; XU, 2006), a partir da imagem do MSI/Sentinel-2 do dia 13 de agosto de 2018 (imagem concomitante com a campanha de campo);

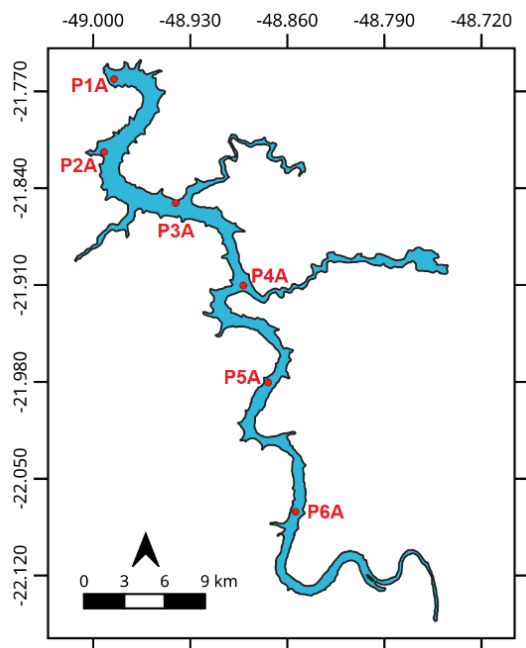
- C) Aplicou-se um filtro nas imagens corrigidas atmosféricamente de acordo com a tabela gerada em B2. O resultado é a seleção de imagens com correção atmosférica que possuem no máximo 20% de nuvem dentro da área do reservatório;
- D) As bandas das imagens filtradas foram divididas por π e reamostradas para 20 metros;
- E) Cada banda foi recortada a partir do *shape* da delimitação da área do reservatório (máscara de água). Vale ressaltar que não foi criado um *shape* de máscara de água para cada imagem, foi usado um *shape* único (mesmo descrito acima) para diferentes épocas do ano;
- F) Nas bandas recortadas foi aplicado o *shape* com classificação binária, gerado em B2, para a remoção das nuvens e sombras;
- G) Aplicação ou não da correção do *glint*. Se a correção for aplicada, então a R_{rs} das imagens nas bandas B3, B4, B5 e B6 é subtraída da R_{rs} das bandas B11 ou B12;
- H) Aplicação dos modelos híbridos (MHL e MHO) e geração dos mapas das classes ópticas, estimativa da concentração da *chl-a* e classificação do estado trófico da CETESB (fatiamento do mapa de estimativa da *chl-a* de acordo com a Tabela 2.4);
- I) Estabelecimento de pontos ao longo do reservatório (pontos escolhidos em áreas de presença/ausência de florações - Figura 3.12) para gerar gráficos de análise temporal (classe óptica + *chl-a* estimada), a partir de uma janela de 3x3 pixels (classe: usa a moda da janela; *chl-a*: usa a mediana da janela);
- J) Cálculo dos valores mínimo, máximo e médio mensal da concentração de *chl-a* estimada em todo o reservatório. Nessa etapa, primeiro agrupou-se todos os mapas de *chl-a* de um mesmo mês em cada ano. Depois, para cada mês, os valores de *chl-a* de cada pixel foram ordenados de forma crescente e aplicou o percentil, com o intuito de remover os *outliers* presentes nos 2% iniciais e finais do conjunto de dados. Por fim, considerando uma representatividade de 96% dos dados de *chl-a* estimada, os valores mínimo, máximo e médio mensais foram calculados.
- K) Cálculo da porcentagem de ocorrência das classes ópticas dos modelos híbridos e dos estados tróficos da CETESB nos meses dos anos disponíveis, a partir do tamanho da área de cada classe em relação à área total do reservatório.

Figura 3.11 – Fluxograma da rotina de análise temporal.



Na Figura 3.12 os pontos estão localizados: a) P1A próximo a barragem; b) P2A em uma região de meandro e próximo a uma agroindústria; c) P3A na foz do rio Jacaré-Guaçu, que é afetado pelo despejo de esgoto sem tratamento; d) P4A na foz do rio Jacaré-Pepira, que está presente em uma área de proteção ambiental, e próximo a uma grande piscicultura nas margens do reservatório no município de Itaju/SP; e) P5A próximo a um conjunto de casas nas margens do reservatório no município de Arealva/SP; e f) P6A próximo a uma grande piscicultura nas margens do reservatório entre os municípios de Arealva/SP e Bariri/SP.

Figura 3.12 - Pontos escolhidos ao longo do reservatório de Ibitinga para a análise temporal das classes ópticas e da concentração da chl-*a*.




4 RESULTADOS

4.1 Classes ópticas

A classificação supervisionada do SAM resultou em três classes ópticas (classes 1, 2 e 3), respectivamente representadas na Figura 4.1. A quantidade de amostras em cada classe óptica foi: 25 para a classe 1, 22 para a classe 2 e 22 para a classe 3.

Figura 4.1 - Espectros de R_{rs} *in situ* classificados pelo SAM. (A) Classe 1, (B) Classe 2 e (C) Classe 3. As setas indicam os picos de reflectância característicos de cada classe.




A classe 1 (Figura 4.1A) apresenta um pico de reflectância no verde (~560 nm) maior que os picos no vermelho (~650 nm) e infravermelho (~700 nm); pico no vermelho (~650 nm) maior que o pico no infravermelho (~700 nm); começa a surgir o pico em torno de 810 nm. A classe 2 (Figura 4.1B) possui um pico no verde (~550-560 nm) maior que os picos no vermelho (~650 nm) e infravermelho (~700-705 nm); pico no infravermelho (~700-705 nm) maior que o pico no vermelho (~650 nm); pico em torno de 810 nm começa a se tornar mais evidente, mas ainda é inferior aos outros três picos citados. Na Classe 3 (Figura 4.1C) o pico no verde (~550 nm) é maior que o do vermelho (~650 nm), mas pode ser um pouco maior, igual ou menor que o do infravermelho (~705-710 nm); o pico no vermelho (~650 nm) pode ser um pouco maior, igual ou menor que o do em torno de 810 nm; o pico em torno de 810 nm pode ser menor que os do verde (~550 nm) e infravermelho (~705-710 nm), mas pode também ser maior que ambos, formando um platô (comportamento espectral semelhante à vegetação).

Com relação ao método limnológico, a Figura 4.2 mostra a separação dos espectros de R_{rs} *in situ* para cada classe óptica de faixa específica de concentração de chl-*a* considerada. A quantidade de amostras em cada classe óptica foi: 13 para a classe

“OligoMeso”, 31 para a classe “EutroSuper” e 25 para a classe “Hiper”. Comparando a Figura 4.2 com a Figura 4.1 é possível notar que o formato dos espectros de R_{rs} *in situ*, em geral, segue o mesmo padrão para cada faixa específica de concentração determinada por ambos métodos. A maior diferença está entre as classes “EutroSuper” do método limnológico (Figura 4.2B) e a “Classe 2” do método óptico (Figura 4.1B), em que as características descritas acima dos espectros de R_{rs} *in situ* pertencentes à Classe 1 (Figura 4.1A) e Classe 2 (Figura 4.1B) se misturam na classe “EutroSuper” (Figura 4.2B). Isso pode gerar regiões de transição óptica, principalmente, entre as classes “OligoMeso” e “EutroSuper” do método limnológico.

Figura 4.2 - Resultado da separação dos espectros de R_{rs} *in situ* em cada faixa específica de concentração da chl-*a* do método limnológico, gerando as classes ópticas. (A) Classe “OligoMeso”, (B) Classe “EutroSuper” e (C) Classe “Hiper”.



A Tabela 4.1 mostra as faixas específicas de concentração de chl-*a* definidas pelos métodos limnológico e óptico descritos na seção 3.3 para uso nos modelos híbridos. O método limnológico foi desenvolvido pensando em uma aplicação mais destinada ao monitoramento de reservatórios tropicais brasileiros. Isso porque os limiares de concentração de chl-*a* presentes no IET da CETESB (2017) foram adaptados de Carlson (1977) por Lamparelli (2004) considerando 34 pontos amostrados em reservatórios no Estado de São Paulo no período de 1996-2001. Além disso, as faixas específicas de concentração da chl-*a* geradas por este método possuem intervalos sem sobreposição.

Já o método óptico teria uma aplicação mais ampla, pois permite dividir as faixas de concentração de chl-*a* em outros sistemas aquáticos opticamente complexos eutrofizados com comportamentos espectrais distintos, uma vez que a divisão das faixas de chl-*a* foi baseada na semelhança do formato dos espectros de R_{rs} *in situ*. Vale ressaltar que a

medida que o algoritmo SAM estabelece as classes ópticas, as faixas de concentração de chl-*a* exibem pequenas sobreposições entre as classes, no caso relacionadas à natureza *fuzzy* das massas de água e à presença dos demais COAs.

Tabela 4.1 - Resultado da divisão do conjunto de valores de concentração de chl-*a* em faixas específicas de concentração.

Método Limnológico	
Classes ópticas	Faixa chl-<i>a</i> (mg/m³)
OligoMeso	chl- <i>a</i> ≤ 11,03
EutroSuper	11,03 < chl- <i>a</i> ≤ 69,05
Hiper	chl- <i>a</i> > 69,05
Método Óptico	
Classes ópticas	Faixa chl-<i>a</i> (mg/m³)
Classe 1	2,89 ≤ chl- <i>a</i> ≤ 22,83
Classe 2	19,51 ≤ chl- <i>a</i> ≤ 87,63
Classe 3	75,89 ≤ chl- <i>a</i> ≤ 938,97

4.2 Avaliação dos algoritmos bio-ópticos de chl-*a* para cada faixa específica de concentração de chl-*a*

Para simplificar a forma de como mostrar os resultados da análise exploratória, a Tabela 4.2 mostra apenas os valores de R² dos algoritmos bio-ópticos de melhor desempenho para cada faixa específica de concentração da chl-*a*. Os valores de R² em vermelho são o resultado da análise exploratória do algoritmo de melhor desempenho da respectiva classe óptica. Pela análise da Tabela 4.2 é possível verificar que os algoritmos de melhor desempenho em cada faixa de chl-*a* possuem, em sua maioria, maior valor de R² em relação às outras faixas, indicando que seriam mais adequados para estimar a concentração da chl-*a* na respectiva classe óptica.

Tabela 4.2 – Resultado estatístico (R^2) da análise exploratória para cada classe óptica dos métodos limnológico e óptico, considerando os algoritmos bio-ópticos de melhor desempenho para cada faixa específica de concentração de chl-*a*. Sendo: Lin é ajuste linear, Pol é ajuste polinomial, Exp é ajuste exponencial.

Método Limnológico					
Algoritmo de melhor desempenho em cada classe óptica	Ajuste	R² em cada classe			
		OligoMeso	EutroSuper	Hiper_600	Hiper_1000
Gitelson et al. (2011a) - OligoMeso	Exp	0,7	0,52	0,67	0,65
Mishra e Mishra (2012), bandas B5 e B4 - EutroSuper	Pol	0,68	0,63	0,21	0,43
B5/B3 - Hiper_600	Exp	0,08	0,18	0,87	0,79
Mishra e Mishra (2010), bandas B6 e B4 - Hiper_1000	Pol	0,05	0,09	0,78	0,90

Método Óptico					
Algoritmo de melhor desempenho em cada classe óptica	Ajuste	R² em cada classe			
		Classe 1	Classe 2	Classe3_600	Classe3_1000
Gitelson et al. (2011a) - Classe 1	Lin	0,60	0,46	0,67	0,77
Mishra e Mishra (2010), bandas B5 e B4 - Classe 2	Exp	0,36	0,61	0,69	0,72
B5/B3 - Classe3_600	Exp	0,05	0,13	0,86	0,77
B6/B3 - Classe3_1000	Pol	0,25	0,07	0,83	0,88

As estatísticas de validação dos algoritmos bio-ópticos de melhor desempenho para cada faixa de concentração de chl-*a* dos métodos limnológico e óptico são mostrados na Tabela 4.3 (os gráficos de dispersão da validação de cada algoritmo se encontram nas Figuras A.1 e A.2, no Apêndice A). Em geral, as estatísticas dos algoritmos em todas as faixas variaram (mínimo/máximo): a) para o método limnológico: MAPE 21,78 – 26,65%; R^2 0,79 – 0,92; NRMSE 12,64 – 21,39%; e b) para o método óptico: MAPE 20,12 – 34,36%; R^2 0,78 – 0,98; NRMSE 7,92 – 26,78%. É possível notar também que tanto para as classes ópticas “OligoMeso” e “Hiper_ate600” do método limnológico quanto para as classes ópticas “Classe 1” e “Classe3_ate600” do método óptico os modelos de melhor

desempenho são os mesmos, no caso a razão de 3 bandas do Gitelson et al. (2011a) e a razão simples de 2 bandas B5/B3, respectivamente.

Tabela 4.3 - Resultado da validação pela Monte Carlo; algoritmos bio-ópticos de melhor desempenho para cada faixa específica de concentração da chl-a geradas pelos métodos limnológico e óptico. Sendo: N é número de amostras usado para na validação, Lin é ajuste linear, Pol é ajuste polinomial, Exp é ajuste exponencial, MAPE (%), RMSE (mg/m³) e NRMSE (%).

Método Limnológico - Modelo Híbrido Limnológico (MHL)								
Classes/Faixas	Algoritmo	Ajuste	N	MAPE	R²	RMSE	NRMSE	Coefficientes
OligoMeso (chl-a ≤ 11,03)	Gitelson et al. (2011a)	Exp	4	25,17	0,92	1,12	21,39	[8,62 4,82]
EutroSuper (11,03 < chl-a ≤ 69,05)	Mishra e Mishra (2012), bandas B5 e B4	Pol	10	24,04	0,79	7,47	15,18	[-92,64 151,74 18,59]
Hiper_ate600 (69,05 < chl-a ≤ 600)	B5/B3	Exp	7	21,78	0,89	39,64	12,64	[4,47 3,56]
Hiper_ate1000 (69,05 < chl-a ≤ 1000)	Mishra e Mishra (2010), bandas B6 e B4	Pol	8	26,65	0,88	123,63	16,07	[-3,57e+08 1,19e+06 1,39e+02]
Método Óptico - Modelo Híbrido Óptico (MHO)								
Classes/Faixas	Algoritmo	Ajuste	N	MAPE	R²	RMSE	NRMSE	Coefficientes
Classe 1 (2,89 ≤ chl-a ≤ 22,83)	Gitelson et al. (2011a)	Lin	8	34,36	0,78	5,34	26,78	[74,35 13,31]
Classe 2 (19,51 ≤ chl-a ≤ 87,63)	Mishra e Mishra (2010), bandas B5 e B4	Exp	7	23,35	0,93	12,09	19,05	[30,67 5682,47]
Classe 3_ate600 (75,89 ≤ chl-a ≤ 600)	B5/B3	Exp	6	21,40	0,82	47,22	14,40	[4,66 3,53]
Classe 3_ate1000 (75,89 ≤ chl-a ≤ 1000)	B6/B3	Pol	7	20,12	0,98	58,90	7,92	[-157,72 810,11 -199,10]

Os modelos presentes na Tabela 4.3 também foram calibrados e validados em intervalos de concentrações de chl-a mais amplos (Tabela 4.4), como valores até 600 mg/m³ e até 1000 mg/m³, ou seja, considerando todo o conjunto de amostras, sem separar por classes. O objetivo desta etapa foi o de comparar o desempenho dos modelos em faixas mais amplas e em faixas mais específicas de concentração. Os resultados mostram que tais modelos perdem desempenho quando aplicados para faixas de concentrações mais amplas, tendo estatísticas (mínimo/máximo) que variam: concentração até 600 mg/m³

possui MAPE 52,31 – 247,10%, R^2 0,67 – 0,92, NRMSE 11,14 – 19,58%; concentração até 1000 mg/m³ possui MAPE 68,27 – 424,26%; R^2 0,59 – 0,97; NRMSE 4,89 – 48,97%.

Tabela 4.4 - Resultado da validação pela Monte Carlo, usando os algoritmos bio-ópticos de melhor desempenho da Tabela 4.3 para faixas mais amplas de concentração de chl-*a*, até 600 mg/m³ e até 1000 mg/m³. Sendo: Lin é ajuste linear, Pol é ajuste polinomial, Exp é ajuste exponencial, MAPE (%), RMSE (mg/m³) e NRMSE (%).

Concentração chl-<i>a</i> até 600 mg/m³ - N_{total} = 65						
Algoritmo	Ajuste	MAPE	R²	RMSE	NRMSE	Coefficientes
Mishra e Mishra (2012), bandas B5 e B4	Pol	52,31	0,72	38,78	19,58	[882,99 112,44 9,31]
Mishra e Mishra (2010), bandas B5 e B4	Exp	230,01	0,90	49,57	12,98	[52,13 2678,99]
Mishra e Mishra (2010), bandas B6 e B4	Pol	231,14	0,85	53,81	14,37	[-1,84e+09 1,85e+06 1,07e+02]
B5/B3	Exp	80,26	0,92	45,02	12,05	[2,06 4,26]
B6/B3	Pol	247,10	0,79	49,22	11,14	[76,25 351,08 -50,63]
Gitelson et al. (2011a)	Lin	77,52	0,67	56,94	12,86	[236,84 13,58]
Gitelson et al. (2011a)	Exp	216,49	0,92	43,84	11,71	[58,83 1,12]
Concentração chl-<i>a</i> até 1000 mg/m³ - N_{total} = 69						
Algoritmo	Ajuste	MAPE	R²	RMSE	NRMSE	Coefficientes
Mishra e Mishra (2012), bandas B5 e B4	Pol	132,36	0,59	133,73	19,73	[2379,08 -235,45 -20,53]
Mishra e Mishra (2010), bandas B5 e B4	Exp	279,21	0,74	249,41	26,65	[52,90 3000,10]
Mishra e Mishra (2010), bandas B6 e B4	Pol	223,40	0,84	48,33	10,92	[-8,45e+08 1,63e+06 9,81e+01]
B5/B3	Exp	177,14	0,95	104,95	11,21	[11,94 2,64]
B6/B3	Pol	328,37	0,93	55,39	6,58	[-93,72 608,72 -99,11]
Gitelson et al. (2011a)	Lin	68,27	0,97	27,43	4,89	[220,70 23,62]
Gitelson et al. (2011a)	Exp	424,26	0,75	412,36	48,97	[84,21 0,72]

Embora o modelo NDCI do Mishra e Mishra (2012) teve um desempenho razoável (MAPE = 52,31%; R^2 = 0,72; NRMSE = 19,58%) considerando para sua calibração/validação dados com uma amplitude de concentração de chl-*a* até 600 mg/m³, foi possível observar no gráfico da validação (Figura A.3, Apêndice A) que a partir de aproximadamente 50 mg/m³ havia uma maior dispersão entre os valores de chl-*a* estimados e medidos *in situ* em relação à reta 1:1. Vale ressaltar também que a validação deste modelo abrangeu apenas valores de concentração até 200 mg/m³, pois o sorteio de

70% para calibração e 30% para a validação foi aleatório. Assim, o desempenho do modelo NDCI mostrado na Tabela 4.4 não corresponde à toda a faixa de concentração de chl-*a* considerada (até 600 mg/m³).

4.3 Árvore de decisão para detectar as classes ópticas

De todos os atributos de entrada selecionados para o treinamento e teste do modelo de classificação por árvore de decisão (seção 3.6 da metodologia), foram usados apenas as razões simples de bandas para o desenvolvimento da estrutura condicional do modelo híbrido. Isso porque foi o único tipo de atributo de entrada, dentre os selecionados, que minimiza a influência da intensidade da R_{rs} nos limiares da condicional, não restringindo a aplicação dos modelos híbridos na imagem a intensidades específicas de R_{rs} .

Os resultados do treinamento e teste da árvore de decisão para cada modelo híbrido (MHL e MHO), considerando a R_{rs} *in situ* simulada para as bandas no MSI/Sentinel-2, se encontram nas Figuras 4.3 e 4.4. Nas Figuras 4.3A e 4.4A, as 48 amostras usadas no treinamento da árvore de decisão são referentes aos 70% do total disponível (69 amostras), sendo o restante (21 amostras) usado no teste (Figuras 4.3B e 4.4B).

Figura 4.3 - Resultado da árvore de decisão para o Modelo Híbrido Limnológico (MHL), usando dados *in situ* (N = 69 amostras). (A) Resultado do treinamento do algoritmo de classificação da árvore de decisão, sendo Classe 1 = OligoMeso, Classe 2 = EutroSuper e Classe 3 = Hiper as classes ópticas geradas pelo método limnológico; (B) Resultado do teste do algoritmo treinado, gerando a matriz de confusão.

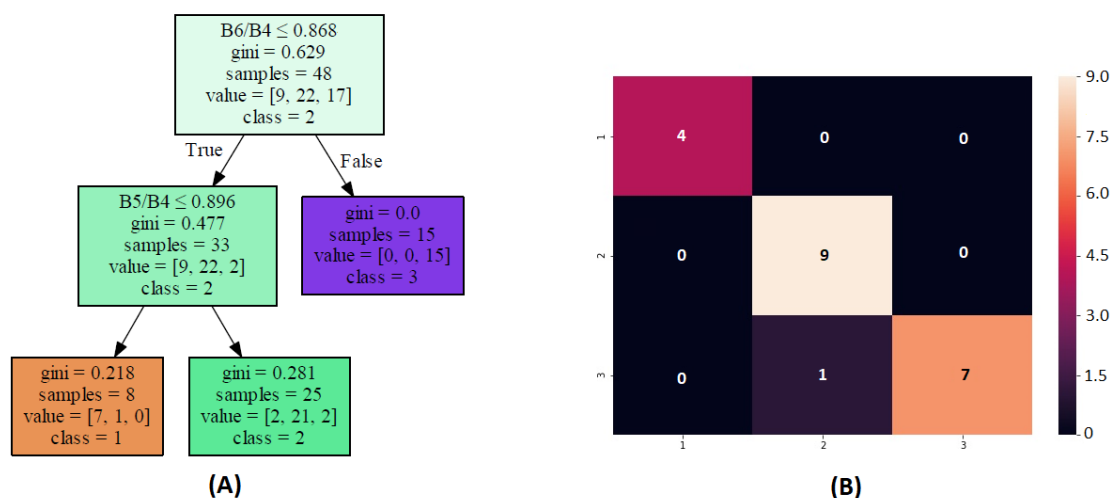
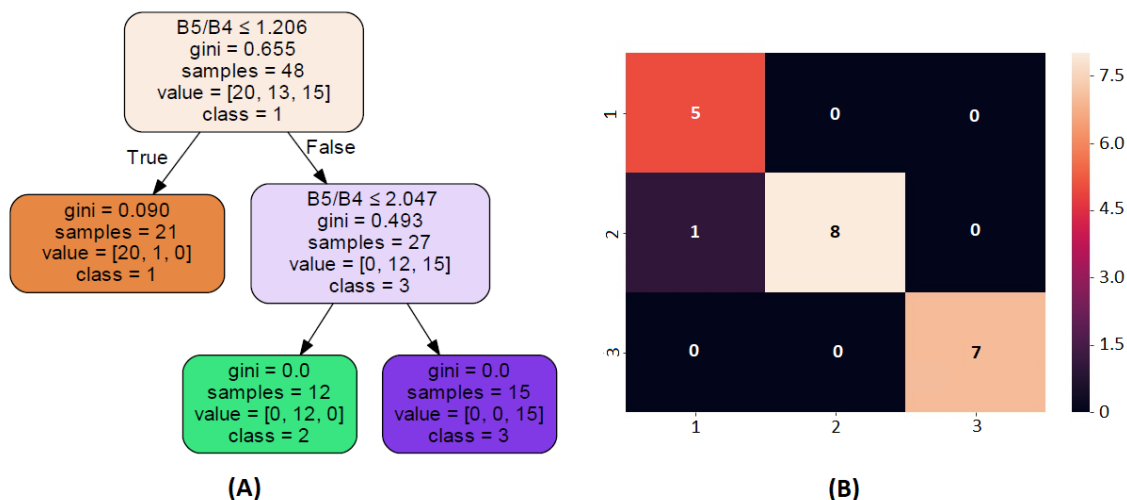


Figura 4.4 - Resultado da árvore de decisão para o Modelo Híbrido Óptico (MHO), usando dados *in situ* (N = 69 amostras). (A) Resultado do treinamento do algoritmo de classificação da árvore de decisão, sendo Classe 1, 2 e 3 as respectivas classes ópticas do SAM; (B) Resultado do teste do algoritmo treinado, gerando a matriz de confusão.



A árvore de decisão com melhor resultado de treinamento foi a referente ao MHO (Figura 4.4A), com o índice *gini* da maioria dos nodos folha assumindo valores iguais ou próximos a zero, mostrando que o algoritmo de classificação conseguiu separar os registros de treino em subconjuntos mais puros. Além disso, os resultados da validação da árvore de decisão para o MHL e MHO (matriz de confusão Figuras 4.3B e 4.4B, respectivamente) tiveram a mesma acurácia de aproximadamente 95%. A matriz de confusão do MHL (Figura 4.3B) mostrou que das quatro amostras da “Classe 1” todas foram classificadas como “Classe 1”, das nove amostras da “Classe 2” todas foram classificadas como “Classe 2”, e das oito amostras da “Classe 3” uma foi classificada como “Classe 2” (erro de classificação) e sete foram classificadas como “Classe 3”. A mesma análise pode ser feita com a matriz de confusão do MHO (Figura 4.4B), sendo que nesse caso houve apenas erro de classificação nas amostras da “Classe 2” (uma amostra foi classificada como “Classe 1”). Por fim, o desempenho dos modelos de classificação da árvore de decisão a partir do conjunto de teste de dados *in situ* para o MHL e MHO também foi obtido usando as métricas “precisão” e “recall” (Tabela 4.5). Tais resultados mostraram que ambos modelos de classificação tiveram alta precisão e sensibilidade.

Tabela 4.5 - Avaliação do desempenho de classificação da árvore de decisão para cada modelo híbrido usando dados *in situ*.

MHL		
Classes ópticas	Precisão	Recall
OligoMeso	1	1
EutroSuper	0,9	1
Hiper	1	0,875
MHO		
Classes ópticas	Precisão	Recall
Classe 1	0,833	1
Classe 2	1	0,889
Classe 3	1	1

É importante ressaltar também que embora a condição de parada do treinamento da árvore de decisão tenha sido estabelecida quando atingisse a partição de pelo menos 95% dos dados de treinamento, tal condição de parada não foi alcançada para o MHL (Figura 4.3A). No caso, o treinamento da árvore de decisão do MHL parou com aproximadamente 90% dos dados de treinamento particionados, pois o número de decisões aumentava ao buscar separar entre duas amostras classificadas de forma errada. Aumentar o número de condições de testes em uma árvore de decisão pode aumentar o risco de *overfitting* do modelo (TAN et al., 2006), ou seja, erros de classificação em dados independentes dos dados de treino. Dessa forma, o ideal é obter um número de decisões que evite esse processo, mesmo que a condição de parada estabelecida não tenha sido atingida.

4.4 Estrutura dos modelos híbridos e validação *in situ*

As Figuras 4.5 e 4.6 mostram a estrutura final do MHL e MHO, respectivamente. Essas figuras resumem os resultados de cada etapa seguida para desenvolver os modelos híbridos, sendo os resultados mostrados nas Tabelas 4.1 e 4.3 e Figuras 4.3 e 4.4. Em geral, a estrutura do MHL e MHO é composta por: i) divisão das faixas específicas de concentração da chl-*a* (classes ópticas 1, 2 e 3) resultantes do método limnológico ou óptico (usando $R_{rs}(\lambda)$ *in situ*; Tabela 4.1); ii) cada classe óptica tem associada um algoritmo bio-óptico de estimativa de chl-*a* de melhor desempenho, resultante da simulação Monte Carlo (usando R_{rs} *in situ* simulada para as bandas do MSI/Sentinel-2; Tabela 4.3); iii) as classes ópticas e seus respectivos algoritmos de chl-*a* são alternados

pixel a pixel em imagens de satélite, usando um classificador por árvore de decisão com base em regras de decisão definidas por limites (Figuras 4.3 e 4.4).

Em resumo, a primeira etapa para aplicar o modelo híbrido (MHL ou MHO) na imagem do MSI/Sentinel-2 é verificar a regra da condicional com base na árvore de decisão (círculos pretos das Figuras 4.5 e 4.6). Essas regras de decisão são aplicadas pixel a pixel na imagem com o intuito de classificar cada pixel em uma das três classes ópticas (retângulos coloridos Figuras 4.5 e 4.6: as cores verde, amarela e vermelha indicam baixa, média e alta intensidade de floração, respectivamente), tendo como saída um mapa de classes ópticas. Em seguida, o algoritmo bio-óptico de melhor desempenho selecionado para cada classe óptica é aplicado pixel a pixel de acordo com sua classificação. Assim, é obtido o mapa de estimativa da concentração da chl-*a*.

Figura 4.5 – Estrutura do MHL. As classes 1, 2 e 3 indicam a presença de baixa (verde), média (amarela) e alta (vermelha) intensidade de floração, respectivamente. Sendo Classe 1 = OligoMeso, Classe 2 = EutroSuper e Classe 3 = Hiper, no caso as classes ópticas geradas pelo método limnológico.

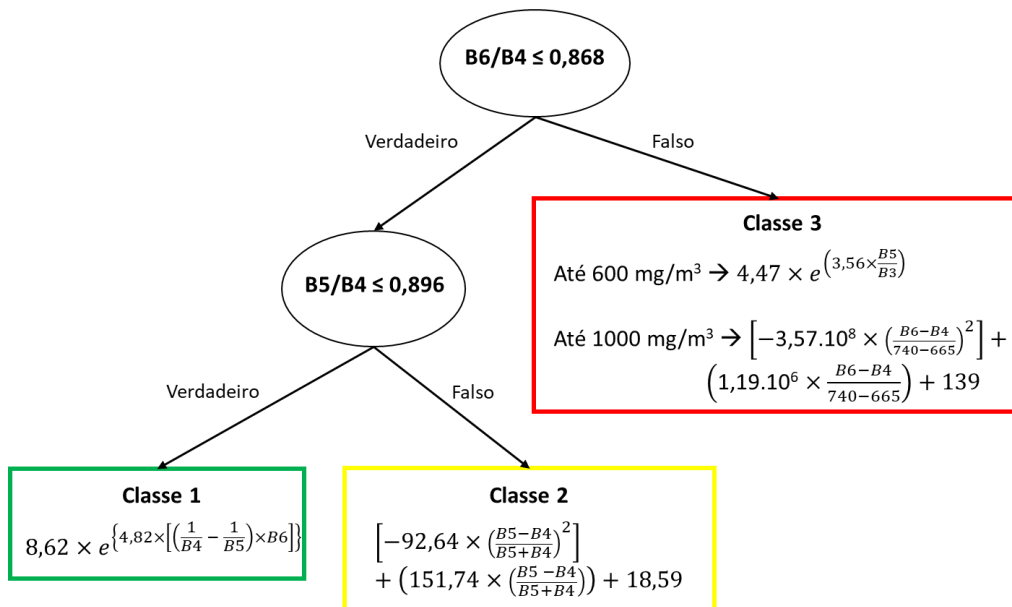
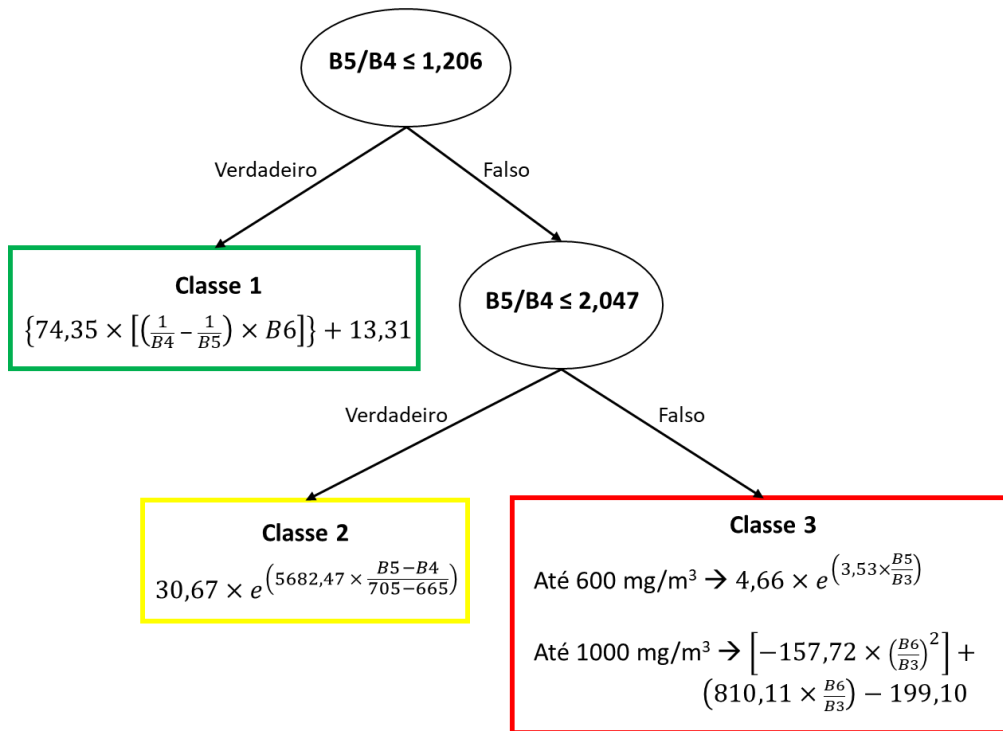


Figura 4.6 - Estrutura do MHO. As classes 1, 2 e 3 indicam a presença de baixa (verde), média (amarela) e alta (vermelha) intensidade de floração, respectivamente. Sendo classe 1, 2 e 3 as respectivas classes ópticas do SAM.



As Figuras 4.7, 4.8, 4.9 e 4.10 mostram o desempenho da validação dos algoritmos bio-ópticos calibrados/validados para uma faixa mais ampla de concentração da chl-*a* (Tabela 4.4) e dos modelos híbridos (validação do MHL e MHO), usando o conjunto de dados *in situ* referente aos 30% da validação da Monte Carlo de cada faixa específica de concentração da chl-*a* dos métodos limnológico e óptico. Vale lembrar que os algoritmos bio-ópticos presentes nessas figuras (Figuras 4.7, 4.8, 4.9 e 4.10 A - C) são os mesmos algoritmos usados para compor os modelos híbridos em cada faixa de concentração (Figuras 4.7, 4.8, 4.9 e 4.10 D), mas calibrados/validados para uma concentração de chl-*a* até 600 mg/m³ ou até 1000 mg/m³ (Tabela 4.4).

Analisando todas as figuras foi possível notar que os modelos híbridos (MHL: Figuras 4.7D e 4.8D; MHO: Figuras 4.9D e 4.10D) obtiveram um desempenho bem melhor que os algoritmos calibrados/validados para concentrações mais amplas. É possível notar, por exemplo, que o valor do MAPE melhora muito para o MHO (MAPE = 26,33%; Figura 4.10D) em comparação com os algoritmos bio-ópticos de 3 bandas do Gitelson et al (2011a) (MAPE = 70,88%; Figura 4.10A), *slope* do Mishra e Mishra (2010) (MAPE =

278,44%; Figura 4.10B) e razão de duas bandas B6/B3 (MAPE = 337,93%; Figura, 4.10C). Isso mostra que em reservatórios tropicais os algoritmos bio-ópticos têm melhor desempenho quando descrevem um conjunto de dados com comportamento espectral semelhante, o que reforça a importância do uso da abordagem híbrida na estimativa da concentração da chl-*a* por SR nesses sistemas aquáticos complexos. Além disso, o desempenho de validação do MHL e do MHO mostrou que a abordagem híbrida teve bom desempenho usando ambos algoritmos referentes à classe 3 (MHL: B5/B3 para “Hiper_ate600” e *Slope* usando B6 e B4 para “Hiper_ate1000”; MHO: B5/B3 para “Classe3_ate600” e B6/B3 para “Classe3_ate1000”).

Figura 4.7 – Desempenho da validação dos algoritmos usando dados *in situ*, referente aos 30% da validação da Monte Carlo de cada faixa específica de concentração da chl-a do método limnológico. Esse conjunto de 30% de dados aleatórios para a validação foi o mesmo para os quatro casos mostrados. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste exponencial, calibrado/validado até 600 mg/m³; (B) Algoritmo NDCI do Mishra e Mishra (2012), com ajuste polinomial, calibrado/validado até 600 mg/m³; (C) Algoritmo razão de bandas B5/B3, com ajuste exponencial, calibrado/validado até 600 mg/m³; (D) Modelo Híbrido Limnológico (MHL) considerando a classe 3 (Hiper) com valores até 600 mg/m³.

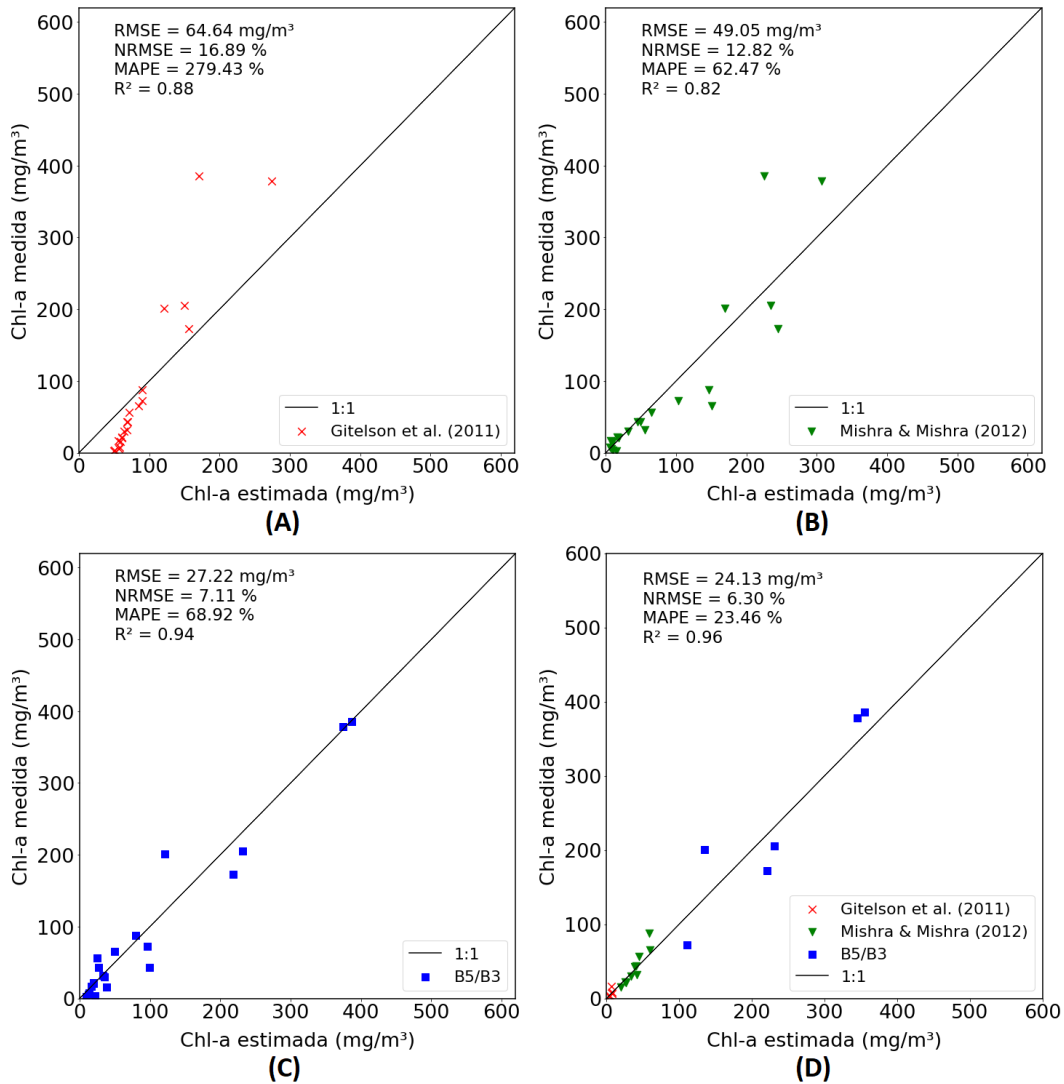


Figura 4.8 - Desempenho da validação dos algoritmos usando dados *in situ*, referente aos 30% da validação da Monte Carlo de cada faixa específica de concentração da chl-*a* do método limnológico. Esse conjunto de 30% de dados aleatórios para a validação foi o mesmo para os quatro casos mostrados. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste exponencial, calibrado/validado até 1000 mg/m³; (B) Algoritmo NDCI do Mishra e Mishra (2012), com ajuste polinomial, calibrado/validado até 1000 mg/m³; (C) Algoritmo *Slope* do Mishra e Mishra (2010), com ajuste polinomial, calibrado/validado até 1000 mg/m³; (D) Modelo Híbrido Limnológico (MHL) considerando a classe 3 (Hiper) com valores até 1000 mg/m³.

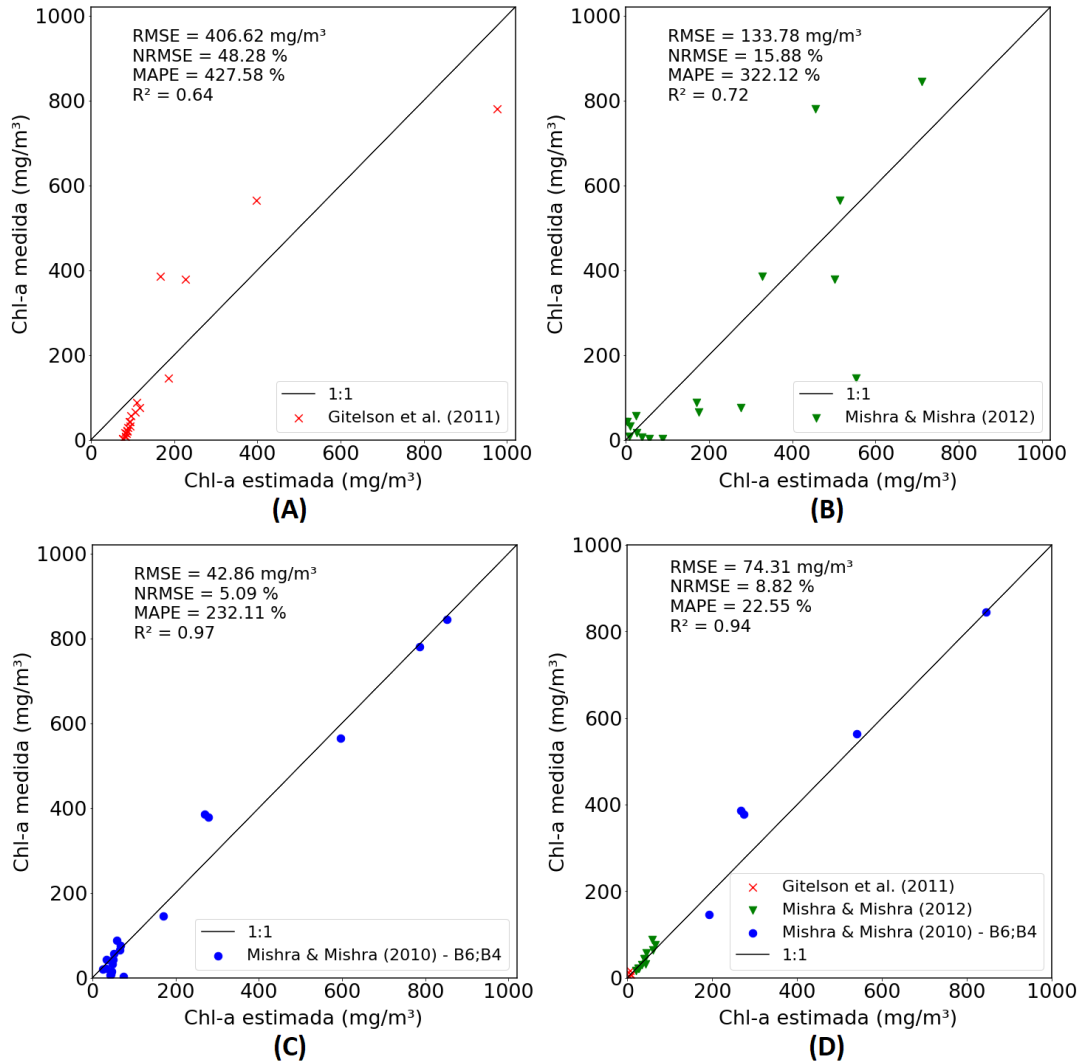


Figura 4.9 – Desempenho da validação dos algoritmos usando dados *in situ*, referente aos 30% da validação da Monte Carlo de cada faixa específica de concentração da chl-*a* do método óptico. Esse conjunto de 30% de dados aleatórios para a validação foi o mesmo para os quatro casos mostrados. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste linear, calibrado/validado até 600 mg/m³; (B) Algoritmo *Slope* do Mishra e Mishra (2010), com ajuste exponencial, calibrado/validado até 600 mg/m³; (C) Algoritmo razão de bandas B5/B3, com ajuste exponencial, calibrado/validado até 600 mg/m³; (D) Modelo Híbrido Óptico (MHO) considerando a classe 3 com valores até 600 mg/m³.

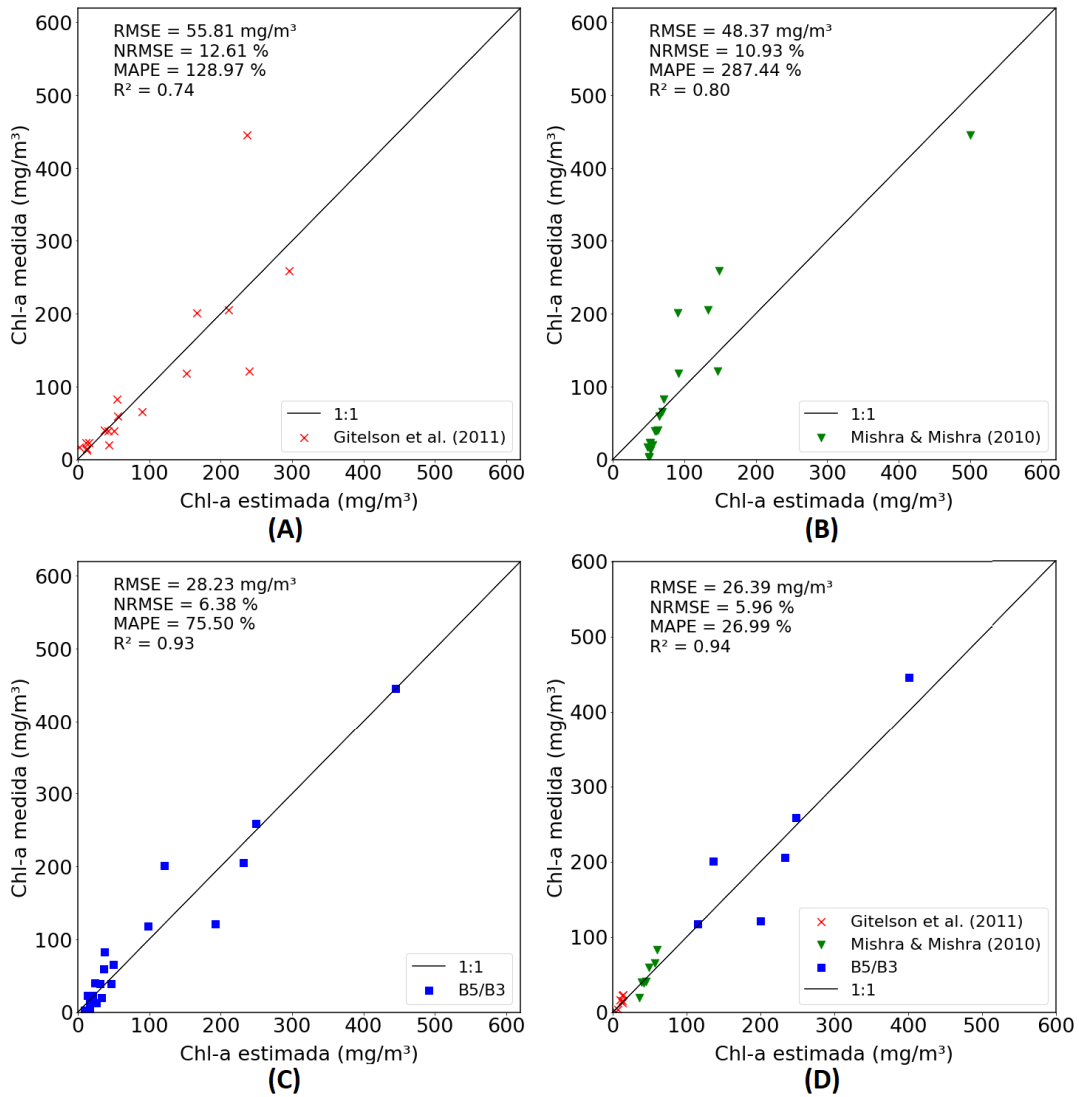
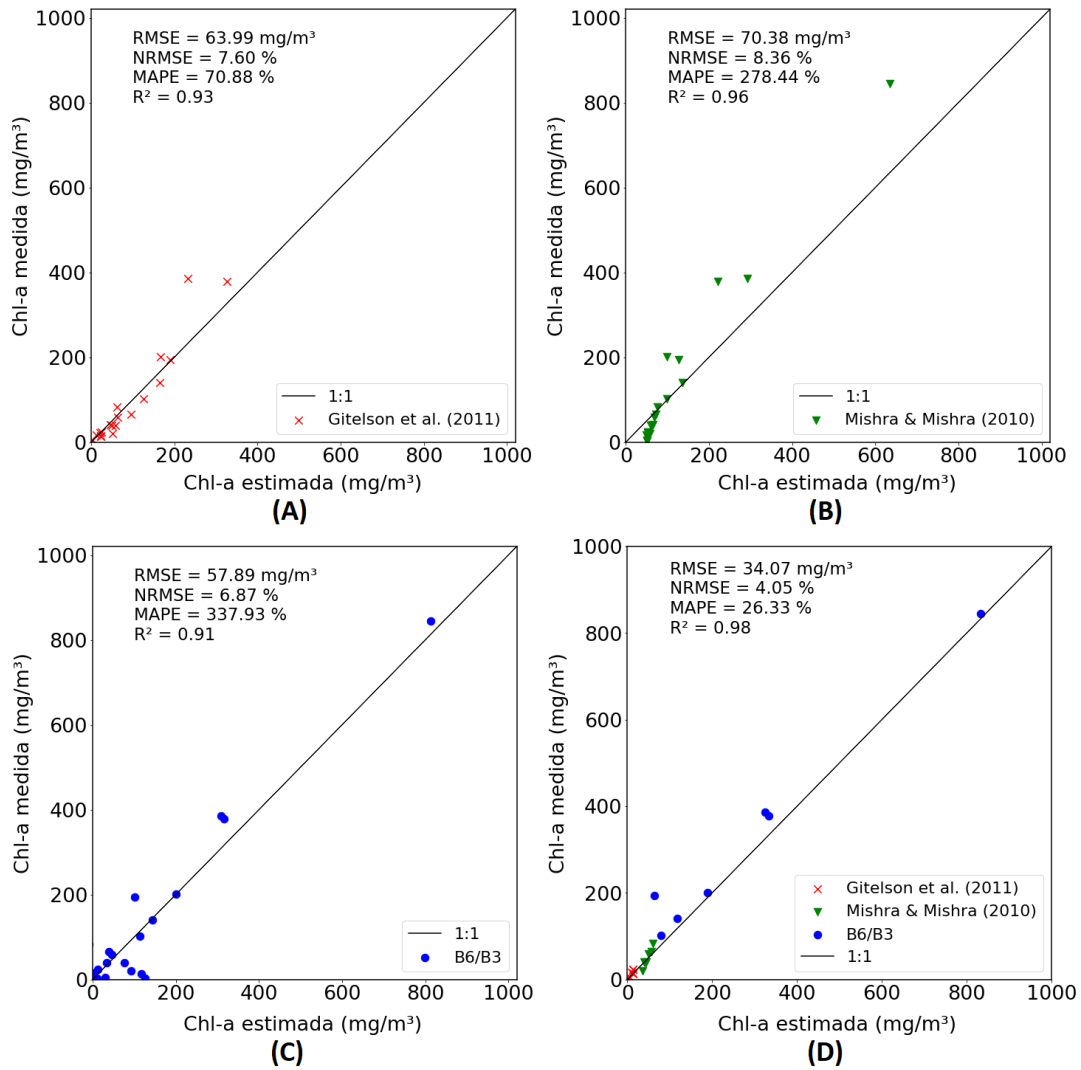


Figura 4.10 – Desempenho da validação dos algoritmos usando dados *in situ*, referente aos 30% da validação da Monte Carlo de cada faixa específica de concentração da chl-*a* do método óptico. Esse conjunto de 30% de dados aleatórios para a validação foi o mesmo para os quatro casos mostrados. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste linear, calibrado/validado até 1000 mg/m³; (B) Algoritmo *Slope* do Mishra e Mishra (2010), com ajuste exponencial, calibrado/validado até 1000 mg/m³; (C) Algoritmo razão de bandas B6/B3, com ajuste polinomial, calibrado/validado até 1000 mg/m³; (D) Modelo Híbrido Óptico (MHO) considerando a classe 3 com valores até 1000 mg/m³.



O desempenho dos algoritmos bio-ópticos em cada faixa específica de concentração para os modelos híbridos limnológico e óptico (MHL e MHO), após sua validação usando o conjunto de dados *in situ* referente aos 30% da validação da Monte Carlo, é mostrado nas Figuras 4.11 e 4.12, respectivamente. Nessas figuras é possível avaliar se houve algum erro de classificação da árvore de decisão durante o processo de validação dos modelos híbridos (tópico 3.7 da metodologia).

Para o MHL, a árvore de decisão teve erro de classificação nas Classes 1 (faixa “OligoMeso”) e 2 (faixa “EutroSuper”). No caso, aplicando a condicional da Classe 1 (Figura 4.5) nos dados de validação houve a seleção de 1 estação amostral classificada como Classe 2 (faixa “EutroSuper” no método limnológico – estação 22 da Londe (2008) com concentração de chl-*a* igual a 16,33 mg/m³). E aplicando a condicional da Classe 2 (Figura 4.5) nos dados de validação houve a seleção de 2 estações amostrais classificadas como Classe 3 (faixas “Hiper_ate600” e “Hiper_ate1000” no método limnológico – estações 17 e 27 da Londe (2008) com concentrações de chl-*a* iguais a 75,89 mg/m³ e 87,63 mg/m³, respectivamente). Essas estações amostrais foram classificadas de maneira errada, pois estão localizadas na faixa de transição entre as classes ópticas e também pode haver incertezas na R_{rs} *in situ*. Em decorrência desses erros de classificação da árvore de decisão para o MHL, alguns modelos perderam desempenho (ex.: Figura 4.11A, MAPE = 31,78% e $R^2 = 0,29$) em comparação com a Tabela 4.3 (MAPE = 25,17% e $R^2 = 0,92$) após a validação do modelo híbrido. Já para o MHO, não houve erro de classificação da árvore de decisão durante o processo de validação (Tabela 4.3 e Figura 4.12 possuem os mesmos resultados estatísticos).

Figura 4.11 - Desempenho dos algoritmos bio-ópticos que compõem o MHL após o processo de validação usando dados *in situ*. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste exponencial, calibrado/validado para a faixa de chl-*a* da classe óptica “OligoMeso”; (B) Algoritmo NDCI do Mishra e Mishra (2012), com ajuste polinomial, calibrado/validado para a faixa de chl-*a* da classe óptica “EutroSuper”; (C) Algoritmo razão de bandas B5/B3, com ajuste exponencial, calibrado/validado para a faixa de chl-*a* da classe óptica “Hiper” até 600 mg/m³; (D) Algoritmo *Slope* do Mishra e Mishra (2010), com ajuste polinomial, calibrado/validado para a faixa de chl-*a* da classe óptica “Hiper” até 1000 mg/m³.

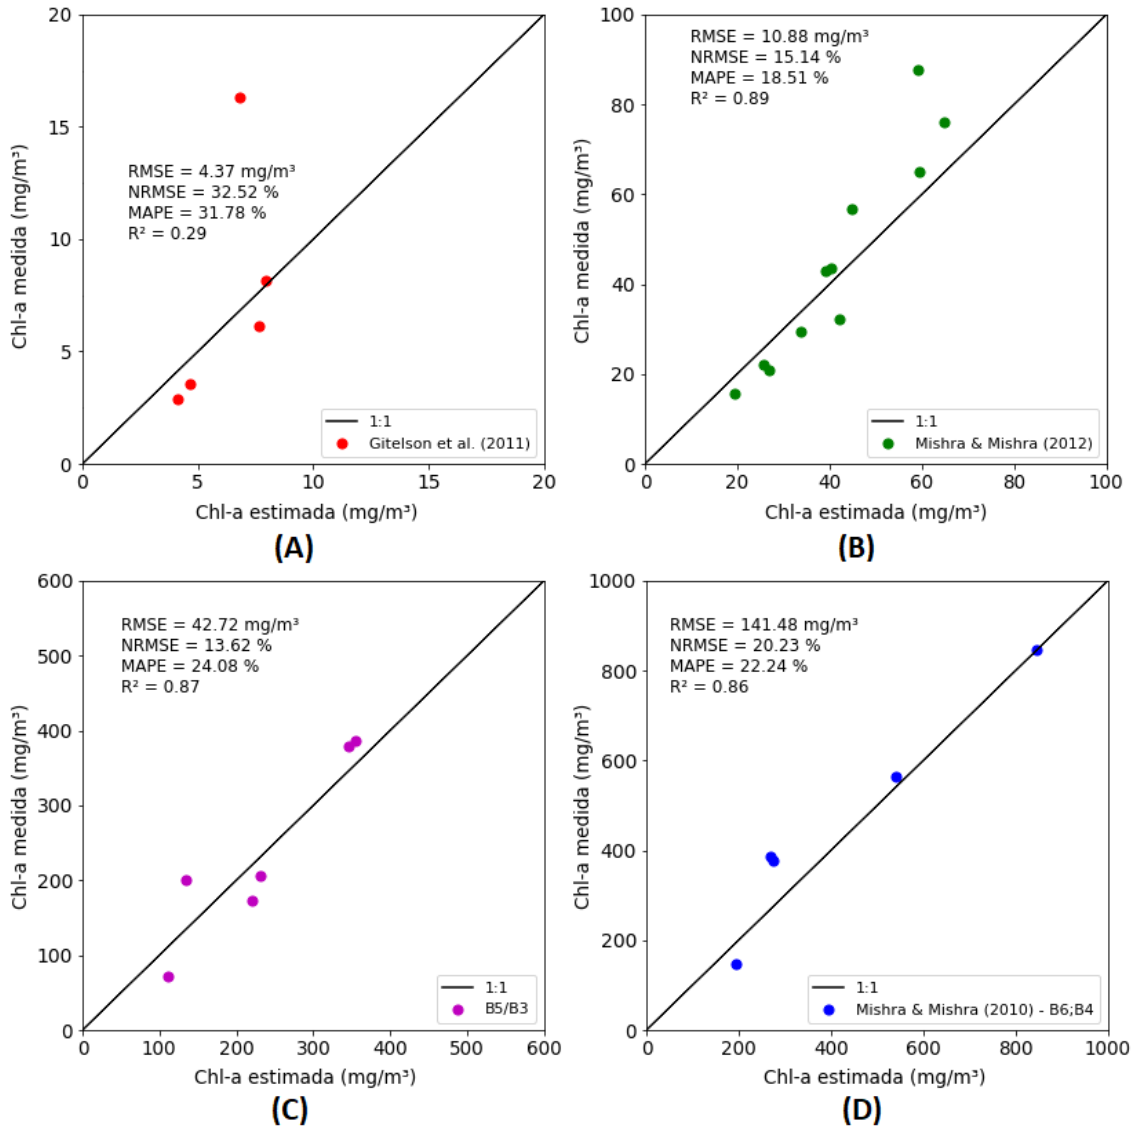
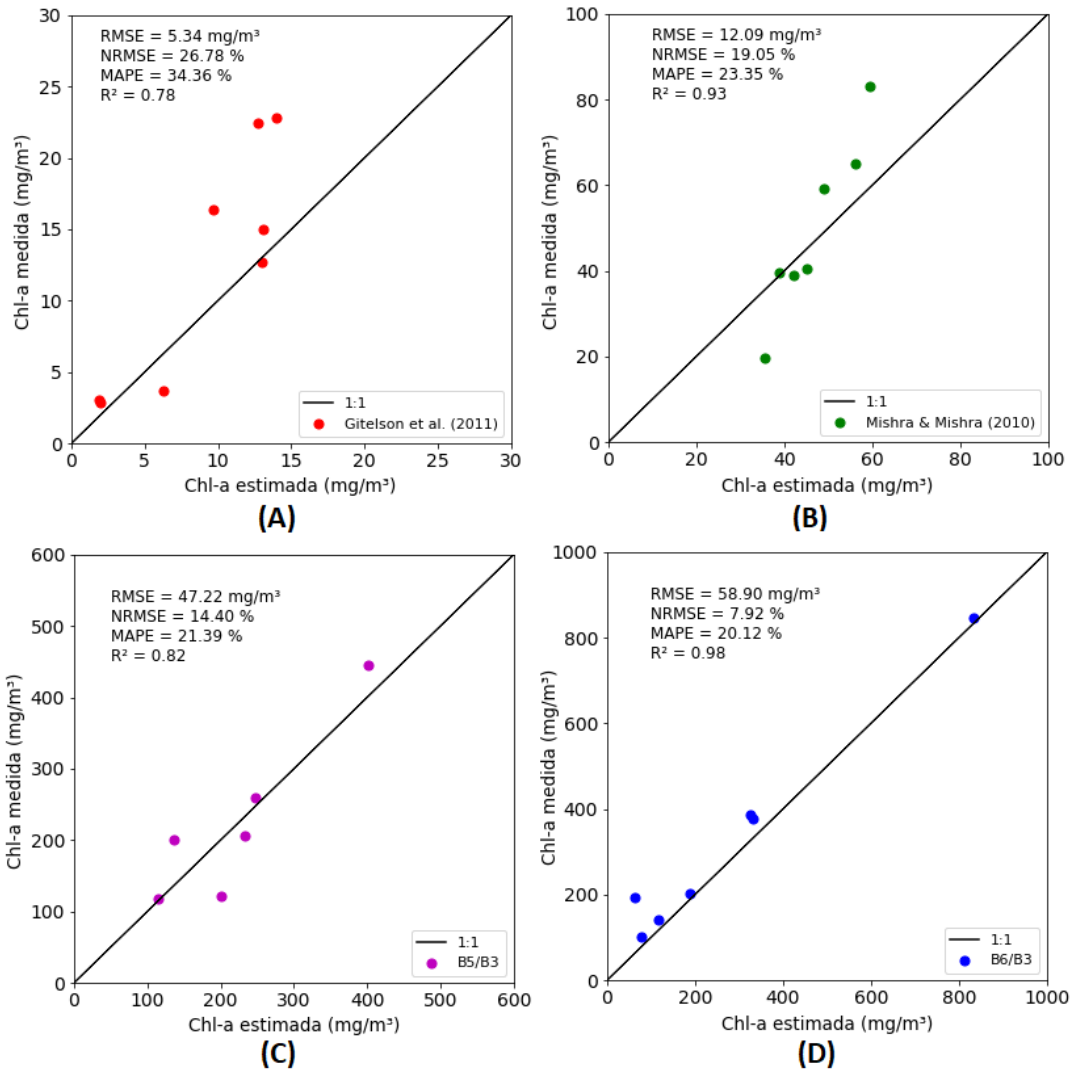


Figura 4.12 - Desempenho dos algoritmos bio-ópticos que compõem o MHO após o processo de validação usando dados *in situ*. (A) Algoritmo de 3 bandas do Gitelson et al. (2011a), com ajuste linear, calibrado/validado para a faixa de chl-*a* da classe óptica “Classe 1”; (B) Algoritmo *Slope* do Mishra e Mishra (2010), com ajuste exponencial, calibrado/validado para a faixa de chl-*a* da classe óptica “Classe 2”; (C) Algoritmo razão de bandas B5/B3, com ajuste exponencial, calibrado/validado para a faixa de chl-*a* da classe óptica “Classe 3” até 600 mg/m³; (D) Algoritmo razão de bandas B6/B3, com ajuste polinomial, calibrado/validado para a faixa de chl-*a* da classe óptica “Classe 3” até 1000 mg/m³.

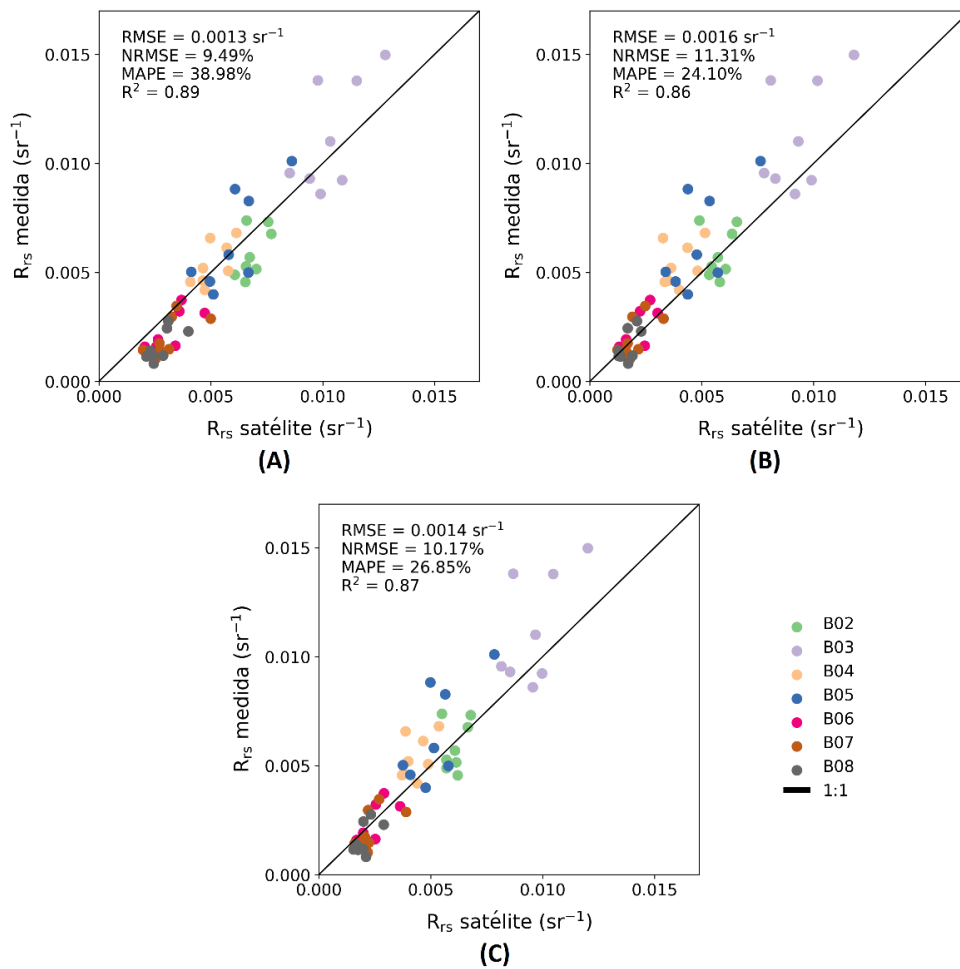


4.5 Avaliação da correção atmosférica e validação dos modelos híbridos a partir da imagem MSI/Sentinel-2

Os resultados da validação da correção atmosférica com e sem a correção do *glint* se encontram na Figura 4.13 (8 estações amostrais coletadas no campo de Agosto/2018). É possível notar que a correção atmosférica teve bom desempenho nos três casos: sem a

correção do *glint*, com a correção do *glint* pela subtração da banda 11 do MSI/Sentinel-2, e com a correção do *glint* pela subtração da banda 12 do MSI/Sentinel-2, sendo melhor pela metodologia de correção do *glint* com a subtração da banda 11 do MSI/Sentinel-2 (Figura 4.11B). Com a inclusão dessa correção do *glint*, os pontos de dispersão das bandas B2 e B6-8 se aproximaram mais da reta 1:1 enquanto que no restante das bandas alguns pontos foram um pouco supercorrigidos.

Figura 4.13 - Validação da correção atmosférica (A) sem a correção do *glint*, (B) com a correção do *glint* pela subtração da banda 11 do MSI/Sentinel-2 e (C) com a correção do *glint* pela subtração da banda 12 do MSI/Sentinel-2.



Quando as bandas foram analisadas separadamente (Tabela 4.6), a estimativa da R_{rs} sem considerar a correção do *glint* (somente correção atmosférica) apresentou valores de MAPE para as bandas B6 à B8 do MSI/Sentinel-2 superiores a 50%. Alguns autores já demonstraram que os erros na correção atmosférica em águas interiores aumentam em

comprimentos de onda mais longos (BERNARDO et al., 2017; MACIEL et al., 2019). Dessa forma, não foi considerado somente a correção atmosférica nas imagens MSI/Sentinel-2 pois alguns algoritmos bio-ópticos que compõem o MHL e o MHO usam a banda B6 (Tabela 4.3), e isso poderia aumentar o erro da estimativa da chl-*a* nas faixas específicas que a consideram (MHL: faixas de chl-*a* das classes ópticas “OligoMeso” e “Hiper_ate1000”; MHO: faixas de chl-*a* das classes ópticas “Classe_1” e “Classe3_ate1000”). Entretanto, as bandas B3 à B5 após a correção atmosférica tiveram bons resultados de MAPE, no caso valores inferiores a 20% (melhores resultados que considerado a correção do *glint*).

Tabela 4.6 - Desempenho da correção atmosférica, com e sem a correção do *glint*, para a estimativa da R_{rs} ($n = 8$), considerando separadamente as bandas do MSI/Sentinel-2.

	Sem correção do <i>glint</i>				Correção do <i>glint</i> (B11)				Correção do <i>glint</i> (B12)			
	MAPE (%)	R ²	RMSE (sr ⁻¹)	NRMSE (%)	MAPE (%)	R ²	RMSE (sr ⁻¹)	NRMSE (%)	MAPE (%)	R ²	RMSE (sr ⁻¹)	NRMSE (%)
B2	21,92	0,37	0,0013	45,68	13,50	0,03	0,0011	38,69	15,18	0,09	0,0010	36,60
B3	13,90	0,45	0,0020	31,34	18,44	0,27	0,0028	44,24	16,87	0,33	0,0025	39,84
B4	11,16	0,45	0,0007	28,69	24,24	0,13	0,0017	63,54	19,29	0,22	0,0013	51,41
B5	19,13	0,60	0,0015	24,00	25,12	0,43	0,0022	36,29	22,55	0,51	0,0019	31,78
B6	51,99	0,59	0,0011	41,52	25,56	0,55	0,0006	24,47	26,78	0,55	0,0006	24,11
B7	65,66	0,45	0,0013	51,33	28,70	0,41	0,0007	26,76	38,41	0,37	0,0007	30,61
B8	89,09	0,51	0,0012	63,75	33,14	0,38	0,0005	28,17	48,88	0,34	0,0007	34,78

Considerando a correção do *glint*, ambas metodologias (subtração B11 ou B12 do MSI/Sentinel-2) tiveram desempenhos similares (Tabela 4.6 e Figura 4.13), com exceção das bandas B7 e B8 (diferença de 10% ou mais de MAPE). Além do *glint*, uma questão que também pode influenciar os dados de satélite é o efeito de adjacência. Esse efeito não é igual em todos os comprimentos de onda, uma vez que gera maiores valores de R_{rs} nos comprimentos de onda maiores e tem impacto menor nos comprimentos de onda menores, podendo variar também com o distanciamento das bordas do corpo d’água.

Em geral, os valores de MAPE para a correção do *glint* usando a B11 do MSI/Sentinel-2 foram inferiores a 33%, enquanto que para a correção do *glint* usando a B12 foram

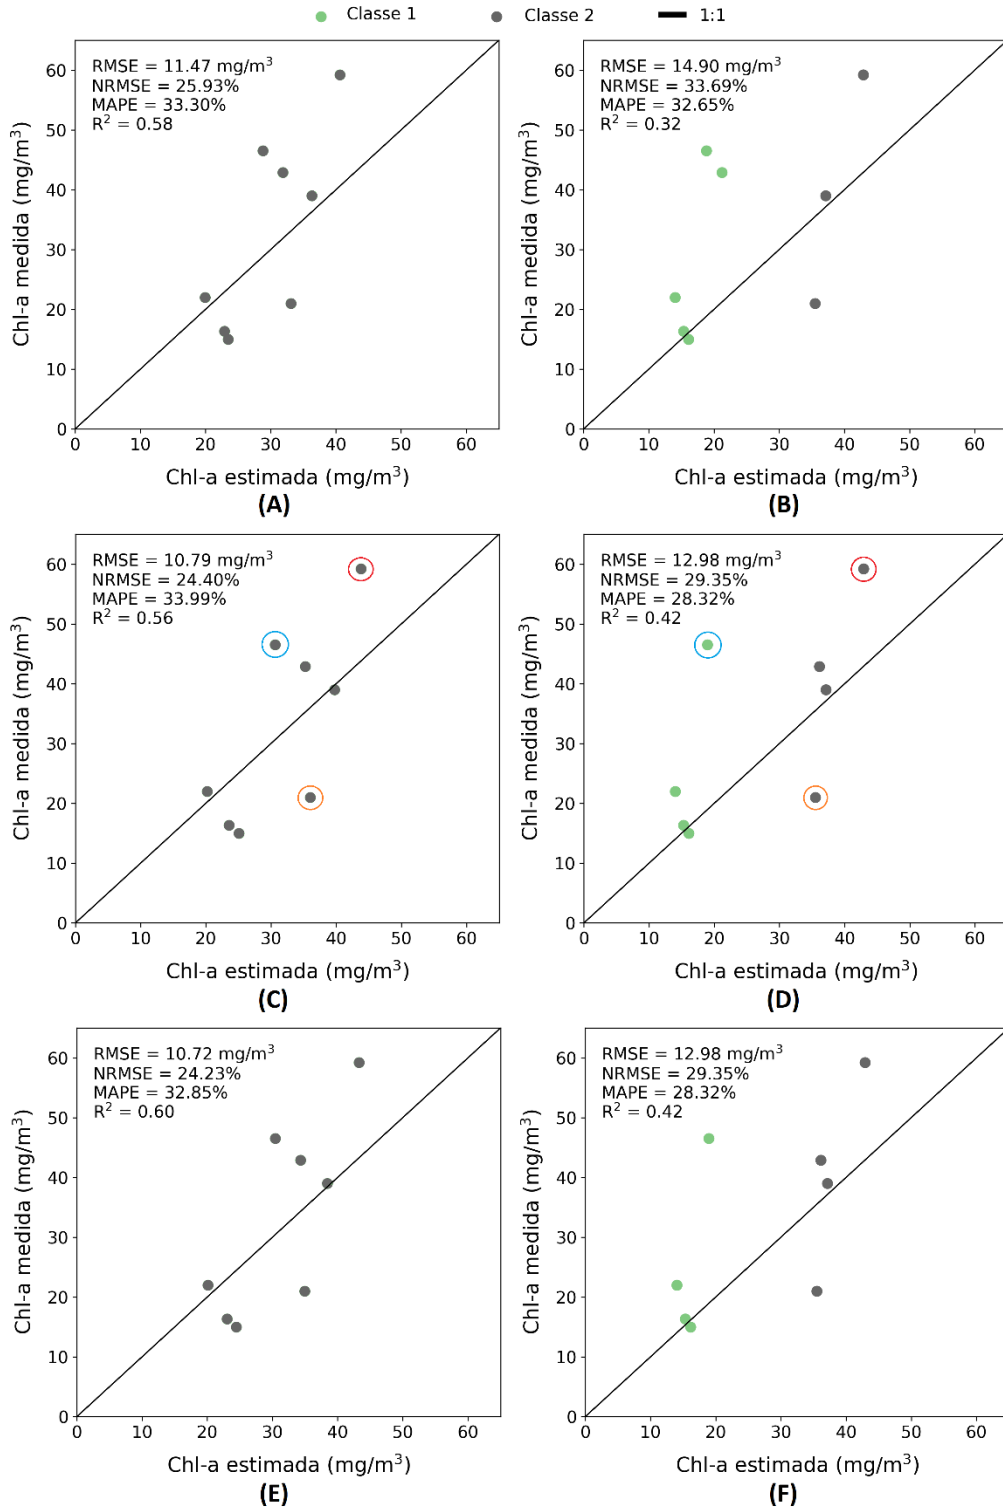
inferiores a 49%. Vale ressaltar também que os valores de R^2 não são altos em ambos casos, o que pode ser explicado pelas diferenças de tempo entre os dados *in situ* e a passagem do satélite, bem como pela baixa variabilidade nos valores de R_{rs} para cada banda. Além disso, a maior dispersão para as bandas de ondas curtas pode também estar associada a erros na radiometria *in situ*.

Os resultados da validação do MHL e do MHO na imagem do sensor MSI/Sentinel-2 com e sem a correção do *glint* se encontram na Figura 4.14. Essa etapa apenas mostrou os resultados dos modelos híbridos que englobam o algoritmo bio-óptico da “Classe 3” até 1000 mg/m³ (MHL_ate1000: considera os algoritmos das classes ópticas “OligoMeso”, “EutroSuper” e “Hiper_ate1000”; MHO_ate1000: considera os algoritmos das classes ópticas “Classe 1”, “Classe_2” e “Classe3_ate1000”; Tabela 4.3).

Analisando os gráficos da Figura 4.14, percebe-se que os resultados da validação do MHL e do MHO na imagem do sensor MSI/Sentinel-2 foram bem parecidos usando ambas correções do *glint*. É possível notar também que existem alguns *outliers* (pontos mais afastados da linha 1:1, círculos coloridos na Figura 4.14 C e D), mesmo quando a correção do *glint* é aplicada. As estações P1 e P2 (círculos azul e vermelho, respectivamente) foram coletadas um dia antes da passagem do Sentinel-2 e a estação P6 (círculo laranja) foi coletada uma hora antes da passagem do satélite. Além do intervalo temporal entre os *matchups*, esses erros também podem estar relacionados à influência da hidrodinâmica do reservatório na formação da floração de algas (LONDE et al., 2016).

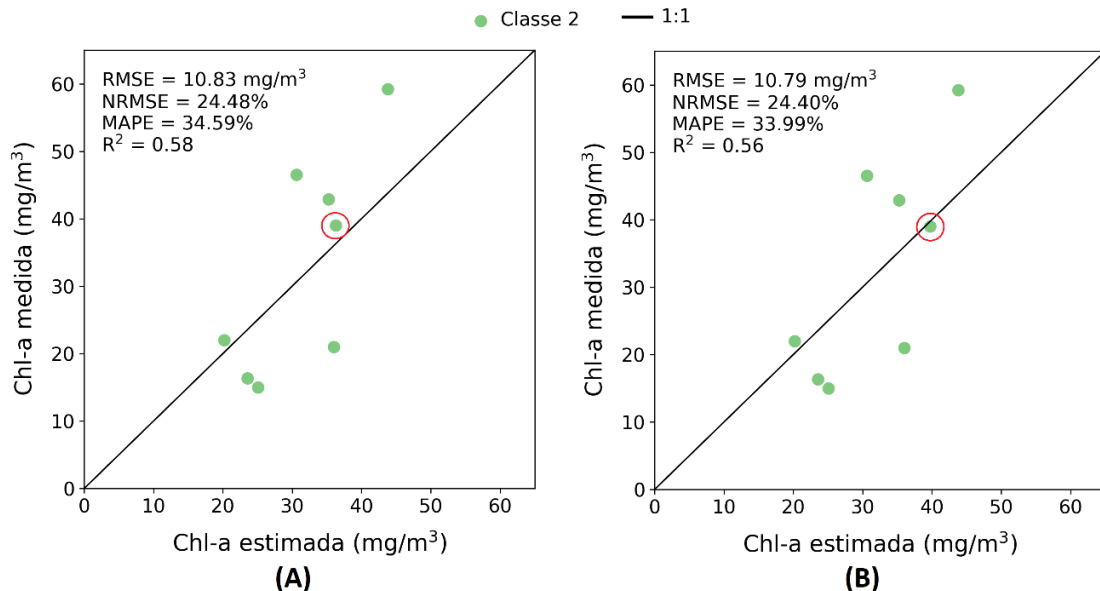
Além disso, pela análise dos resultados do MHL foi possível verificar que considerando ou não a correção do *glint* (Figura 4.14 A, C, E) houve cinco erros de classificação da árvore de decisão do MHL (“OligoMeso” foi classificado como “EutroSuper”; “OligoMeso” é “Classe 1” e “EutroSuper” é “Classe 2” na Figura 4.14). Já pela análise dos resultados do MHO, foi possível verificar que sem considerar a correção do *glint* (Figura 4.14B) houve dois erros de classificação da árvore de decisão do MHO, e considerando a correção do *glint* (Figuras 4.14D e 4.14F) houve apenas um (“Classe 1” foi classificada como “Classe 2”).

Figura 4.14 - Validação do MHL_ate1000 (coluna esquerda: A, C, E) e MHO_ate1000 (coluna direita: B, D, F) na imagem do MSI/Sentinel-2 (13 agosto 2018) corrigida atmosféricamente: (A, B) sem a correção do *glint*, (C, D) com a correção do *glint* pela subtração da banda 11 e (E, F) com a correção do *glint* pela subtração da banda 12. Obs1: Para o MHL, Classe 1 = OligoMeso e Classe 2 = EutroSuper. Obs2: Os círculos azul, vermelho e laranja se referem às estações amostrais P1, P2 e P6, respectivamente, do campo de Agosto/2018.



Vale ressaltar que os resultados estatísticos da validação do MHO considerando os algoritmos bio-ópticos das classes ópticas “Classe3_ate600” e “Classe3_ate1000” (algoritmos Tabela 4.3; MHO_ate600 e MHO_ate1000) foram iguais (Apêndice A, Tabela A.1). Já os resultados da validação do MHL considerando os algoritmos bio-ópticos das classes ópticas “Hiper_ate600” e “Hiper_ate1000” (algoritmos Tabela 4.3; MHL_ate600 e MHL_ate1000) foram um pouco diferentes (Apêndice A, Tabela A.1). Mesmo que pequena, essa diferença das estatísticas entre o MHL_ate600 e MHL_ate1000 (Figura 4.15) na validação com a imagem (considerando a correção do *glint* com a subtração da banda 11 do MSI/Sentinel-2) não era esperada, uma vez que na coleta de campo de Agosto/2018 não foi obtido nenhum exemplo de espectro e valor de concentração da chl-*a* representativo da classe óptica “Hiper” (Figura 4.1C e Tabela 4.1, respectivamente).

Figura 4.15 – Validação do MHL a partir da imagem MSI/Sentinel-2, considerando a correção do *glint* com a subtração da banda 11. (A) MHL_ate600: usa os modelos referentes às faixas de chl-*a* das classes ópticas “OligoMeso”, “EutroSuper” e “Hiper_ate600”; (B) MHL_ate1000: usa os modelos referentes às faixas de chl-*a* das classes ópticas “OligoMeso”, “EutroSuper” e “Hiper_ate1000” (Tabela 4.3). Obs1: Classe 2 = EutroSuper. Obs2: O círculo vermelho enfatiza a estação amostral do campo de Agosto/2018 (P03) que provoca a pequena mudança dos valores estatísticos entre o MHL_ate600 e MHL_ate1000.



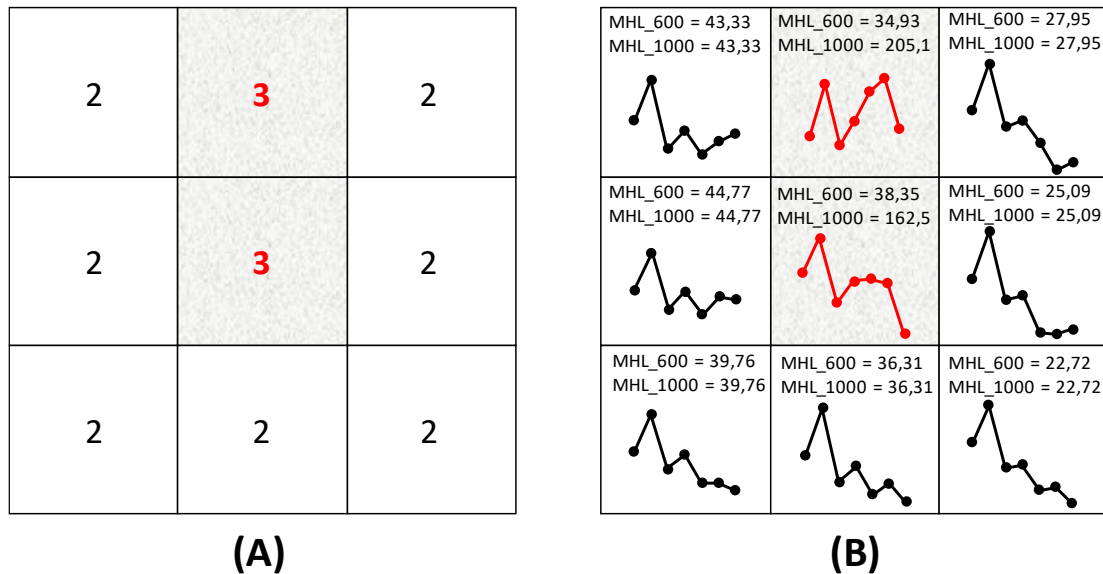
Assim, analisando mais a fundo a execução do processo metodológico considerado na validação (Figura 4.16), verificou-se que a janela 3x3 pixels, criada para extrair a mediana

da concentração da chl-*a* de uma das estações amostrais de campo (estação circutada em vermelho na Figura 4.15) no mapa de chl-*a* gerado pela aplicação do MHL na imagem, capturou uma frente de floração com intensidade variando de média à elevada (Classe 2 e 3 da árvore de decisão, respectivamente; Figura 4.3A). Ao analisar os espectros de R_{rs} de cada um dos nove pixels da janela, percebeu-se que os dois pixels que englobavam a classe 3 (indica presença de elevada eutrofização) tinham espectros com um comportamento bem diferente dos obtidos em campo, principalmente na região do vermelho e infravermelho (Figura 4.16B). Esse comportamento diferente se resume em possuir valores das bandas B6 e B5 do MSI/Setinel-2 com valores inferiores à B3, sendo que nos dados de campo as bandas simuladas mostraram que conforme vai aumentando a concentração da chl-*a*, os valores de B6 e B5 tendem a ser maiores que B3.

Essa diferença no comportamento espectral prejudicou o desempenho dos algoritmos da faixa de chl-*a* da classe óptica “Hiper” para o MHL, tendo valores muito abaixo do esperado quando era aplicado na imagem o algoritmo da faixa de chl-*a* de “Hiper_ate600” e valores mais condizentes ao esperado quando era aplicado na imagem o algoritmo da faixa de chl-*a* de “Hiper_ate1000” (algoritmos Tabela 4.3). Assim, ao determinar a mediana da janela 3x3 pixels, esses valores bem diferentes de concentração de chl-*a* estimados usando os algoritmos das classes “Hiper_ate600” e “Hiper_ate1000” (valores de chl-*a* do MHL_ate600 e MHL_ate1000 na Figura 4.16B, nos pixels hachurados) faziam com que as medianas da estação amostral para o MHL_ate600 e para o MHL_ate1000 tivessem valores diferentes, gerando estatísticas de validação um pouco diferentes (Figura 4.15).

É importante ressaltar que na Figura 4.16B os valores de concentração de chl-*a* gerados pelo MHL_ate600 e MHL_ate1000 são iguais para a “Classe 2”, uma vez que nas duas derivações do MHL (Figura 4.5) a “Classe 2” considera o mesmo algoritmo bio-óptico (NDCI do Mishra e Mishra (2012), Tabela 4.3). Nos modelos MHL_ate600 e MHL_ate1000, a única classe óptica que possui modelos diferentes é a “Classe 3” (classes ópticas “Hiper_ate600” e “Hiper_ate1000”).

Figura 4.16 - (A) Janela 3x3 pixels da estação amostral P03 do campo de Agosto/2018, com as classes ópticas estabelecidas pela árvore de decisão, e os (B) respectivos espectros de R_{rs} com os valores estimados da concentração da chl- a (mg/m³), considerando os algoritmos da “Classe 2” (“EutroSuper”) e “Classe 3” (“Hiper_ate600” e “Hiper_ate1000”; Tabela 4.3) do MHL, para cada pixel da janela. Obs1: os espectros de R_{rs} estão sem valores nos eixos, pois têm apenas a função de mostrar a forma espectral. Obs2.: nos valores de MHL_ate600 e MHL_ate1000 é considerada a correção do *glint* com a subtração da B11 do MSI/Sentinel-2, mas essa situação para o MHL também ocorre com a subtração da B12 e sem considerar a correção do *glint*.



As Figuras 4.17 e 4.18 mostram a espacialização das classes ópticas e da estimativa da concentração da chl- a no reservatório de Ibitinga aplicando o MHL e o MHO até 1000 mg/m³ (MHL_ate1000 e MHO_ate1000), respectivamente, na imagem do MSI/Sentinel-2 com correção atmosférica e correção do *glint* (Figura 4.13B), referente ao campo de Agosto/2018. A Figura 4.17A mostra que o reservatório no dia 13 de agosto de 2018 era composto majoritariamente pela classe 2, usando o MHL. Pela análise da Figura 4.18A é possível notar que grande parte do reservatório nessa mesma data possuía classes 1 e 2, usando o MHO. Essa diferença de classificação do reservatório entre o MHL e MHO é devido principalmente ao range específico de concentração de chl- a considerado para a construção dos modelos híbridos. No MHL o range da classe 1 ($chl-a \leq 11,03$ mg/m³) é mais estreito que o considerado para o MHO ($2,89 \leq chl-a \leq 22,83$ mg/m³), sendo assim mais restrito na Figura 4.17A.

Percebe-se também que as regiões do reservatório que foram classificadas como classe 2 aplicando o MHO_ate1000 à imagem (Figura 4.18A) estão mais ou menos em concordância com as regiões da classe 2 aplicando o MHL_ate1000 (Figura 4.17A). Vale ressaltar que as regiões classificadas como classe 3 em ambos mapas também tiveram um pouco de concordância, mesmo essa classe tendo limiares mínimos um pouco diferentes (Tabela 4.1). Além disso, os valores estimados de concentração de chl-*a* para esta data, nos mapas gerados pelo MHL e MHO (Figuras 4.17B e 4.18B), foram em sua maioria entre 0 – 149 mg/m³.

Figura 4.17 - Espacialização das classes ópticas (A) e da estimativa da concentração da chl-*a* (B) aplicando o MHL_ate1000 na imagem MSI/Sentinel-2, referente ao campo do dia 13 de agosto de 2018 no reservatório de Ibitinga. As classes 1, 2 e 3 indicam a presença de baixa (verde), média (amarela) e alta (vermelha) intensidade de floração no reservatório, respectivamente. Obs: Classe 1 = OligoMeso, Classe 2 = EutroSuper e Classe 3 = Hiper.

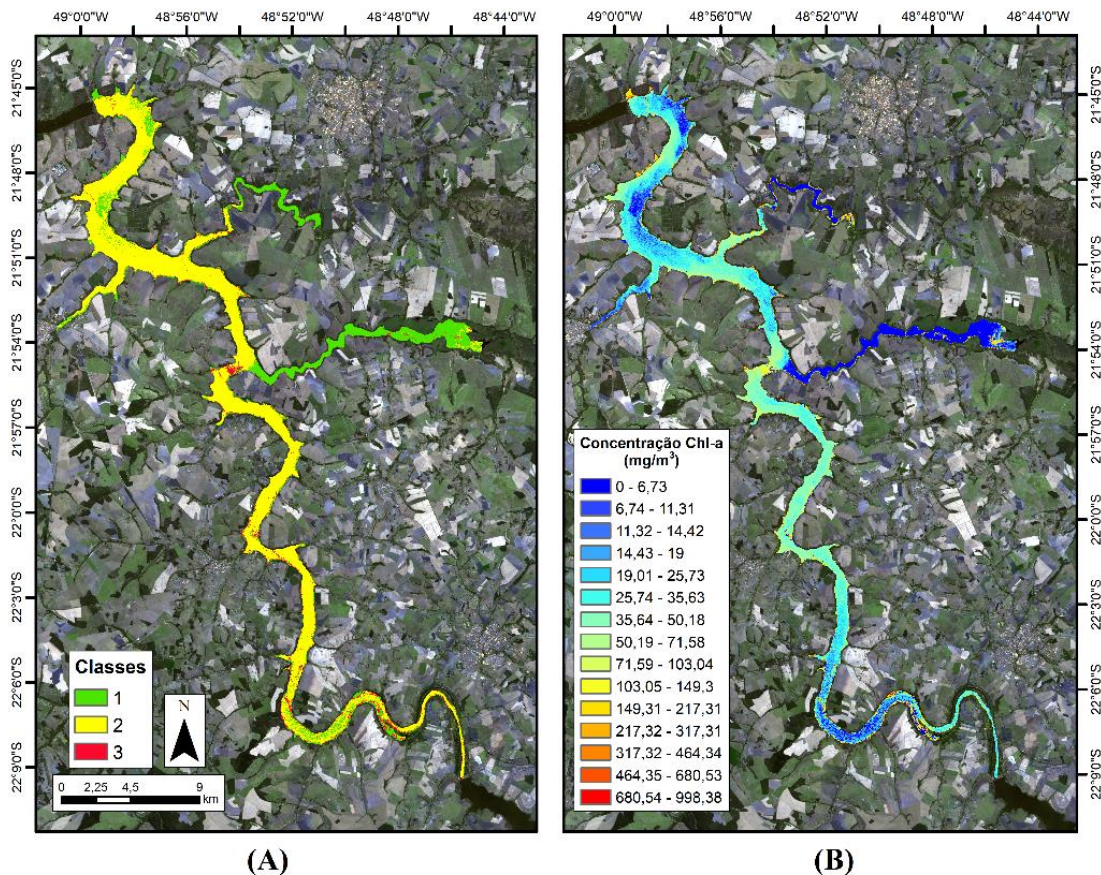
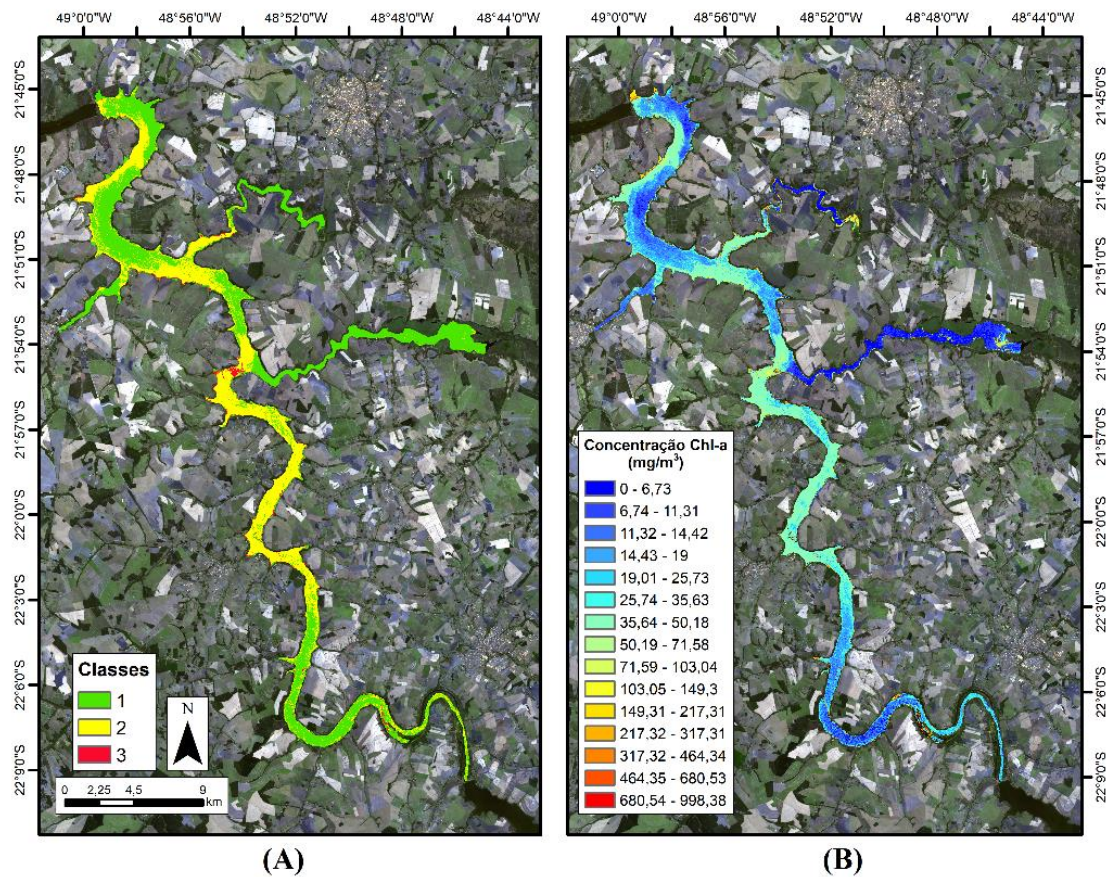


Figura 4.18 - Espacialização das classes ópticas (A) e da estimativa da concentração da chl-*a* (B) aplicando o MHO_ate1000 na imagem MSI/Sentinel-2, referente ao campo do dia 13 de agosto de 2018 no reservatório de Ibitinga. As classes 1, 2 e 3 indicam a presença de baixa (verde), média (amarela) e alta (vermelha) intensidade de floração no reservatório, respectivamente. Obs.: As classes 1, 2 e 3 são as respectivas classes ópticas do SAM.



4.6 Série temporal das classes ópticas, concentração da chl-*a* e estado trófico

As Figuras 4.19 até 4.24 e Figuras 4.25 até 4.30 mostram a série temporal dos mapas de classes ópticas e da concentração da chl-*a*, respectivamente, usando o MHL, para os anos de 2016 a 2019. Esses mapas foram gerados considerando as imagens do MSI/Sentinel-2 com até 20% de nuvens sobre o reservatório, abrangendo um total de 66 imagens. Além disso, a classe “sem classificação” (cor branca no mapa) é referente a presença de nuvens ou a valores de concentração de chl-*a* negativos.

A análise temporal das figuras (Figuras 4.19 até 4.24) mostrou que não houve um padrão de ocorrência das florações no reservatório de Ibitinga ao longo dos meses disponíveis

para essa análise. Em geral, do início de 2016 a setembro de 2019, houve predominância da classe óptica característica da baixa intensidade de floração em apenas 18% dos meses analisados, já a média intensidade de floração teve um pouco menos, no caso aproximadamente 11%. Entretanto, a classe óptica característica da elevada intensidade de floração teve maior predominância no reservatório em relação as duas outras classes ópticas, ocorrendo em cerca de 71% dos meses analisados. Vale ressaltar que a baixa intensidade de floração foi mais presente em alguns meses dos anos de 2016/2017, com concentração de chl-*a* de até 11,03 mg/m³, enquanto a média e elevada intensidades de floração foram bem mais marcantes ao longo dos meses a partir de 2018, com concentração de chl-*a* acima de 11,03 mg/m³.

Além disso, para os anos de 2016/2017, a porcentagem de ocorrência das classes ópticas no reservatório (min/máx; média) foi de: a) “Classe 1” com variação de 3,59 – 92,46% e média de 47,04%; b) “Classe 2” com variação de 0,05 – 56,28% e média de 10,63%; e c) “Classe 3” com variação de 1,34 – 96,35% e média de 42,33%. Já para os anos de 2018/2019, a porcentagem de ocorrência das classes ópticas foi de: a) “Classe 1” com variação de 4,50 – 41,51% e média de 10,67%; b) “Classe 2” com variação de 0,02 – 80,58% e média de 19,99%; e c) “Classe 3” com variação de 6,16 – 91,78% e média de 69,33%.

Comparando as classes ópticas dos anos 2016/2017 e 2018/2019 é possível notar que a presença da condição de baixa intensidade de floração foi reduzida em cerca de 36%, considerando o valor médio da porcentagem de ocorrência. Em contrapartida, as condições de média e elevada intensidades de floração aumentaram dos anos de 2016/2017 para 2018/2019, tendo um aumento de 9,36% para a “Classe 2” e 27,01% para a “Classe 3”.

As Figuras 4.31 até 4.36 mostram a análise temporal das classes ópticas e da concentração da chl-*a*, usando o MHL, para pontos definidos ao longo do reservatório de Ibitinga, presentes na Figura 3.12. Nessas figuras, os pontos pretos pequenos são valores médios mensais da concentração da chl-*a*, tendo em vista a possibilidade de se obter mais que uma imagem do MSI/Sentinel-2 por mês (frequência de imagens selecionadas por mês

presente na Tabela A.2 no Apêndice A). As linhas pretas pontilhadas ligam esses pontos pretos de forma a tentar mostrar uma tendência de variação média da concentração da chl-*a* em cada ano. Além disso, esses gráficos também foram gerados considerando as imagens do MSI/Sentinel-2 com até 20% de nuvens sobre o reservatório.

Pela análise das figuras, verificou-se que em todos os pontos (P1A à P6A) houve a presença da condição de elevada intensidade de floração ao longo dos anos analisados, sendo mais marcante nos anos de 2018/2019. A condição de baixa intensidade de floração esteve mais presente no ano de 2017 para todos os pontos, ocorrendo com maior frequência nos meses de maio a agosto, que é o período de baixa precipitação e temperatura na região. Já a condição de média intensidade de floração ocorreu mais nos anos de 2018/2019 na estação P4A, que está localizada na foz do rio Jacaré-Pepira e próximo a uma grande fazenda de piscicultura nas margens do reservatório. É possível notar também que para um mesmo mês, em alguns casos, os pontos P3A, P4A e P5A tiveram os três tipos de classes ópticas, como pode ser visto no mês de setembro/2018 para o P3A e no mês de junho/2019 para os três pontos. Isso indica que a variabilidade hidrodinâmica do reservatório pode influenciar bastante a formação espaço-temporal das florações.

Com relação à análise do valor médio de concentração de chl-*a*, nota-se que para todos os pontos em todos os anos houve uma elevada variação, com exceção dos meses de maio a agosto do ano de 2017 para os pontos P1A a P5A em que o valor médio de chl-*a* permaneceu praticamente constante. O maior valor médio de concentração mensal para o período analisado foi de aproximadamente: a) 670 mg/m³ no P1A em maio/2019; b) 335 mg/m³ no P2A em janeiro/2019; c) 210 mg/m³ no P3A em julho/2018; d) 260 mg/m³ no P4A em abril/2018; e) 335 mg/m³ no P5A em janeiro/2019; e f) 290 mg/m³ no P6A em julho/2018.

Analisando o valor médio, mínimo e máximo mensal de concentração de chl-*a* estimada para todo o reservatório (Figura 4.37) usando o MHL_ate1000, percebe-se que apenas o valor mínimo se manteve praticamente constante ao longo dos anos, com exceção de setembro/2016 em que a concentração de chl-*a* mínima mensal estimada foi de 97,84

mg/m³. Em 2017, os valores médio e máximo mensal tiveram um comportamento bem semelhante, decrescendo de abril a agosto e aumentando de agosto a outubro. No ano de 2018, o valor médio mensal foi decaindo de fevereiro a junho, com valor médio máximo e mínimo em julho e agosto, respectivamente, e com crescimento de agosto a novembro. Já em 2019, o valor médio mensal teve um decaimento brusco de janeiro a março, com aumento e redução mais brando entre os meses de março e junho e entre junho e setembro. Para o período, o intervalo (min/máx) de valores mínimo, máximo e médio mensal foi respectivamente: a) em 2016: 0 – 97,84 mg/m³, 101,42 – 365,89 mg/m³ e 6,94 – 170,14 mg/m³; b) em 2017: 0 – 4,58 mg/m³, 173,65 – 723,20 mg/m³ e 33,41 – 152,66 mg/m³; c) em 2018: 0 – 3,20 mg/m³, 172,20 – 734,12 mg/m³ e 58,92 – 219,33 mg/m³; e d) em 2019: 0 – 8,68 mg/m³, 181,27 – 821,35 mg/m³ e 75,48 – 249,55 mg/m³.

As Figuras 4.38 a 4.43 mostram a classificação dos estados tróficos da CETESB no reservatório de Ibitinga para os anos de 2016 a 2019, a partir do fatiamento do mapa de chl-*a*, estimada pelo MHL_ate1000. É possível observar que nos anos de 2016 e 2017, o estado trófico hipereutrófico possui presença marcante no reservatório em 50% e 69% das imagens disponíveis, respectivamente. Além disso, o estado trófico mesotrófico foi marcante em 25% das imagens para o ano de 2016 e 38% para o ano de 2017. A partir do ano de 2018, o reservatório foi predominantemente hipereutrófico na maioria dos meses, sendo marcante em cerca de 91% das imagens em 2018 e 87% em 2019. Vale ressaltar que a porcentagem de ocorrência (min/máx) dos estados tróficos no reservatório foi: a) em 2016: 0,68 – 22,30% para o ultraoligotrófico, 0 – 29,19% para o oligotrófico, 0,53 – 92,22% para o mesotrófico, 0,40 – 26,51% para o eutrófico, 0,21 – 30,58% para o supereutrófico e 2,15 – 98,08% para o supereutrófico; b) em 2017: 1,45 – 15,25% para o ultraoligotrófico, 0,01 – 36,44% para o oligotrófico, 0,71 – 47,66% para o mesotrófico, 0,90 – 27,29% para o eutrófico, 0,42 – 7,02% para o supereutrófico e 7,04 – 94,32% para o supereutrófico; c) em 2018: 1,12 – 18,62% para o ultraoligotrófico, 0 – 1,49% para o oligotrófico, 0,08 – 7,70% para o mesotrófico, 0,26 – 34,04% para o eutrófico, 0,39 – 48,96% para o supereutrófico e 7,20 – 95,48% para o supereutrófico; e d) em 2019: 1,26 – 10,05% para o ultraoligotrófico, 0 – 3,78% para o oligotrófico, 0,05 – 31,64% para o mesotrófico, 0,12 – 41,44% para o eutrófico, 0,26 – 53,33% para o supereutrófico e 26,50 – 95,84% para o supereutrófico.

Figura 4.19 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses dos anos 2016 e 2017 (conjunto 1). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.

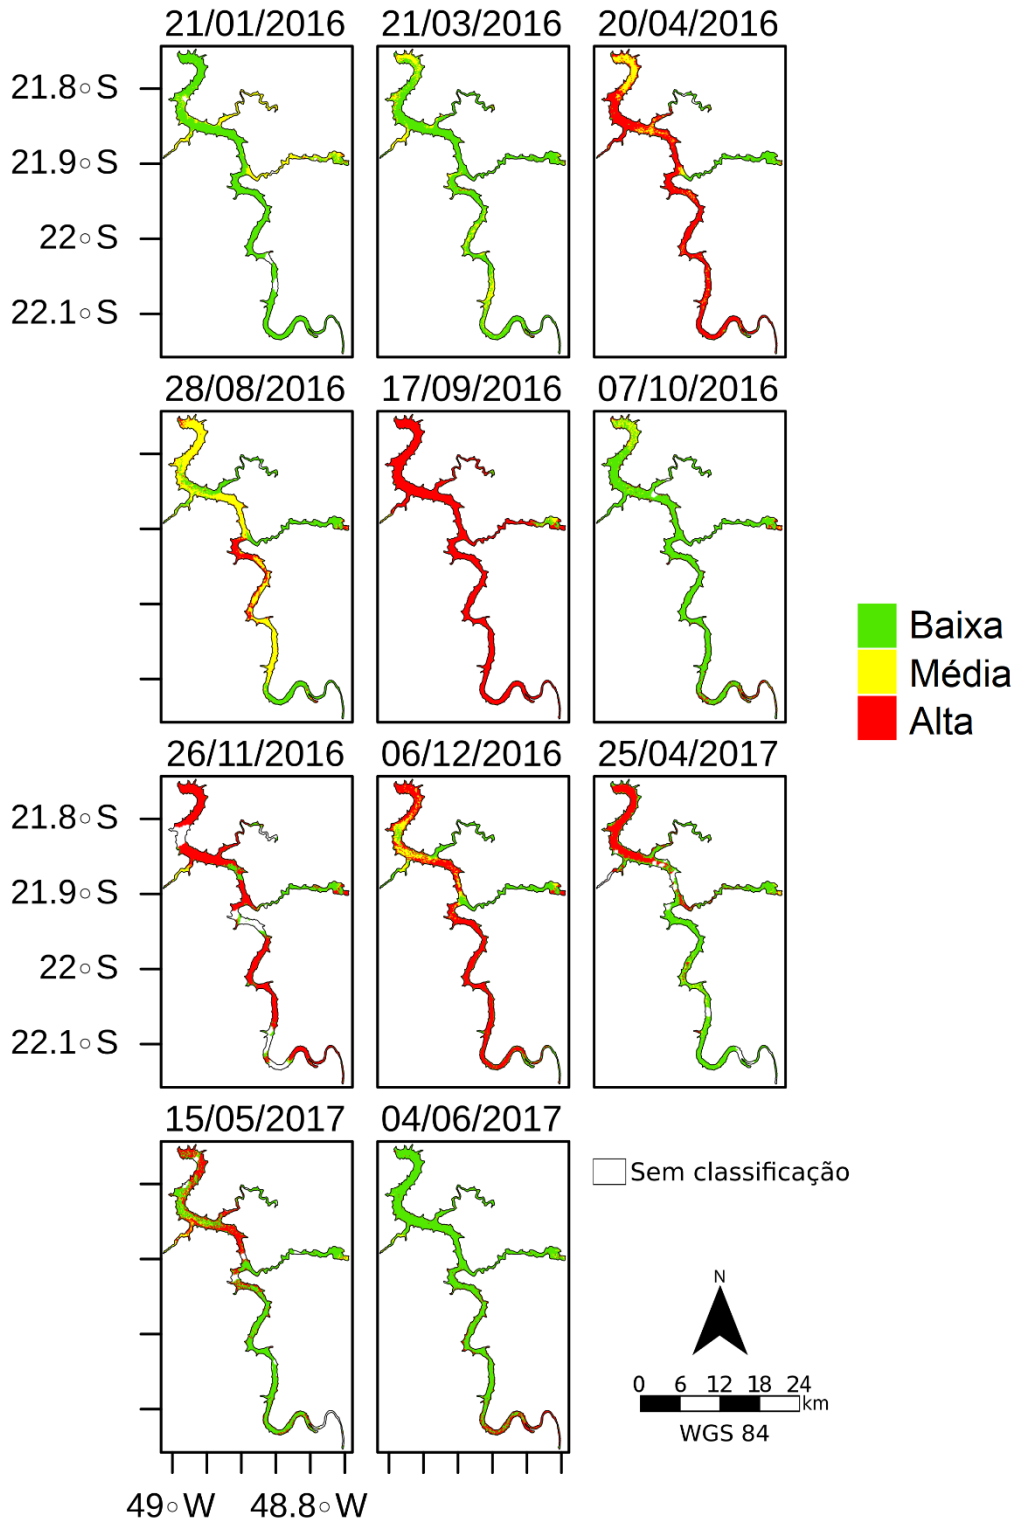


Figura 4.20 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses dos anos 2017 e 2018 (conjunto 2). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.




Figura 4.21 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses do ano 2018 (conjunto 3). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.




Figura 4.22 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses dos anos 2018 e 2019 (conjunto 4). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.




Figura 4.23 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses do ano 2019 (conjunto 5). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.




Figura 4.24 – Mapa das classes ópticas gerado a partir do MHL, referente aos meses do ano 2019 (conjunto 6). As cores verde (classe óptica “OligoMeso”), amarela (classe óptica “EutroSuper”) e vermelha (classe óptica “Hiper) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.




Figura 4.25 – Mapa de concentração de chl-*a* gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses dos anos 2016 e 2017 (conjunto 1).

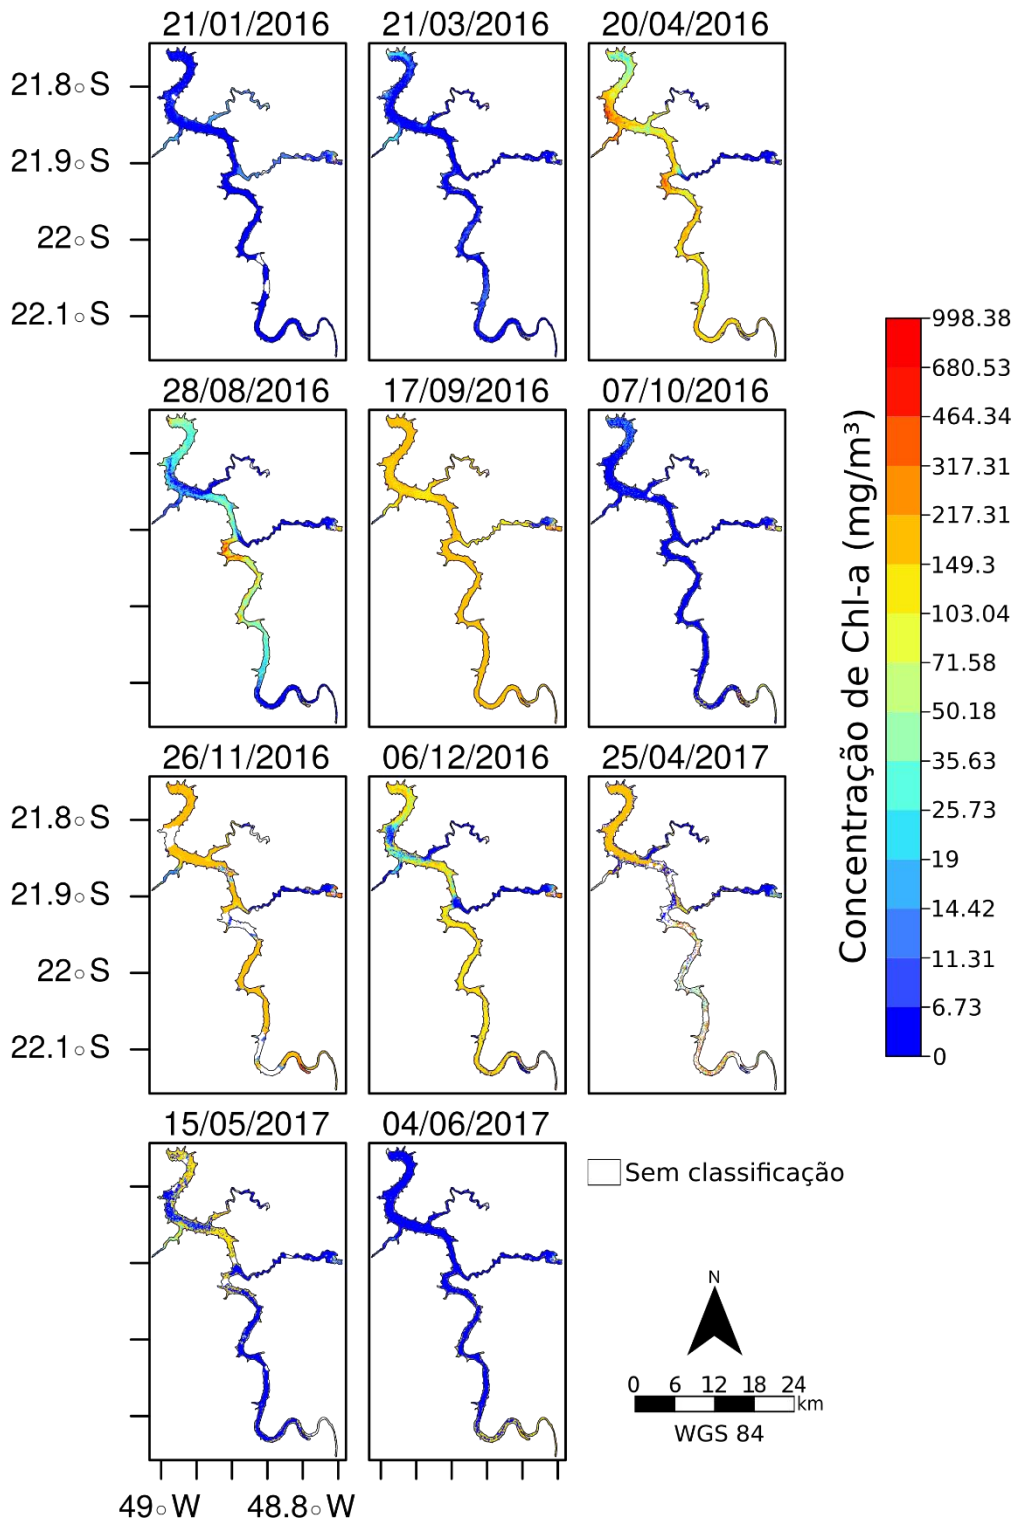


Figura 4.26 – Mapa de concentração de chl-*a* gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses dos anos 2017 e 2018 (conjunto 2).

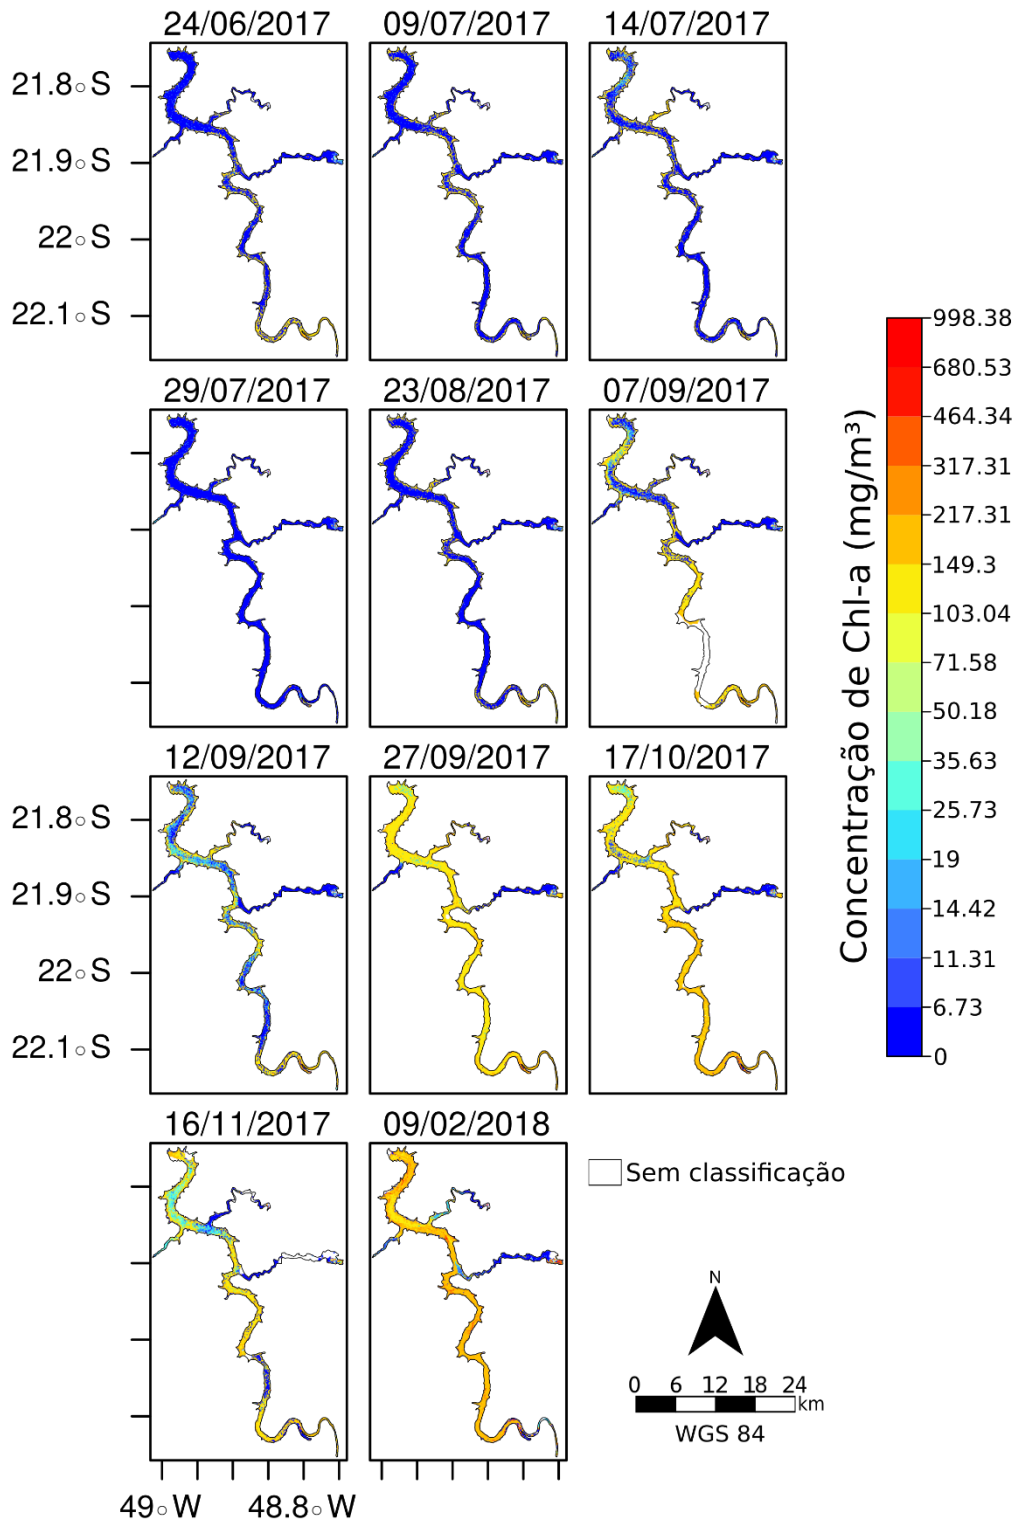


Figura 4.27 – Mapa de concentração de chl-a gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses do ano 2018 (conjunto 3).

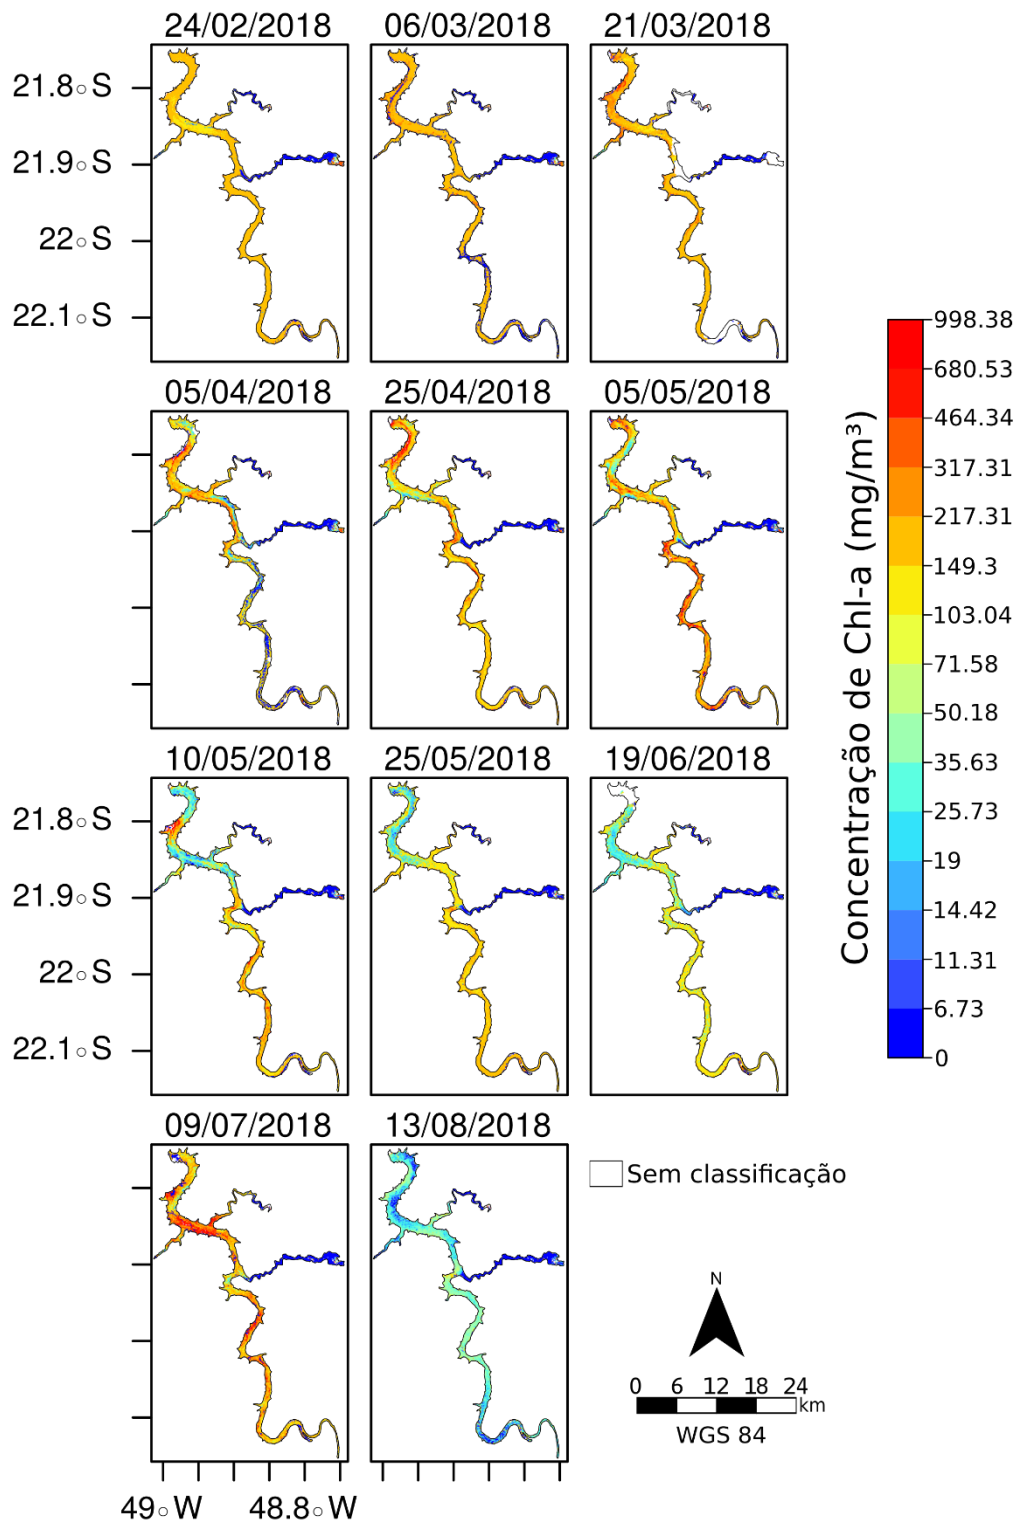


Figura 4.28 – Mapa de concentração de chl-*a* gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses dos anos 2018 e 2019 (conjunto 4).

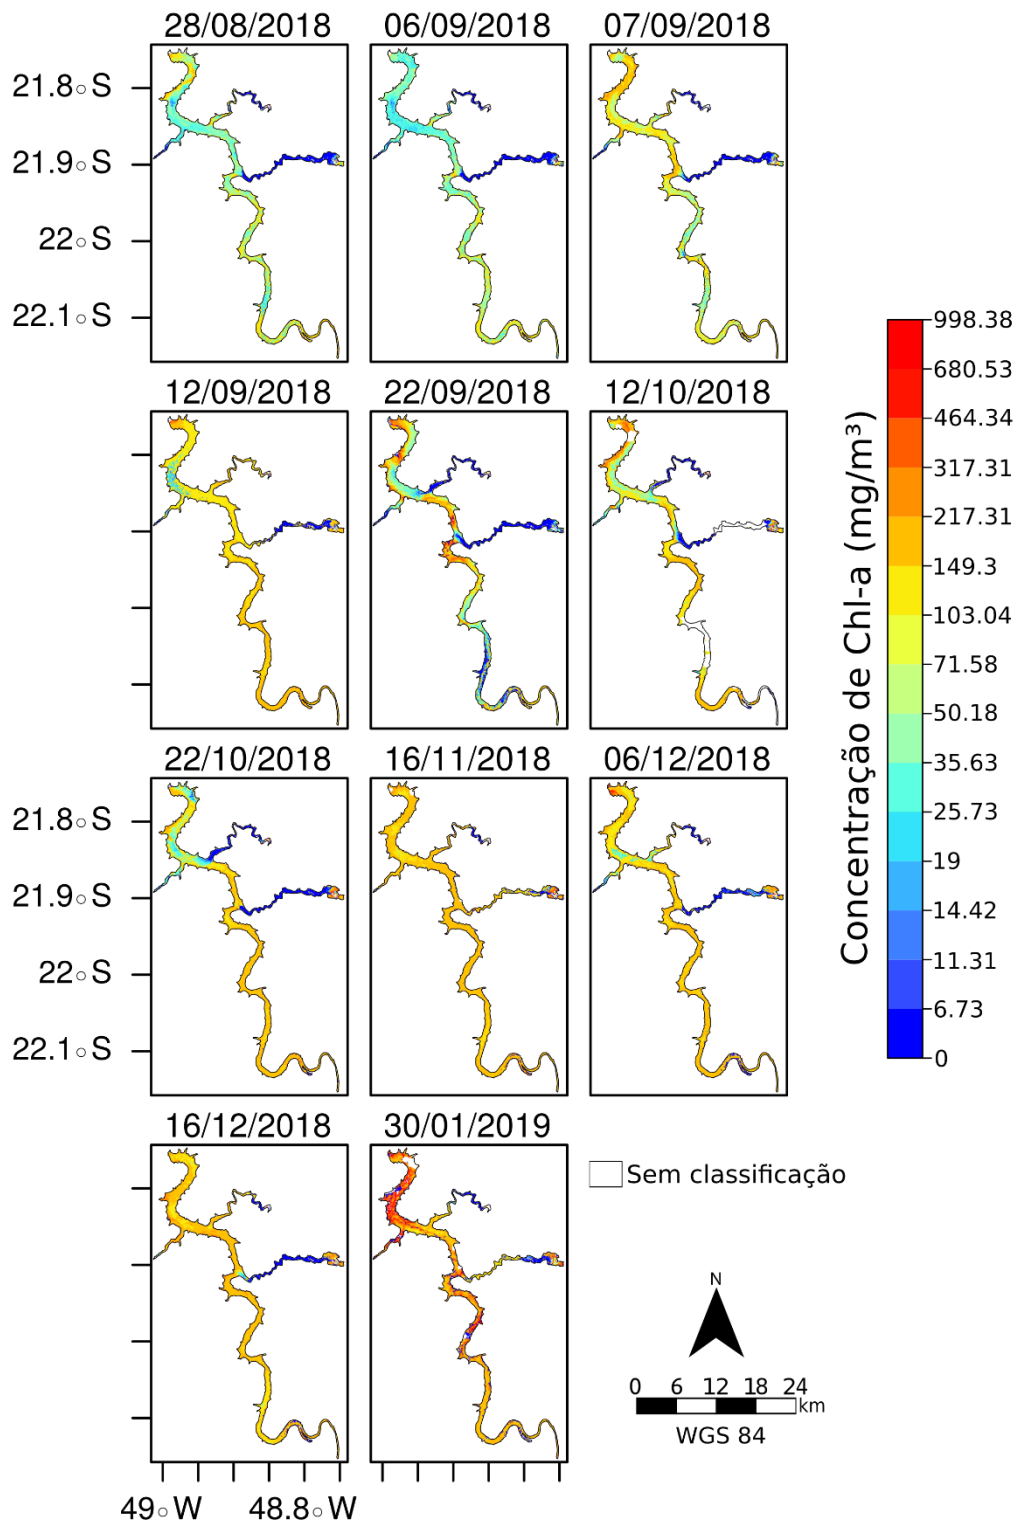


Figura 4.29 – Mapa de concentração de chl-*a* gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses do ano 2019 (conjunto 5).

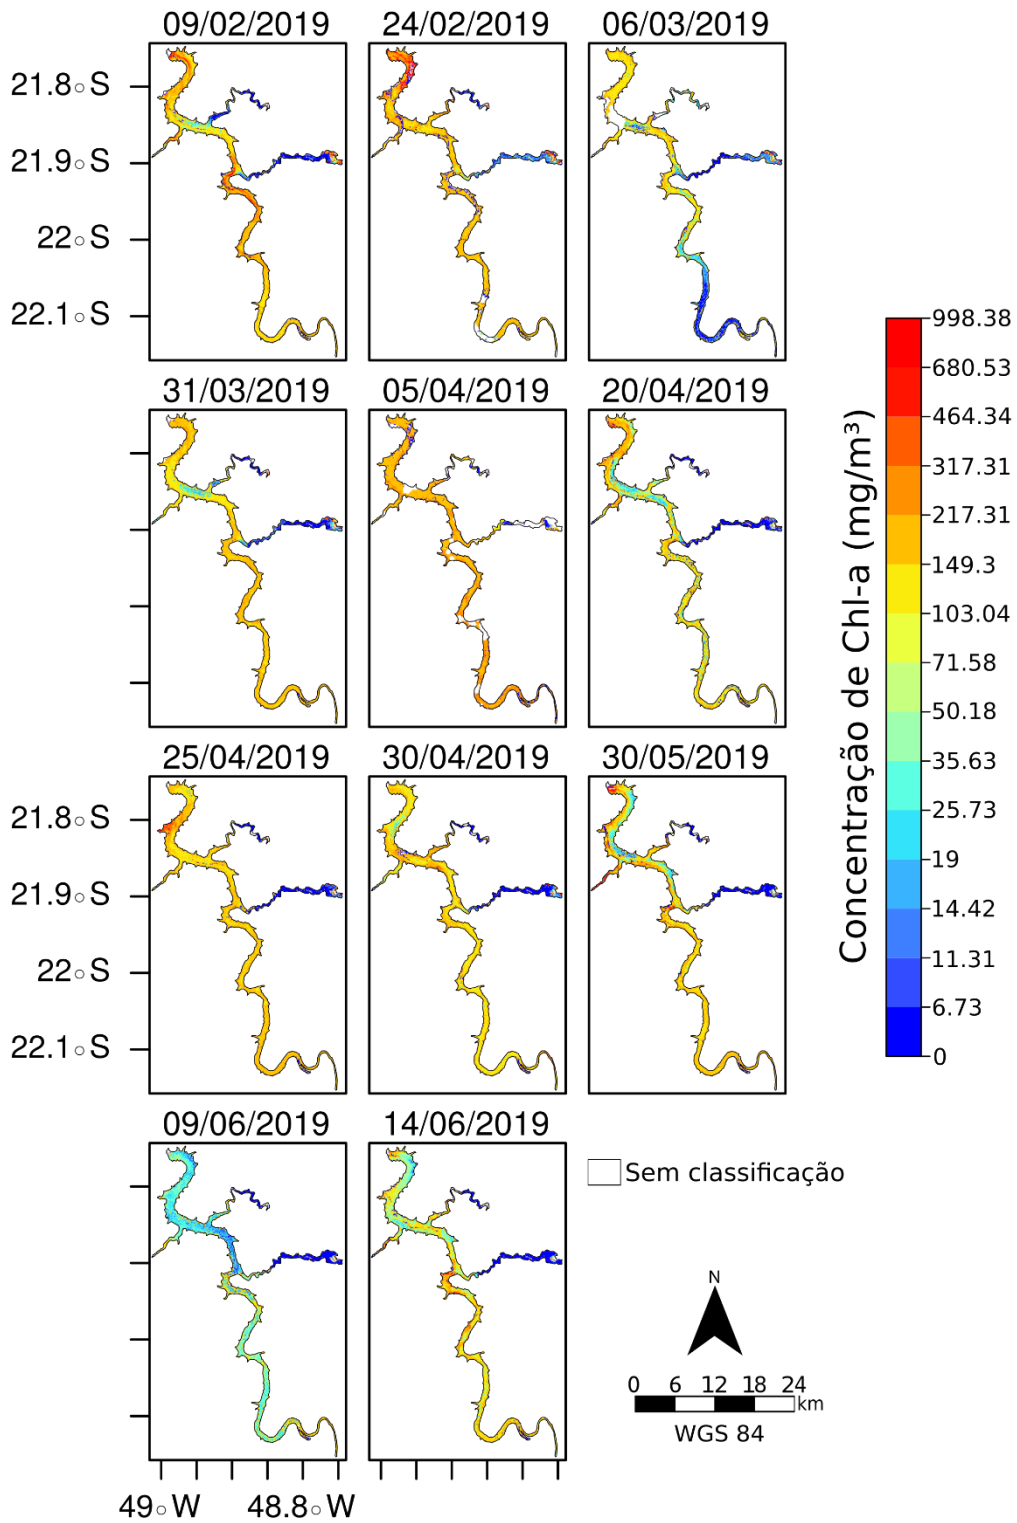


Figura 4.30 – Mapa de concentração de chl-*a* gerado a partir do MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), referente aos meses do ano 2019 (conjunto 6).

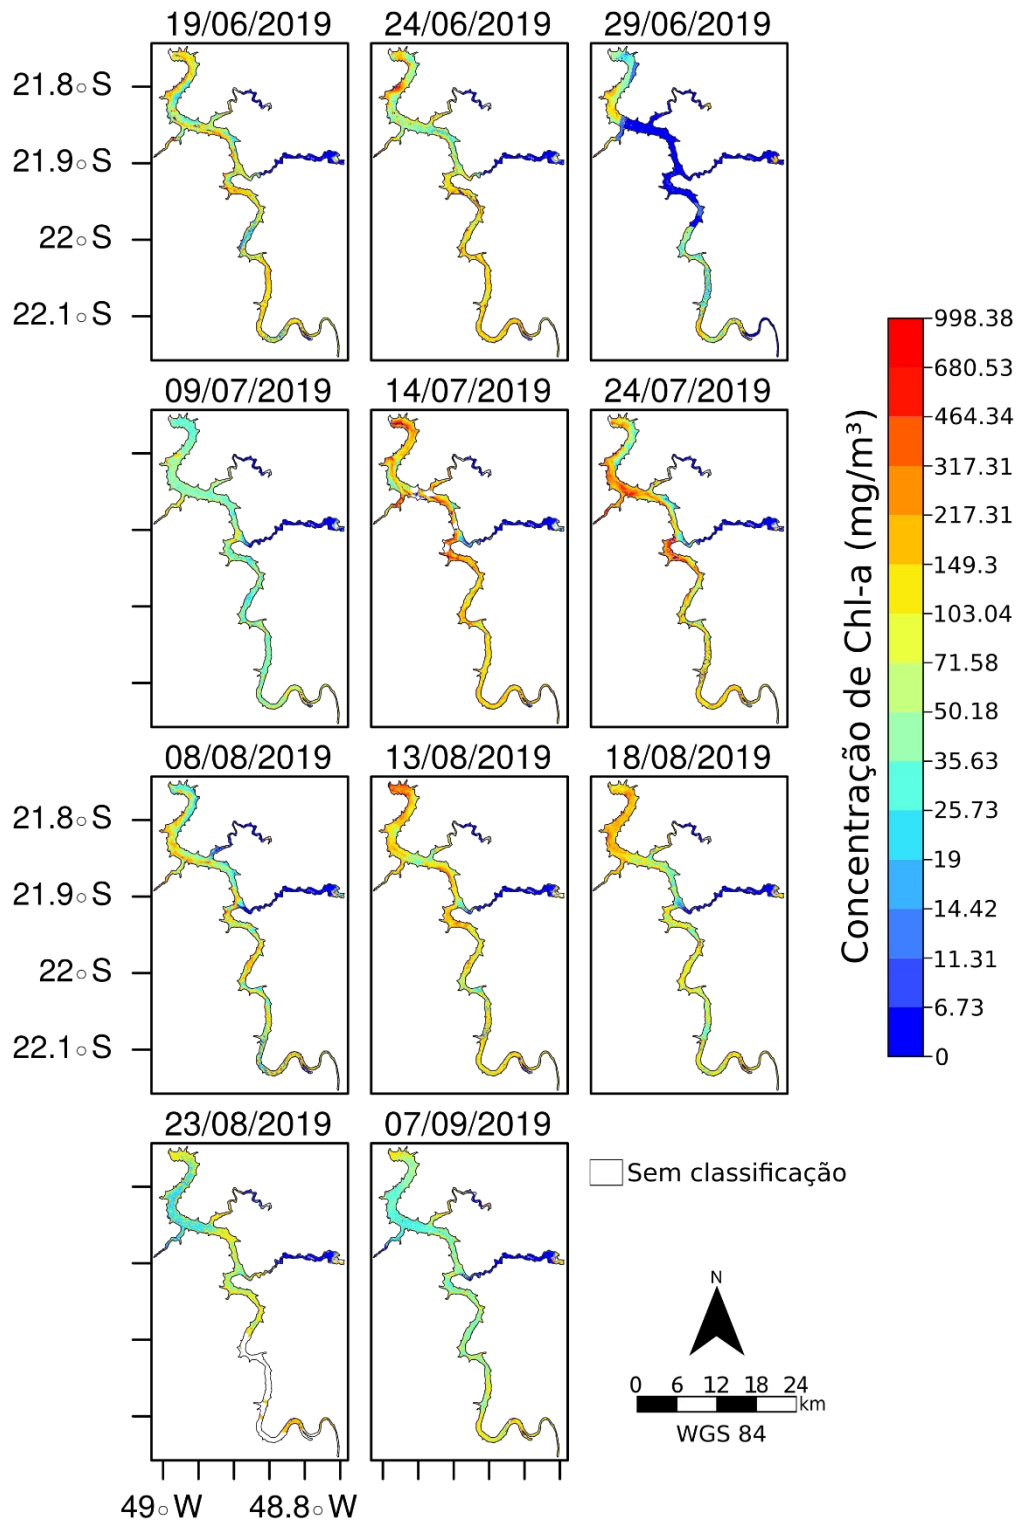


Figura 4.31 – Análise temporal das classes ópticas e da concentração da chl-a geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3) referente à estação amostral P1A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-a e a linha preta pontilhada a tendência de variação média da chl-a em P1A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.




Figura 4.32 – Análise temporal das classes ópticas e da concentração da chl-a geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3) referente à estação amostral P2A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-a e a linha preta pontilhada a tendência de variação média da chl-a em P2A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.




Figura 4.33 – Análise temporal das classes ópticas e da concentração da chl-a geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3) referente à estação amostral P3A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-a e a linha preta pontilhada a tendência de variação média da chl-a em P3A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.




Figura 4.34 – Análise temporal das classes ópticas e da concentração da chl-a geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3) referente à estação amostral P4A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-a e a linha preta pontilhada a tendência de variação média da chl-a em P4A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.




Figura 4.35 – Análise temporal das classes ópticas e da concentração da chl-a geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3) referente à estação amostral P5A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-a e a linha preta pontilhada a tendência de variação média da chl-a em P5A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.




Figura 4.36 – Análise temporal das classes ópticas e da concentração da chl-a geradas pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3) referente à estação amostral P6A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-a e a linha preta pontilhada a tendência de variação média da chl-a em P6A ao longo dos anos. Classe 1 = “OligoMeso”, Classe 2 = “EutroSuper” e Classe 3 = “Hiper”.




Figura 4.37 – Análise temporal do valor mínimo, máximo e médio da concentração de chl-*a* estimada pelo MHL_ate1000 (classe 3 usando o algoritmo da classe óptica “Hiper_ate1000” – Tabela 4.3), para todo o reservatório de Ibitinga. Esses valores abrangem uma representatividade de 96% dos dados de chl-*a* estimada, pois os *outliers* foram excluídos desconsiderando os percentis dos 2% iniciais e finais do conjunto de dados.




Figura 4.38 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.25), referente aos meses dos anos 2016 e 2017 (conjunto 1).

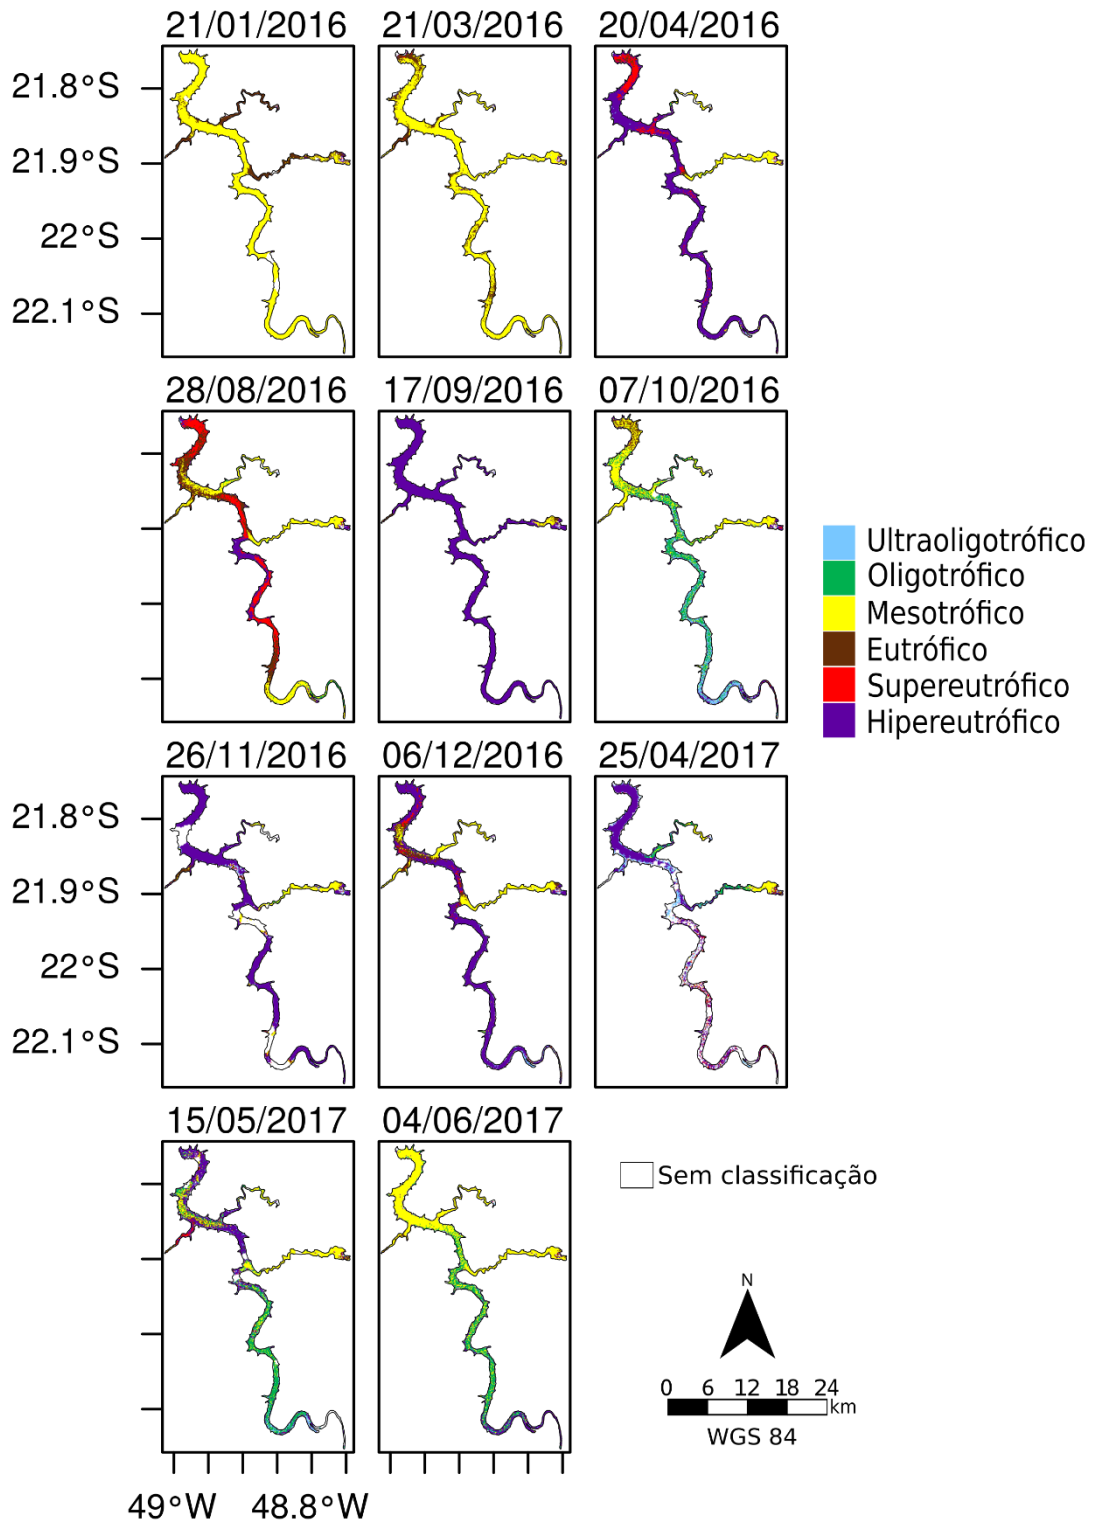


Figura 4.39 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.26), referente aos meses dos anos 2017 e 2018 (conjunto 2).

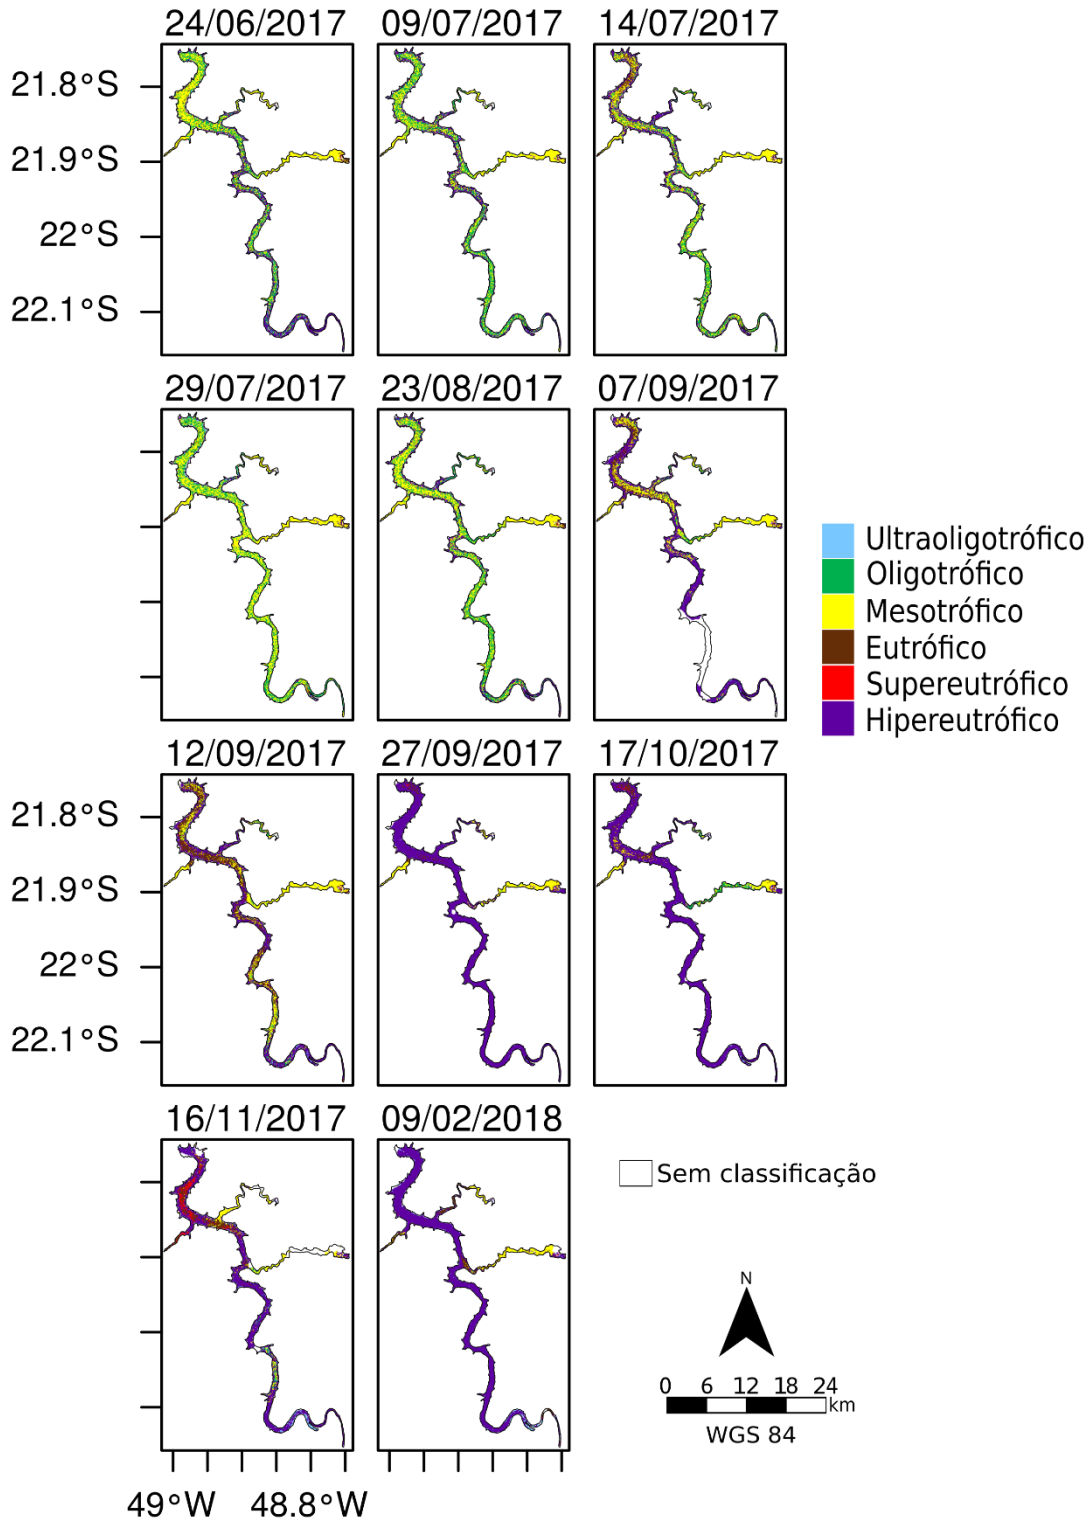


Figura 4.40 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.27), referente aos meses do ano 2018 (conjunto 3).

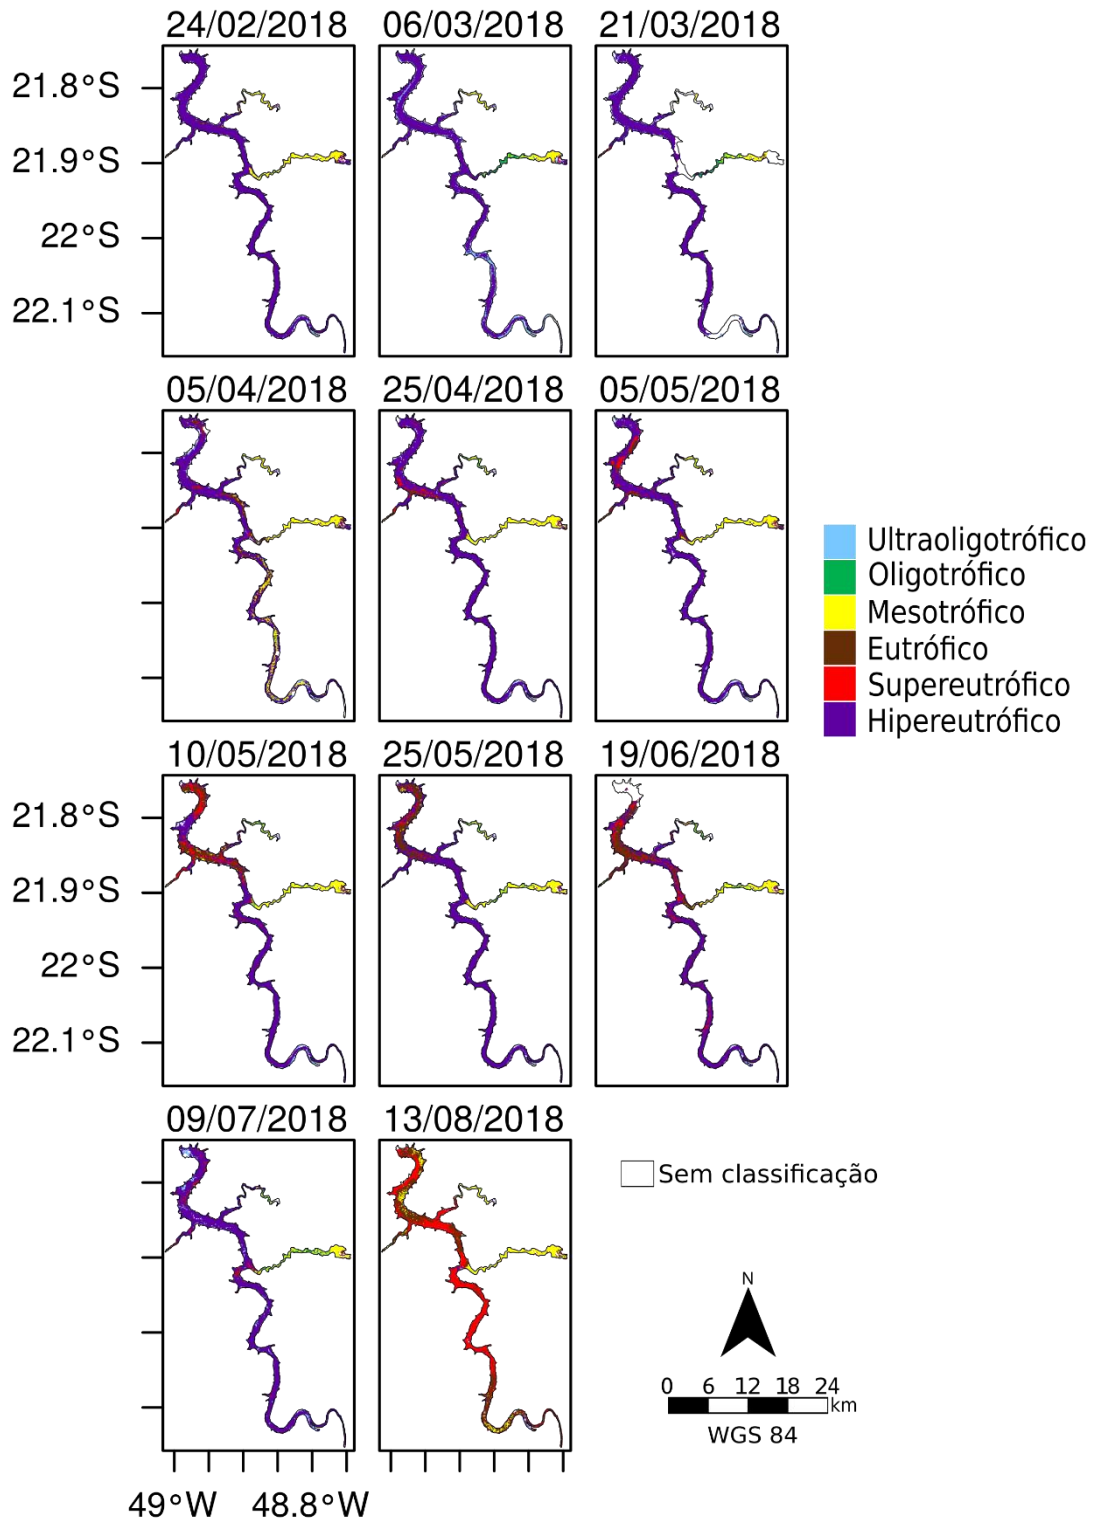


Figura 4.41 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.28), referente aos meses dos anos 2018 e 2019 (conjunto 4).

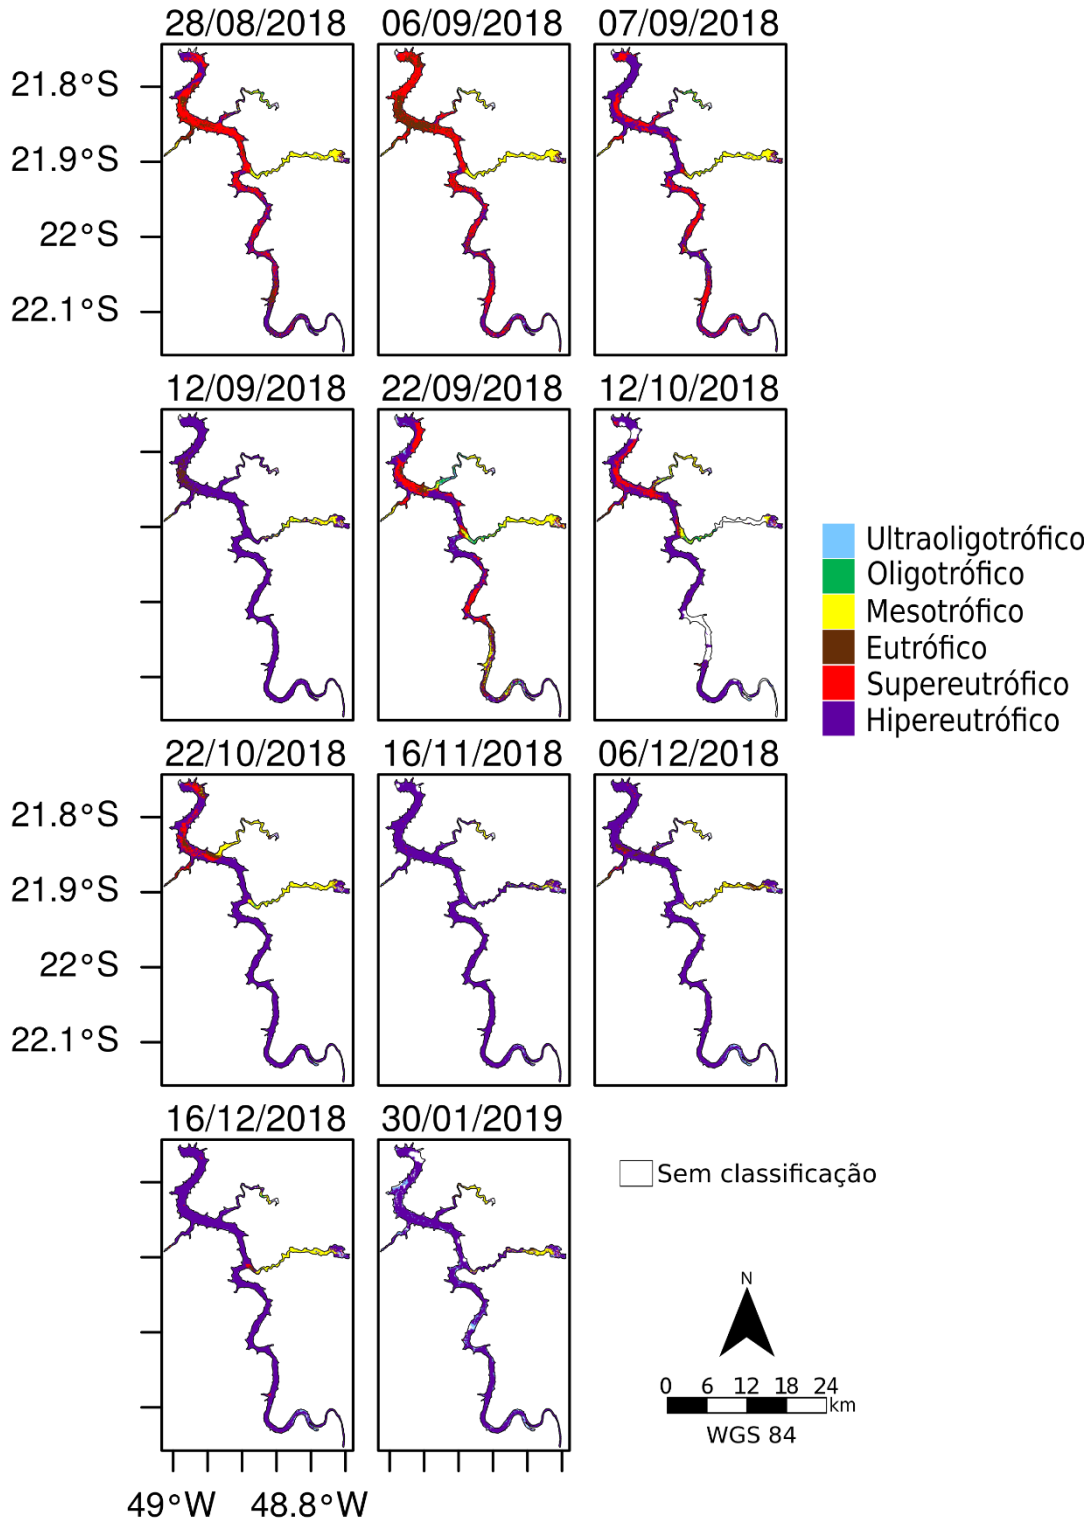


Figura 4.42 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.29), referente aos meses do ano 2019 (conjunto 5).

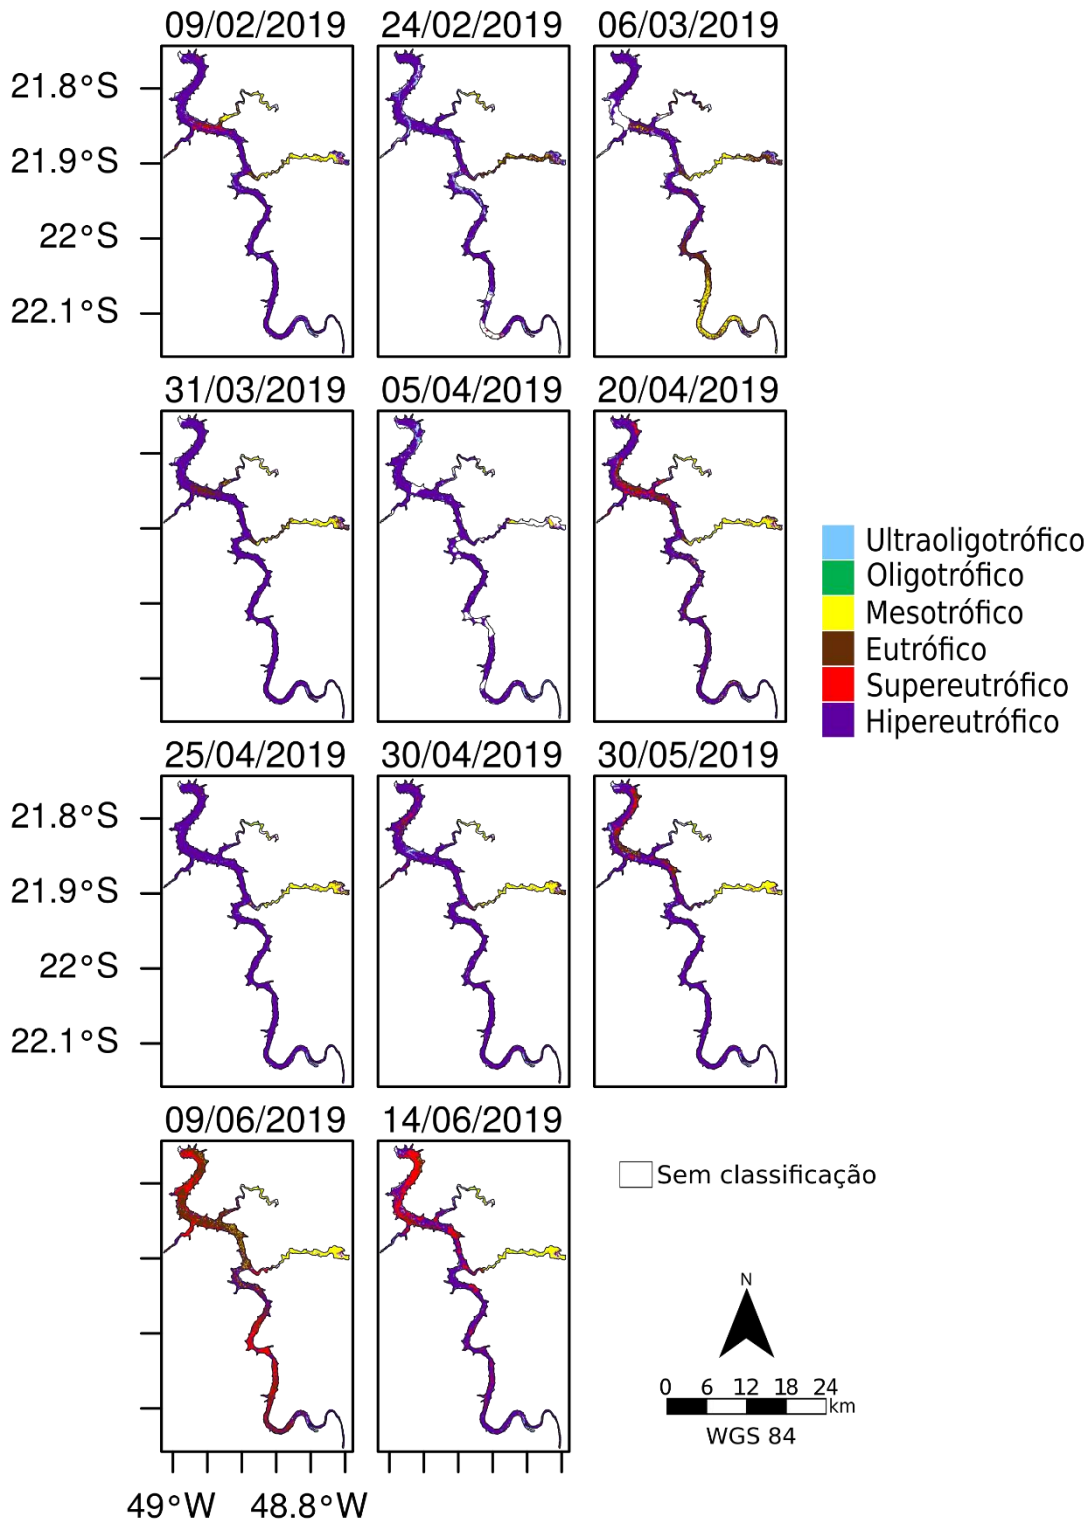
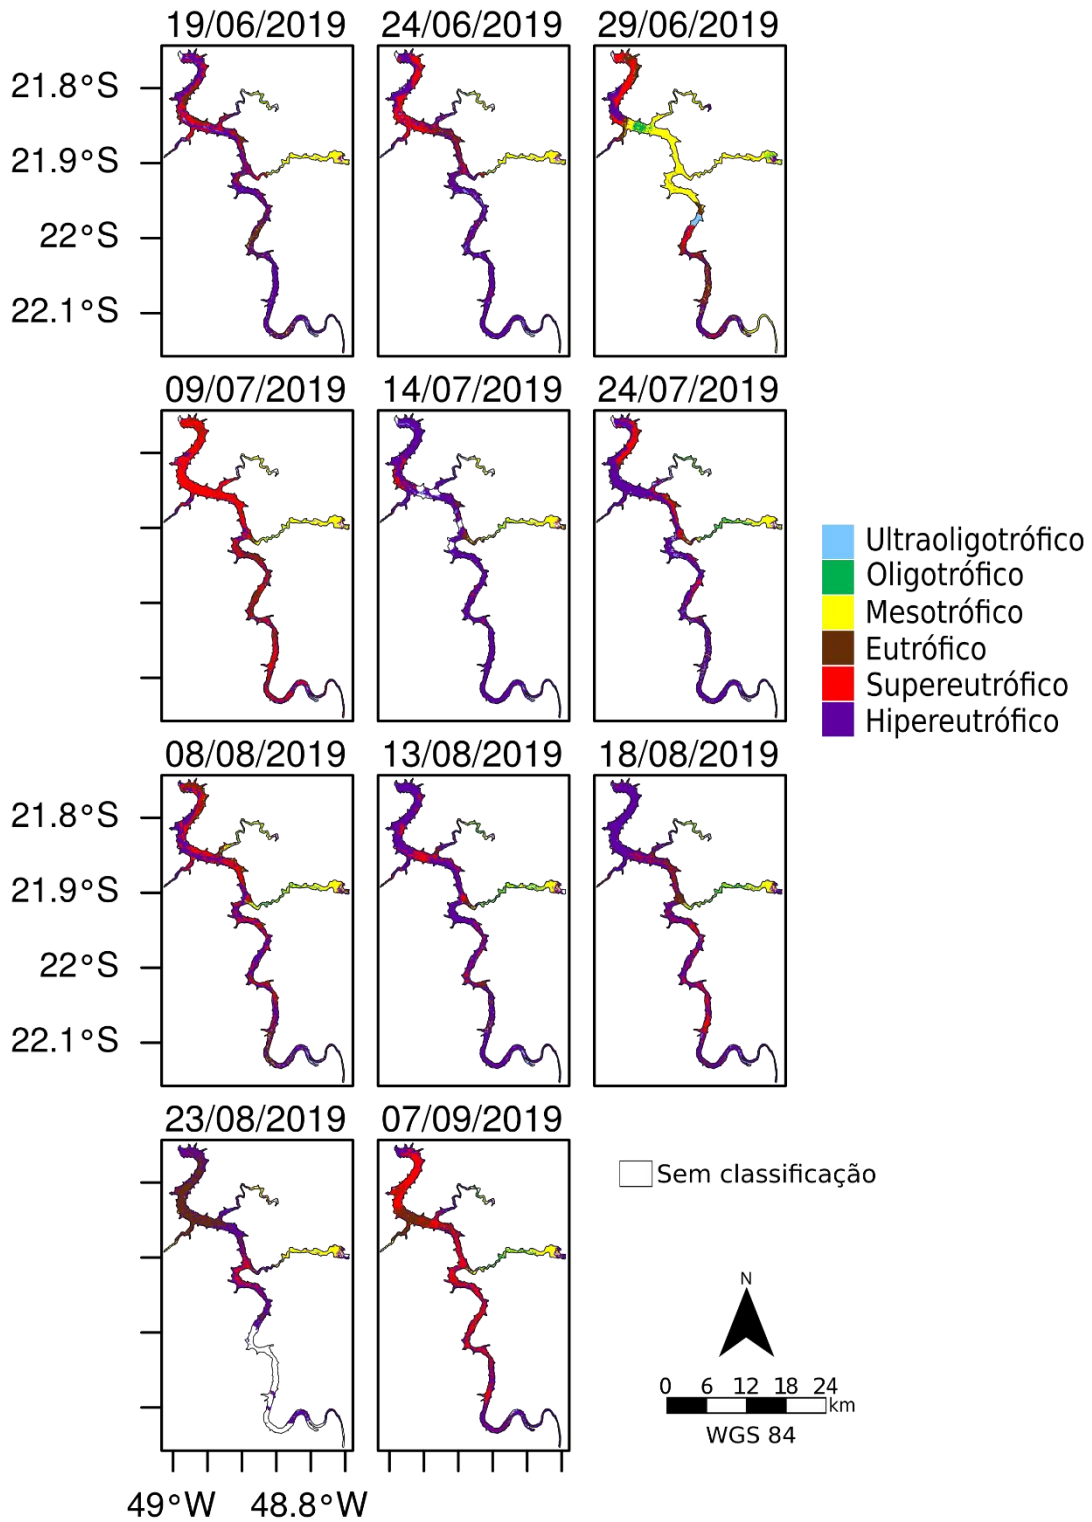


Figura 4.43 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.30), referente aos meses do ano 2019 (conjunto 6).



As Figuras 4.44 até 4.49 e Figuras 4.50 até 4.55 mostram a série temporal dos mapas das classes ópticas e da concentração da chl-*a*, respectivamente, usando o MHO, para os anos de 2016 a 2019. Vale ressaltar que esses mapas foram gerados considerando as imagens do MSI/Sentinel-2 com até 20% de nuvens sobre o reservatório, obtendo um total de 66 imagens. Além disso, a classe “sem classificação” (cor branca no mapa) é referente a presença de nuvens ou a valores de concentração de chl-*a* negativos.

A análise temporal das figuras mostrou que nos anos de 2016 e 2017 (de acordo com os meses disponíveis para essa análise), o reservatório de Ibitinga apresentou na maior parte do tempo a classe óptica característica da condição de baixa intensidade de floração, com concentração de chl-*a* até 22,83 mg/m³. A porcentagem de ocorrência das classes ópticas no reservatório (min/máx; média), para essa época, foi de: a) “Classe 1” com variação de 17,78 – 99,16% e média de 84,32%; b) “Classe 2” com variação de 0,53 – 46,11% e média de 11,50%; e c) “Classe 3” com variação de 0,32 – 36,12% e média de 4,18%. A partir de 2018, a intensidade de floração no reservatório piorou. Houve predominância da média intensidade de floração em cerca de 65% dos meses analisados, com concentração da chl-*a* variando de 19,51 – 87,63 mg/m³. Notou-se também que em 2018/2019 não houve um padrão de ocorrência das florações, tendo um aumento de sua frequência ao longo dos meses. Além disso, a porcentagem de ocorrência das classes ópticas no reservatório para os meses dos anos 2018/2019 foi de: a) “Classe 1” com variação de 8,96 – 71,70% e média de 33,25%; b) “Classe 2” com variação de 19,49 – 71,49% e média de 48,28%; e c) “Classe 3” com variação de 0,95 – 50,98% e média de 18,47%.

Comparando as classes ópticas dos anos 2016/2017 e 2018/2019 é possível notar que a presença da condição de baixa intensidade de floração foi reduzida mais do que a metade (redução de 51,07% para a “Classe 1”), considerando o valor médio da porcentagem de ocorrência. Em contrapartida, as condições de média e elevada intensidades de floração aumentaram um pouco mais de três vezes dos anos de 2016/2017 para 2018/2019, tendo um aumento de 36,77% para a “Classe 2” e 14,29% para a “Classe 3”.

As Figuras 4.56 até 4.61 mostram a análise temporal das classes ópticas e da concentração da chl-*a*, usando o MHO, para pontos definidos ao longo do reservatório de Ibitinga,

presentes na Figura 3.12. Nessas figuras, os pontos pretos pequenos são valores médios mensais da concentração da chl-*a*, tendo em vista a possibilidade de se obter mais que uma imagem do MSI/Sentinel-2 por mês (frequência de imagens selecionadas por mês presente na Tabela A.2 no Apêndice A). As linhas pretas pontilhadas ligam esses pontos pretos de forma a tentar mostrar uma tendência de variação média da concentração da chl-*a* em cada ano. Além disso, esses gráficos também foram gerados considerando as imagens do MSI/Sentinel-2 com até 20% de nuvens sobre o reservatório.

Pela análise das figuras, verificou-se que de todos os pontos selecionados ao longo do reservatório, os que mais tiveram elevada intensidade de floração foram os pontos P1A e P2A, nos anos de 2018/2019, localizados próximos à barragem. Além do mais, nesses anos, o P1A e P2A também apresentaram uma elevada variação do valor médio de concentração da chl-*a*. Já em 2016/2017, os pontos P1A e P2A obtiveram maior frequência da condição de baixa intensidade de floração. Além disso, é possível notar também que para um mesmo mês, em alguns casos, esses pontos tiveram os três tipos de classes ópticas, como pode ser visto no mês de agosto/2019 para o P1A e o no mês de junho/2019 para o P2A. Isso enfatiza que a variabilidade hidrodinâmica do reservatório pode influenciar bastante a formação das florações. Vale ressaltar que o maior valor médio mensal aproximado de concentração de chl-*a* obtido, usando o MHO, para o ano de: a) 2016 foi de 70 mg/m³ para o P1A e 230 mg/m³ para o P2A; b) 2017 foi de 40 mg/m³ para o P1A e 35 mg/m³ para o P2A; c) 2018 foi de 430 mg/m³ para o P1A e 310 mg/m³ para o P2A; e d) 2019 foi de 830 mg/m³ para o P1A e 650 mg/m³ para o P2A.

Com relação aos pontos P3A e P4A, localizados na foz dos rios Jacaré-Guaçu e Jacaré-Pepira respectivamente, houve maior frequência da condição de baixa e média intensidades de floração ao longo dos anos. A média intensidade de floração foi mais presente nos anos de 2018/2019 e a baixa intensidade de floração nos anos de 2016/2017. Em 2018, o P3A teve uma elevada variação do valor médio de concentração da chl-*a* ao longo dos meses, enquanto que em 2019 teve uma média variação. Já o P4A nos anos de 2018/2019 teve uma baixa variação do valor médio de concentração de chl-*a* ao longo dos meses, com exceção dos meses de abril e maio de 2018 e janeiro de 2019. Além disso, o maior valor médio mensal aproximado de concentração de chl-*a* obtido no ano

de: a) 2016 foi de 125 mg/m³ para o P3A e 40 mg/m³ para o P4A; b) 2017 foi de 15 mg/m³ para o P3A e 20 mg/m³ para o P4A; c) 2018 foi de 265 mg/m³ para o P3A e 500 mg/m³ para o P4A; e d) 2019 foi de 125 mg/m³ para o P3A e 440 mg/m³ para o P4A.

O ponto P5A apresentou, principalmente, a condição de média intensidade de floração em 2018/2019, que é uma região próxima a um aglomerado de casas nas margens do reservatório, no município de Arealva. Em 2018, P5A teve uma elevada variação do valor médio da concentração da chl-*a* ao longo dos meses, e em 2019 essa variação foi baixa, principalmente após o mês de fevereiro. Já no ponto P6A a intensidade de floração variou de baixa à média nos anos de 2018/2019, e pela imagem de satélite parece ser uma região próxima a uma grande piscicultura nas margens do reservatório de Ibitinga, entre os municípios de Arealva e Bariri. Em 2018/2019 foi baixa a variação do valor médio de concentração da chl-*a* ao longo dos meses, com exceção do elevado valor de chl-*a* ocorrido em julho/2018. Vale ressaltar também que, assim como os outros pontos nos anos de 2016/2017, P5A e P6A também tiveram maior frequência da condição de baixa intensidade de floração. Por fim, o maior valor médio mensal aproximado de concentração de chl-*a* obtido no ano de: a) 2016 foi de 220 mg/m³ para o P5A e 35 mg/m³ para o P6A; b) 2017 foi de 50 mg/m³ para o P5A e 60 mg/m³ para o P6A; c) 2018 foi de 300 mg/m³ para o P5A e 420 mg/m³ para o P6A; e d) 2019 foi de 710 mg/m³ para o P5A e 50 mg/m³ para o P6A.

Analisando o valor médio, mínimo e máximo mensal de concentração de chl-*a* estimada para todo o reservatório (Figura 4.62) usando o MHO_ate1000, percebe-se que apenas o valor mínimo se manteve praticamente constante ao longo dos anos. Com relação ao valor médio e máximo mensal, é possível notar que não existe um padrão de variação mensal entre os anos de 2016 a 2019. Em 2016, o valor médio máximo de chl-*a* ocorreu no mês de abril e houve um aumento da concentração de setembro a novembro. Já em 2017, o valor médio de chl-*a* no reservatório decaiu de abril a junho, permanecendo sem grandes variações até novembro. Além disso, em 2018 o valor médio máximo de chl-*a* ocorreu em março e julho, e houve um crescimento de agosto a dezembro. Em 2019, houve uma queda brusca da concentração média de chl-*a* de janeiro a março no reservatório, tendo valores médios máximos em abril e julho. Para o período, o intervalo (min/máx) de

valores mínimo, máximo e médio mensal foi respectivamente: a) em 2016: 0,32 – 11,26 mg/m³, 63,64 – 755,36 mg/m³ e 9,07 – 109,41 mg/m³; b) em 2017: 0,13 – 6,83 mg/m³, 353,81 – 679,64 mg/m³ e 21,81 – 119,45 mg/m³; c) em 2018: 2,47 – 31,34 mg/m³, 247,44 – 830,74 mg/m³ e 34 – 252,19 mg/m³; e d) em 2019: 2,90 – 25,06 mg/m³, 137,82 – 838,58 mg/m³ e 36,37 – 309,94 mg/m³.

As Figuras 4.63 a 4.68 mostram a classificação dos estados tróficos da CETESB no reservatório de Ibitinga para os anos de 2016 a 2019, a partir do fatiamento do mapa de chl-*a*, estimada pelo MHO_ate1000. É possível observar que em 2016, o reservatório teve maior presença dos estados tróficos mesotrófico e supereutrófico em 37,5% e 50% das imagens disponíveis, respectivamente. No ano de 2017, o estado trófico mais marcante ao longo dos meses foi o mesotrófico, com ocorrência em 61,5% das imagens. Em 2017, o reservatório foi evoluindo de predominantemente mesotrófico nos meses de junho/julho/agosto, para eutrófico em setembro/outubro/novembro e no início de 2018 para supereutrófico (mês de fevereiro). O estado trófico supereutrófico permaneceu predominante no reservatório na maioria dos meses de 2018 e 2019, ocorrendo em 68,2% e 73,9% das imagens nesses anos, respectivamente. Vale ressaltar que a porcentagem de ocorrência (min/máx) dos estados tróficos no reservatório foi: a) em 2016: 0 – 7,88% para o ultraoligotrófico, 0,03 – 14,90% para o oligotrófico, 1,50 – 94,40% para o mesotrófico, 2,20 – 75,71% para o eutrófico, 1,21 – 51,81% para o supereutrófico e 1,86 – 38,39% para o hipereutrófico; b) em 2017: 0,01 – 17,87% para o ultraoligotrófico, 0,02 – 33,17% para o oligotrófico, 1,99 – 40,77% para o mesotrófico, 3,33 – 74,64% para o eutrófico, 4,76 – 35,96% para o supereutrófico e 4,39 – 50,30% para o hipereutrófico; c) em 2018: 0 – 1,72% para o ultraoligotrófico, 0,01 – 3,85% para o oligotrófico, 0,04 – 16,30% para o mesotrófico, 1,01 – 58,97% para o eutrófico, 26,78 – 74,72% para o supereutrófico e 4,04 – 71,79% para o hipereutrófico; e d) em 2019: 0 – 1,49% para o ultraoligotrófico, 0 – 12,03% para o oligotrófico, 0,04 – 24,85% para o mesotrófico, 0,76 – 64,19% para o eutrófico, 29,80 – 74,06% para o supereutrófico e 2,31 – 54,34% para o hipereutrófico.

Figura 4.44 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses dos anos 2016 e 2017 (conjunto 1). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.

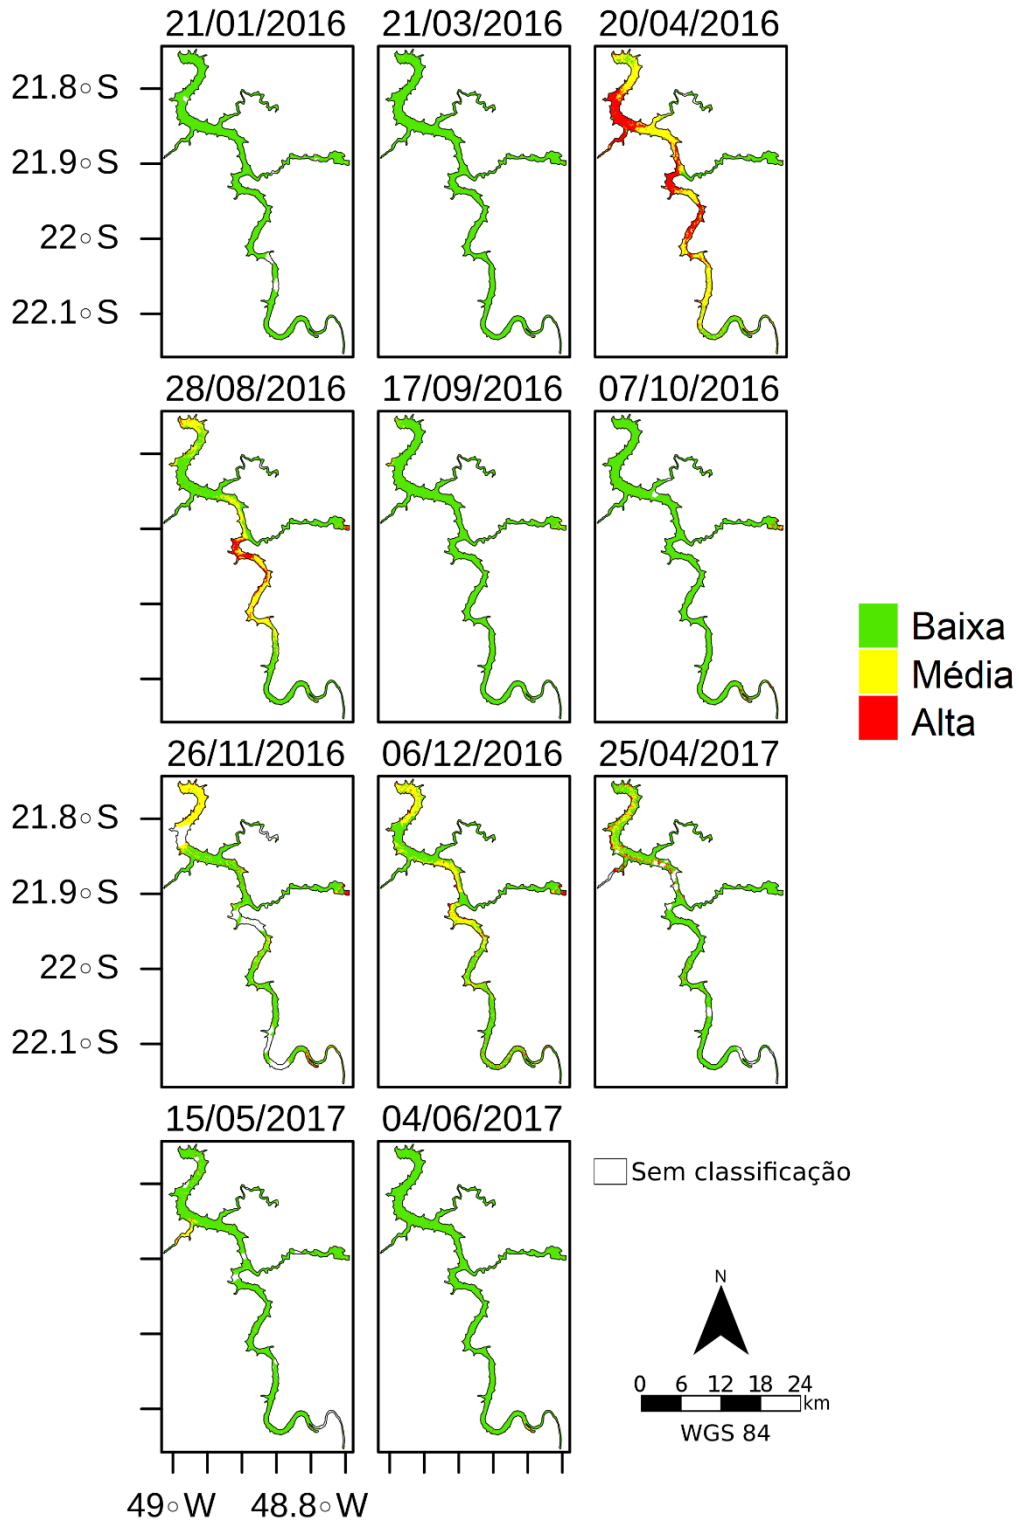


Figura 4.45 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses dos anos 2017 e 2018 (conjunto 2). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.




Figura 4.46 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses do ano 2018 (conjunto 3). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.




Figura 4.47 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses dos anos 2018 e 2019 (conjunto 4). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.




Figura 4.48 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses do ano 2019 (conjunto 5). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.

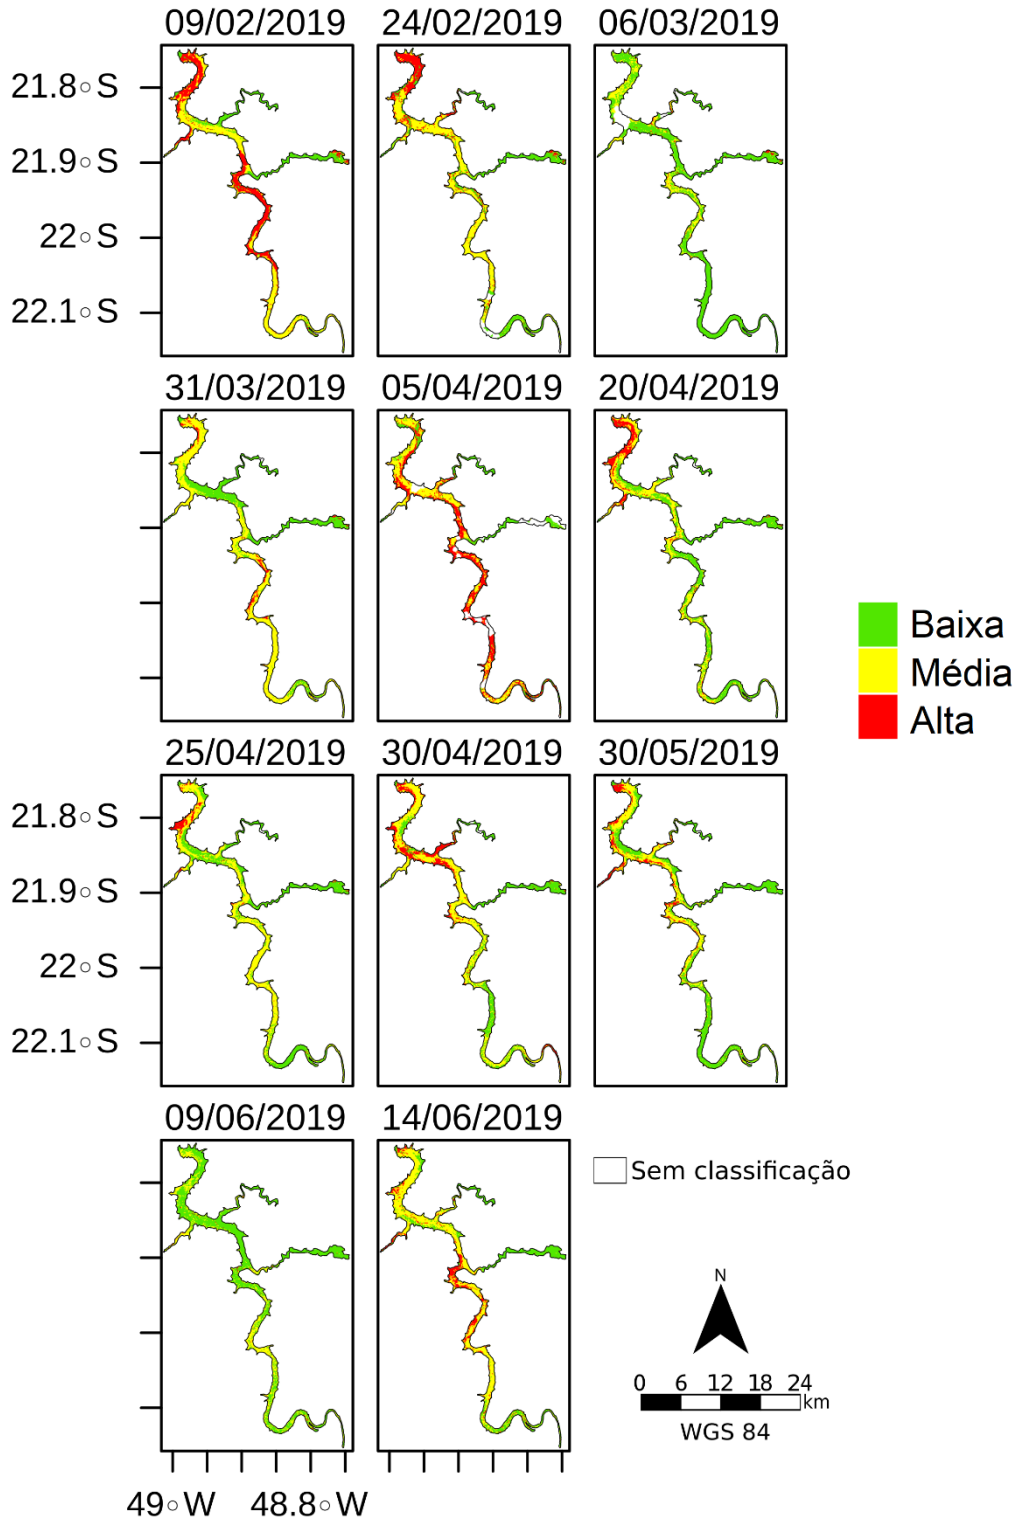


Figura 4.49 – Mapa das classes ópticas gerado a partir do MHO, referente aos meses do ano 2019 (conjunto 6). As cores verde (classe óptica “Classe 1”), amarela (classe óptica “Classe 2”) e vermelha (classe óptica “Classe 3”) indicam a presença de baixa, média e alta intensidade de floração no reservatório, respectivamente.




Figura 4.50 – Mapa de concentração de chl-a gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses dos anos 2016 e 2017 (conjunto 1).

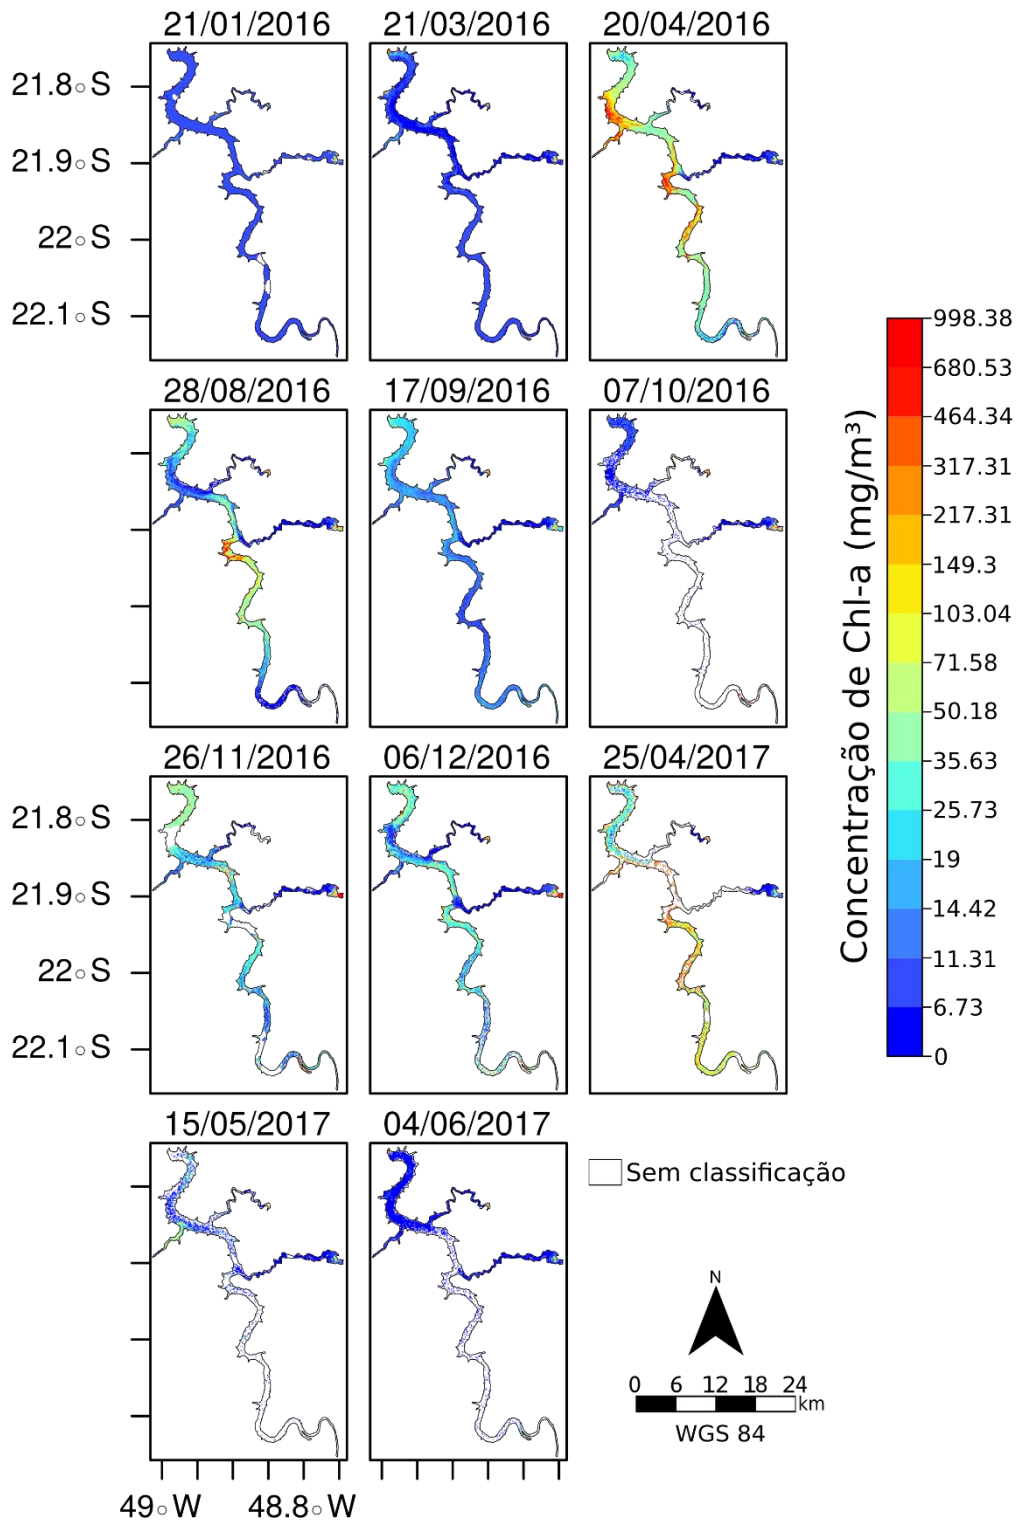


Figura 4.51 – Mapa de concentração de chl-*a* gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses dos anos 2017 e 2018 (conjunto 2).

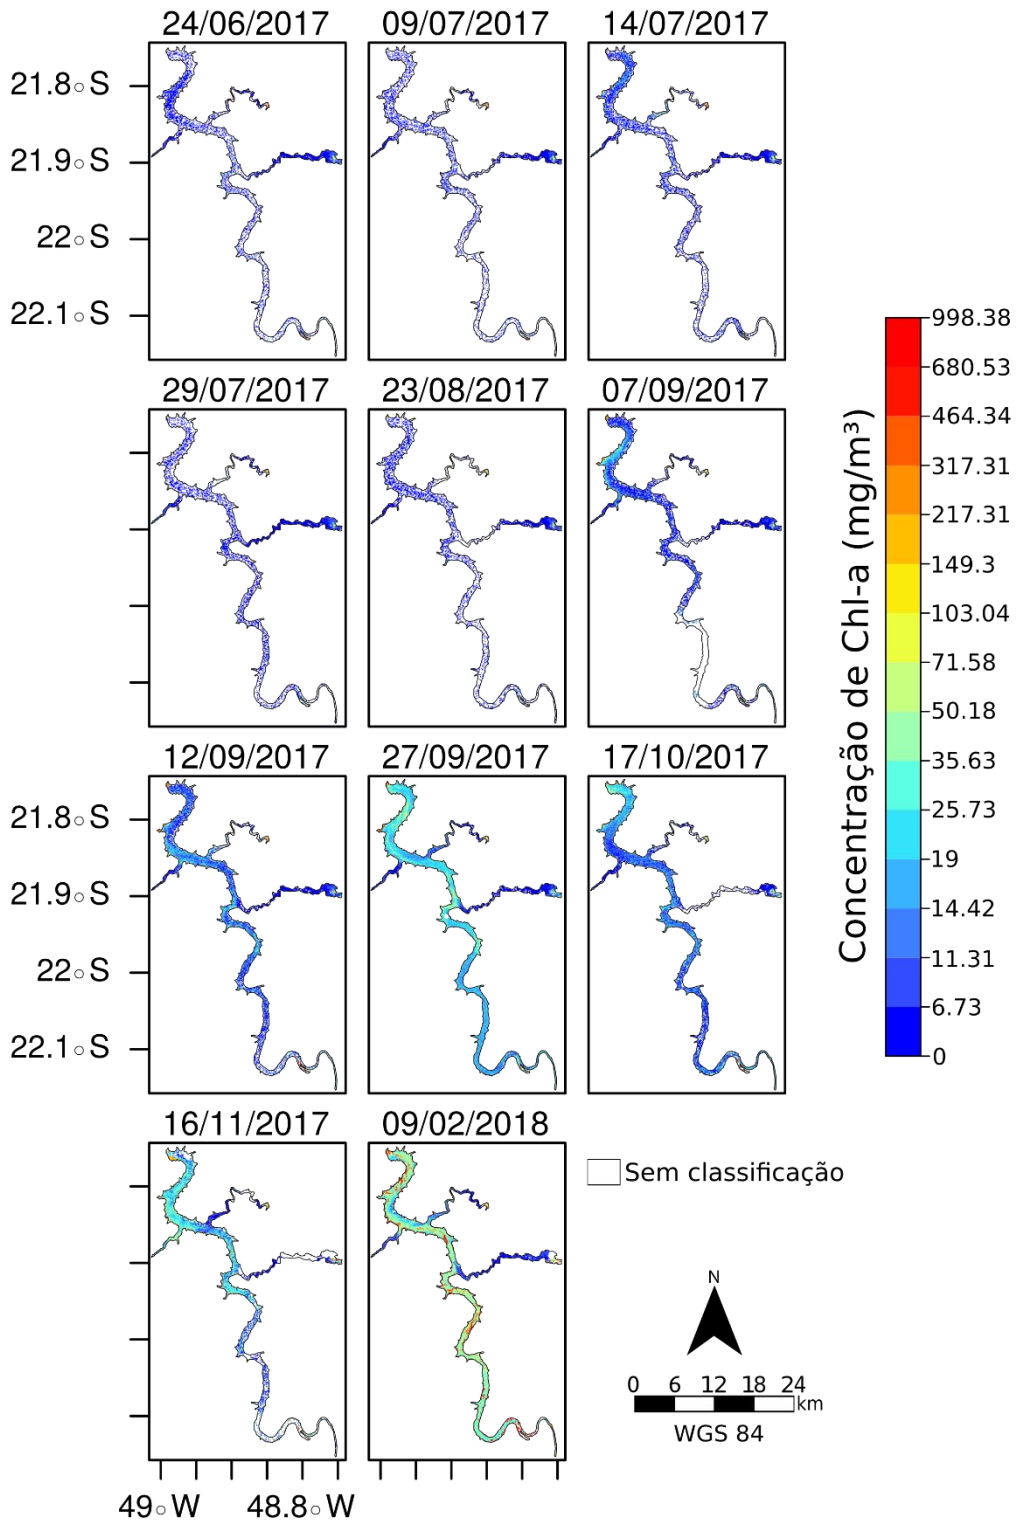


Figura 4.52 – Mapa de concentração de chl-a gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses do ano 2018 (conjunto 3).

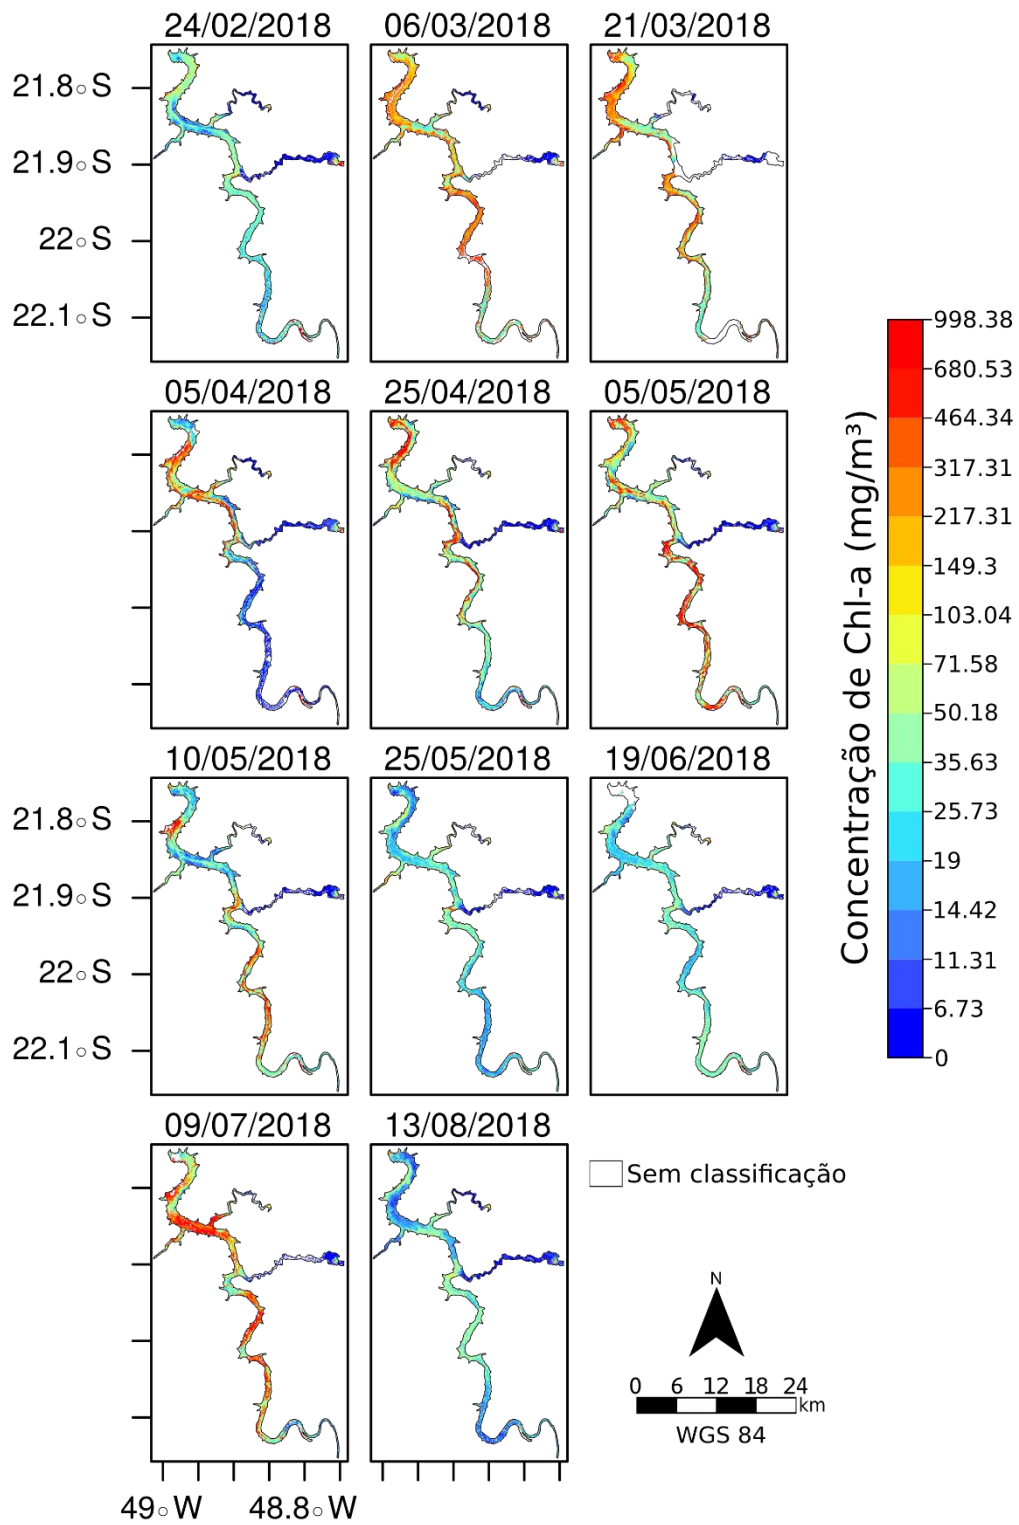


Figura 4.53 – Mapa de concentração de chl-*a* gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses dos anos 2018 e 2019 (conjunto 4).

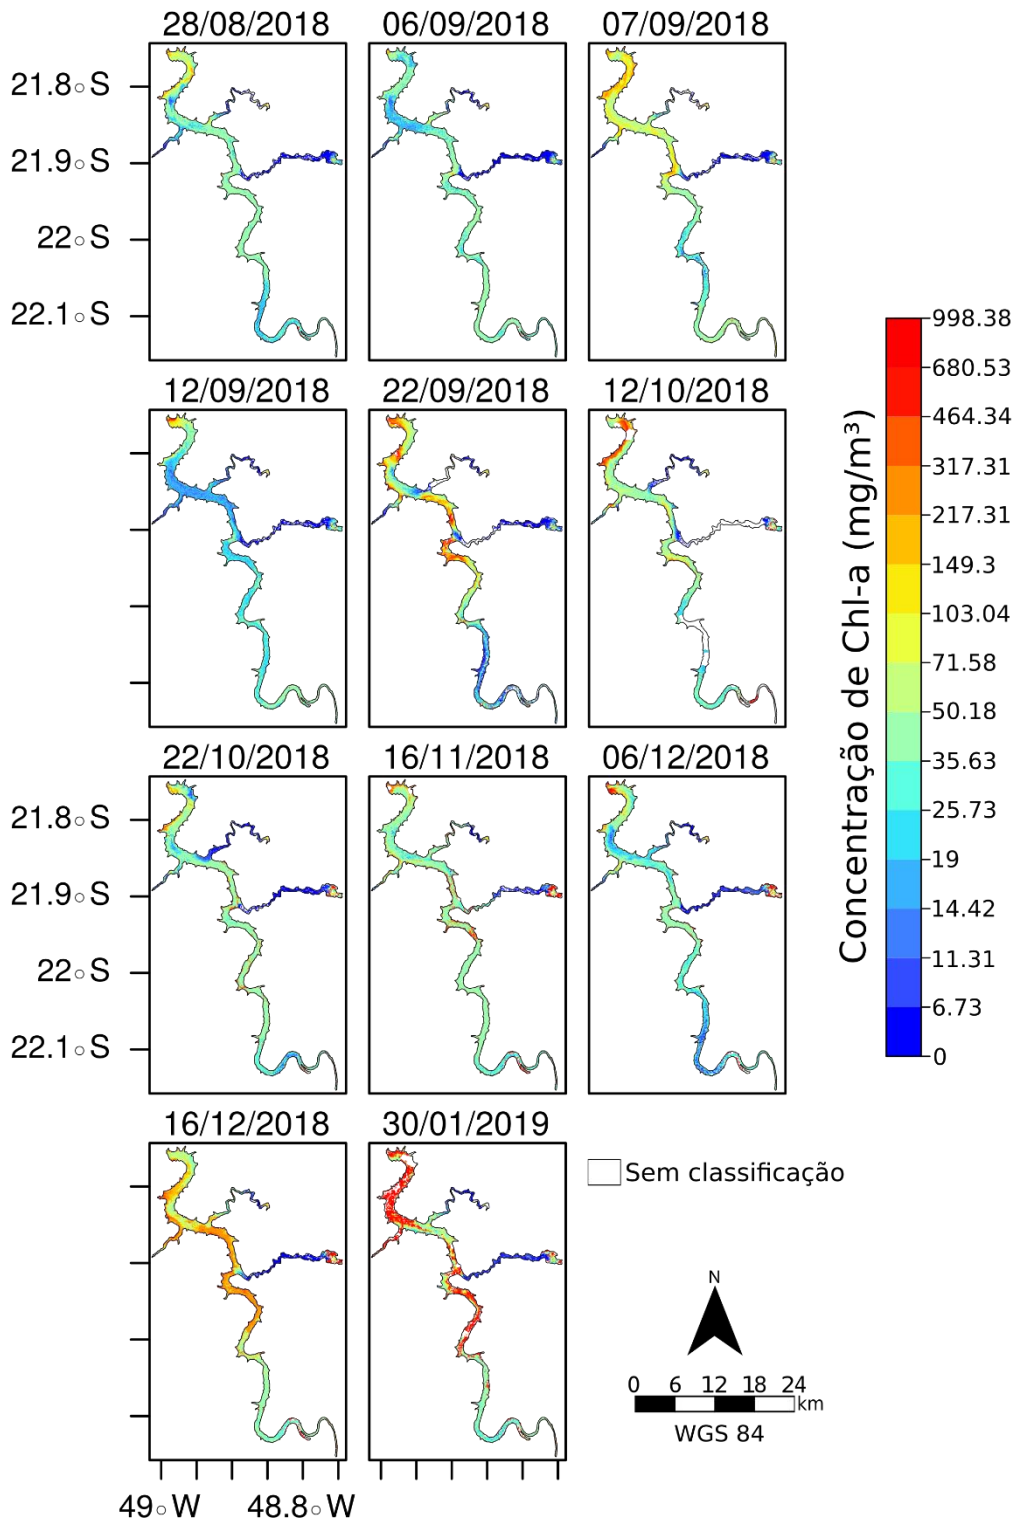


Figura 4.54 – Mapa de concentração de chl-*a* gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses do ano 2019 (conjunto 5).

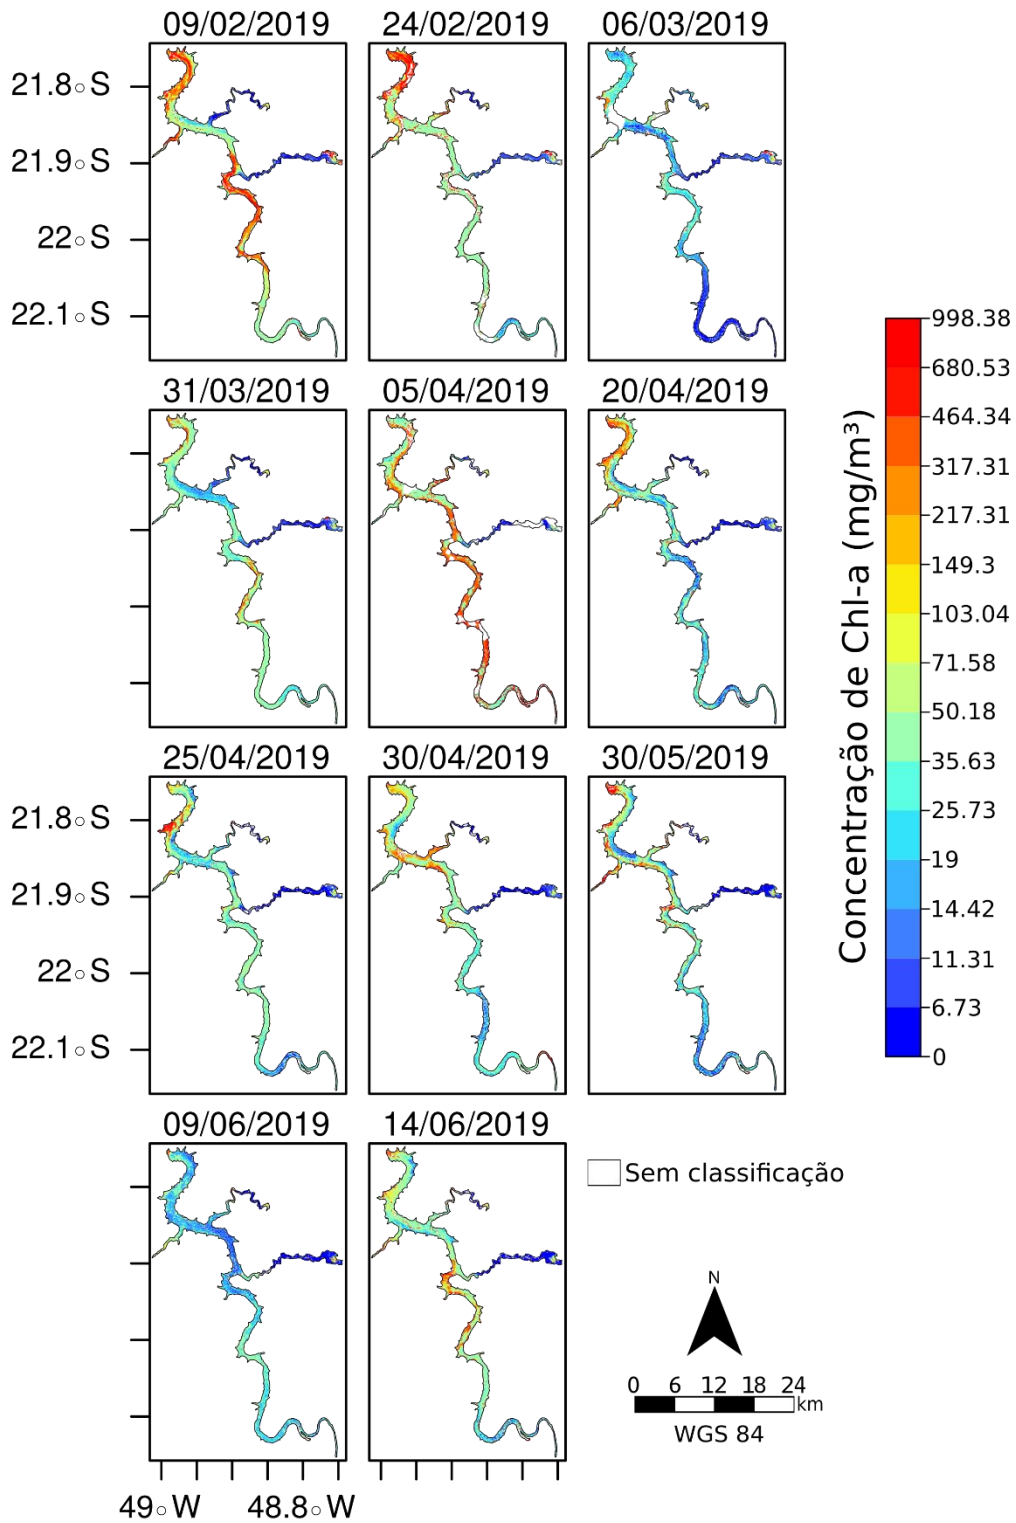


Figura 4.55 – Mapa de concentração de chl-*a* gerado a partir do MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), referente aos meses do ano 2019 (conjunto 6).

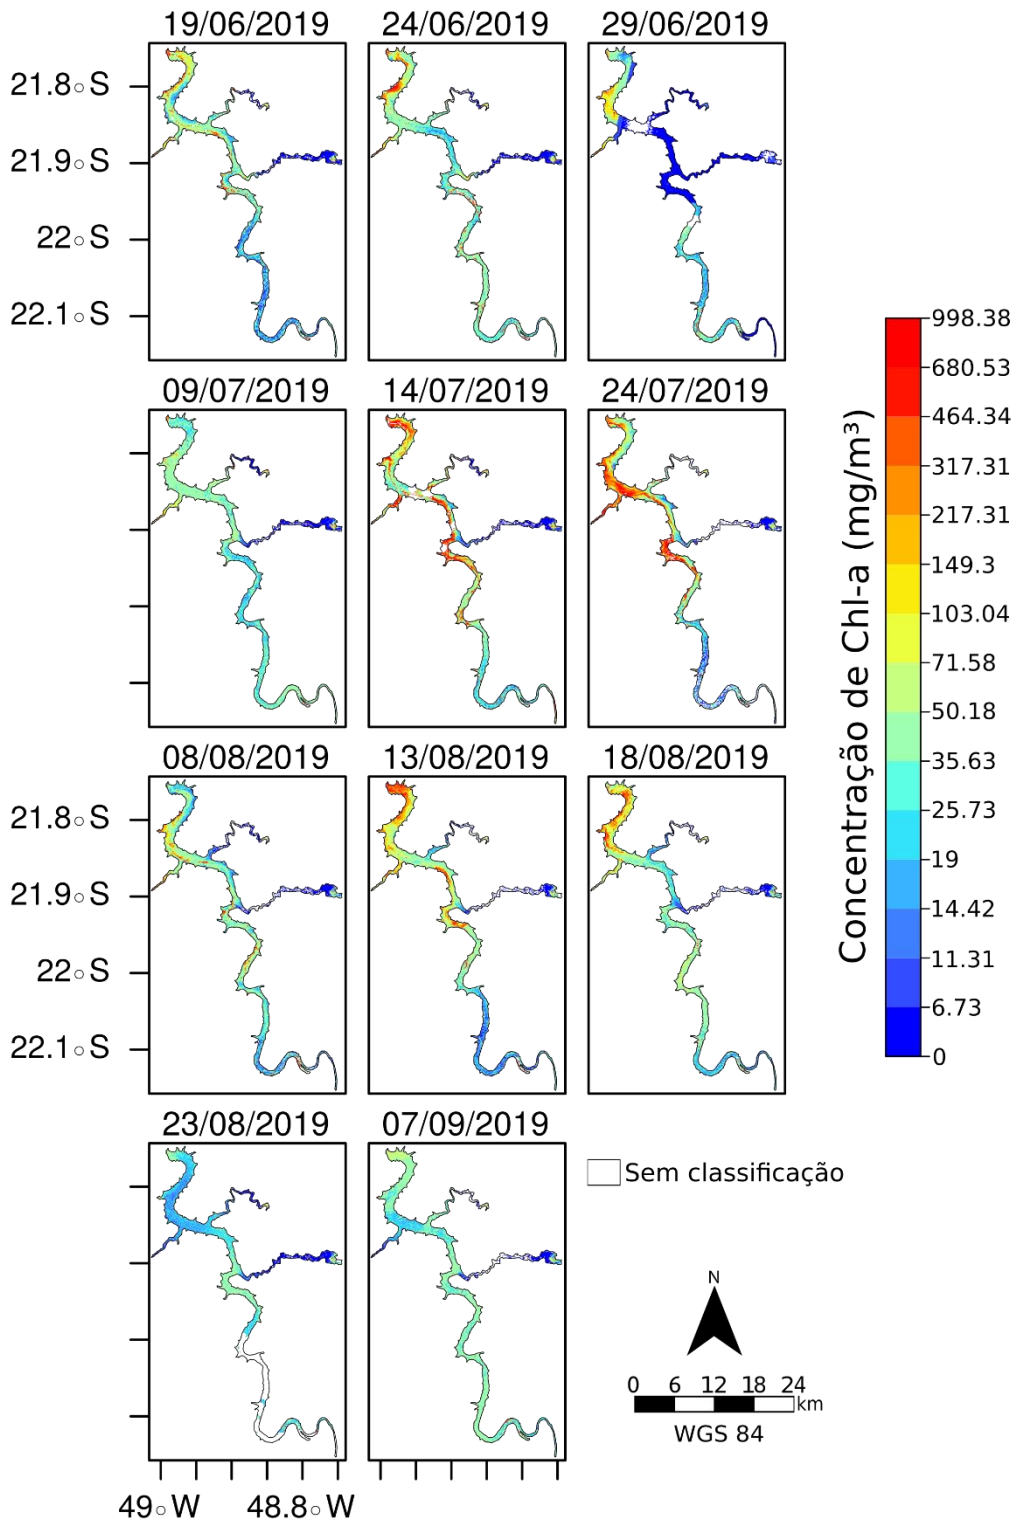


Figura 4.56 – Análise temporal das classes ópticas e da concentração da chl-*a* geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P1A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-*a* e a linha preta pontilhada a tendência de variação média da chl-*a* em P1A ao longo dos anos.




Figura 4.57 – Análise temporal das classes ópticas e da concentração da chl-*a* geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P2A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-*a* e a linha preta pontilhada a tendência de variação média da chl-*a* em P2A ao longo dos anos.




Figura 4.58 – Análise temporal das classes ópticas e da concentração da chl-*a* geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P3A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-*a* e a linha preta pontilhada a tendência de variação média da chl-*a* em P3A ao longo dos anos.




Figura 4.59 – Análise temporal das classes ópticas e da concentração da chl-*a* geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P4A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-*a* e a linha preta pontilhada a tendência de variação média da chl-*a* em P4A ao longo dos anos.




Figura 4.60 – Análise temporal das classes ópticas e da concentração da chl-*a* geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P5A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-*a* e a linha preta pontilhada a tendência de variação média da chl-*a* em P5A ao longo dos anos.




Figura 4.61 – Análise temporal das classes ópticas e da concentração da chl-*a* geradas pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3) referente à estação amostral P6A da Figura 3.12. Os pontos pretos pequenos mostram o valor médio mensal de chl-*a* e a linha preta pontilhada a tendência de variação média da chl-*a* em P6A ao longo dos anos.

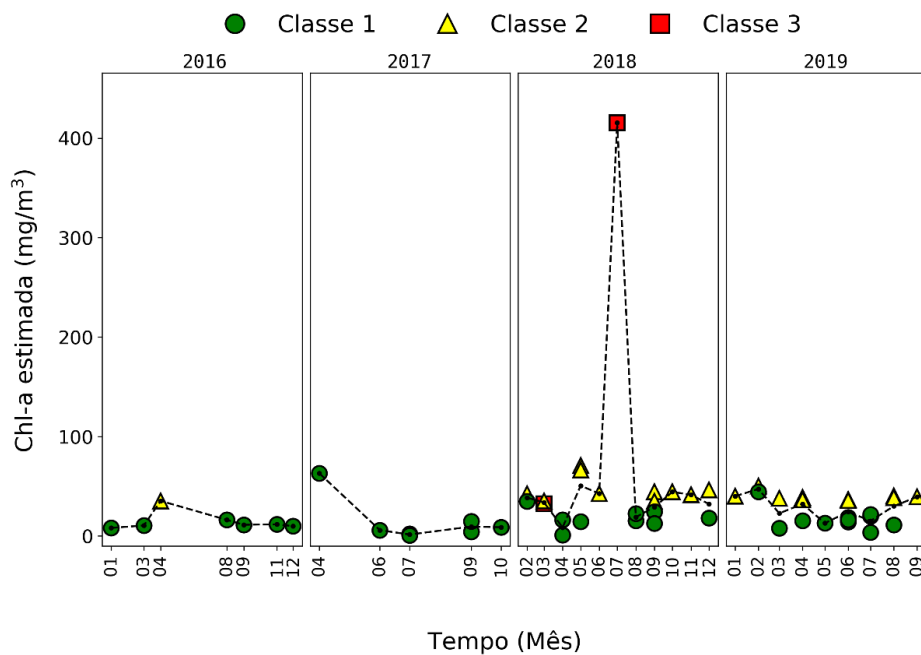


Figura 4.62 – Análise temporal do valor mínimo, máximo e médio da concentração de chl-*a* estimada pelo MHO_ate1000 (classe 3 usando o algoritmo da classe óptica “Classe3_1000” – Tabela 4.3), para todo o reservatório de Ibitinga. Esses valores abrangem uma representatividade de 96% dos dados de chl-*a* estimada, pois os *outliers* foram excluídos desconsiderando os percentis dos 2% iniciais e finais do conjunto de dados.




Figura 4.63 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.50), referente aos meses dos anos 2016 e 2017 (conjunto 1).

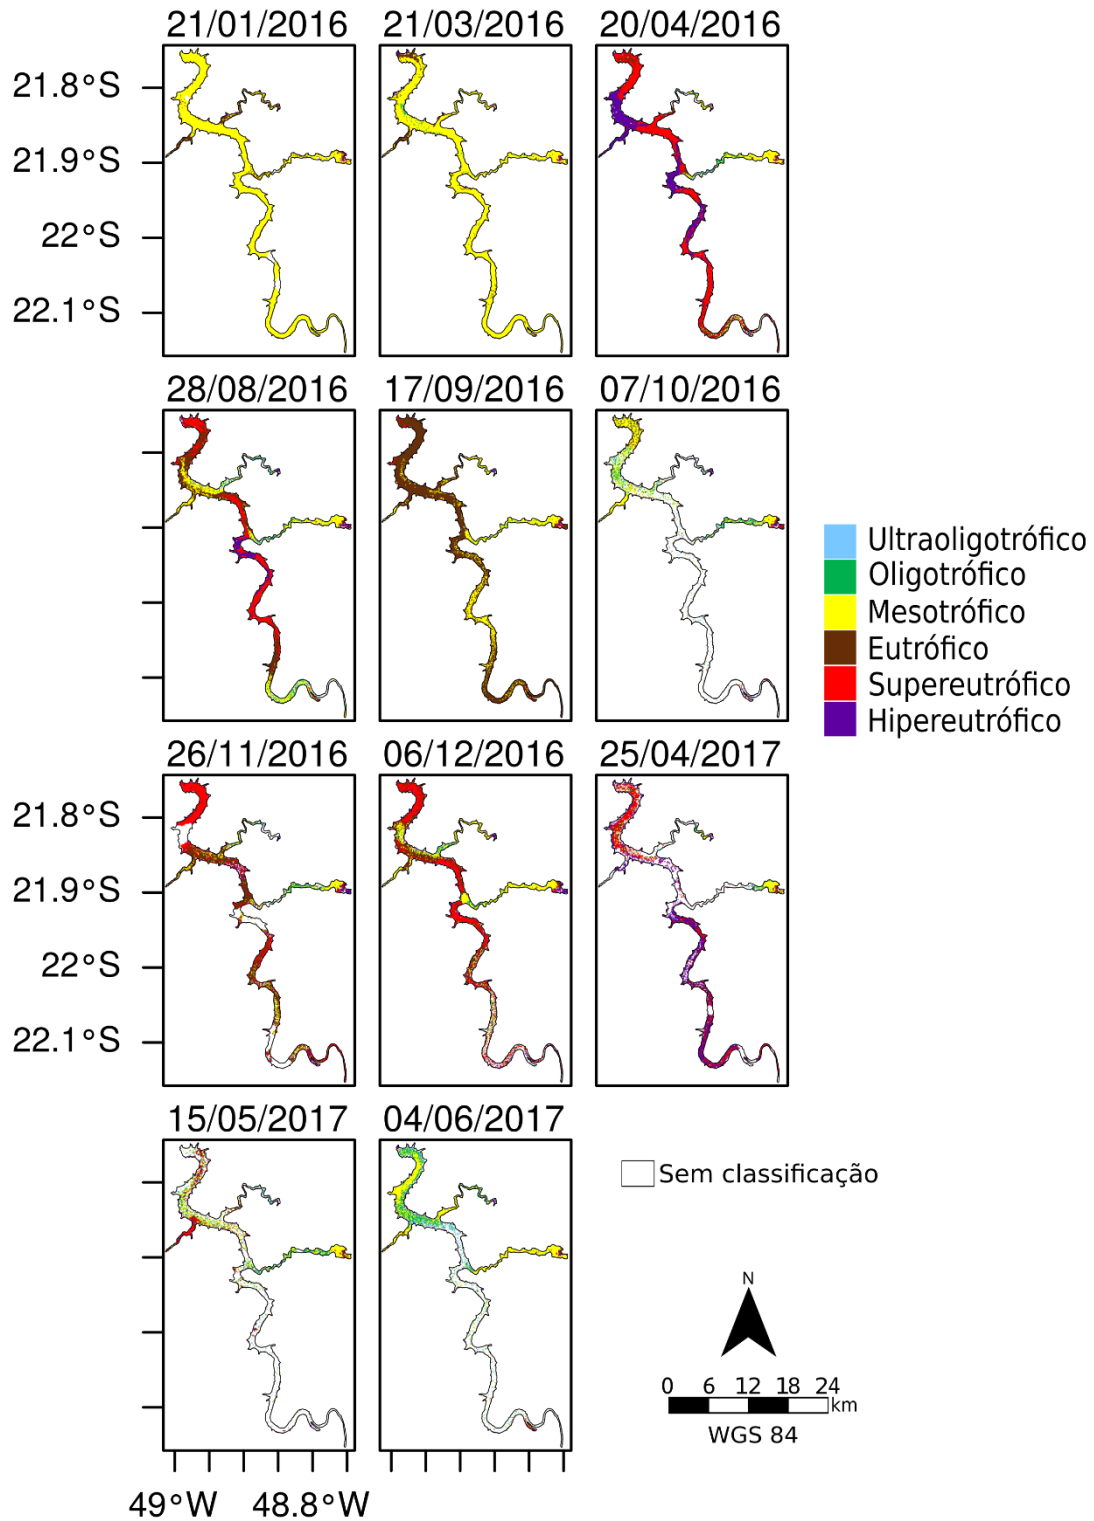


Figura 4.64 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.51), referente aos meses dos anos 2017 e 2018 (conjunto 2).

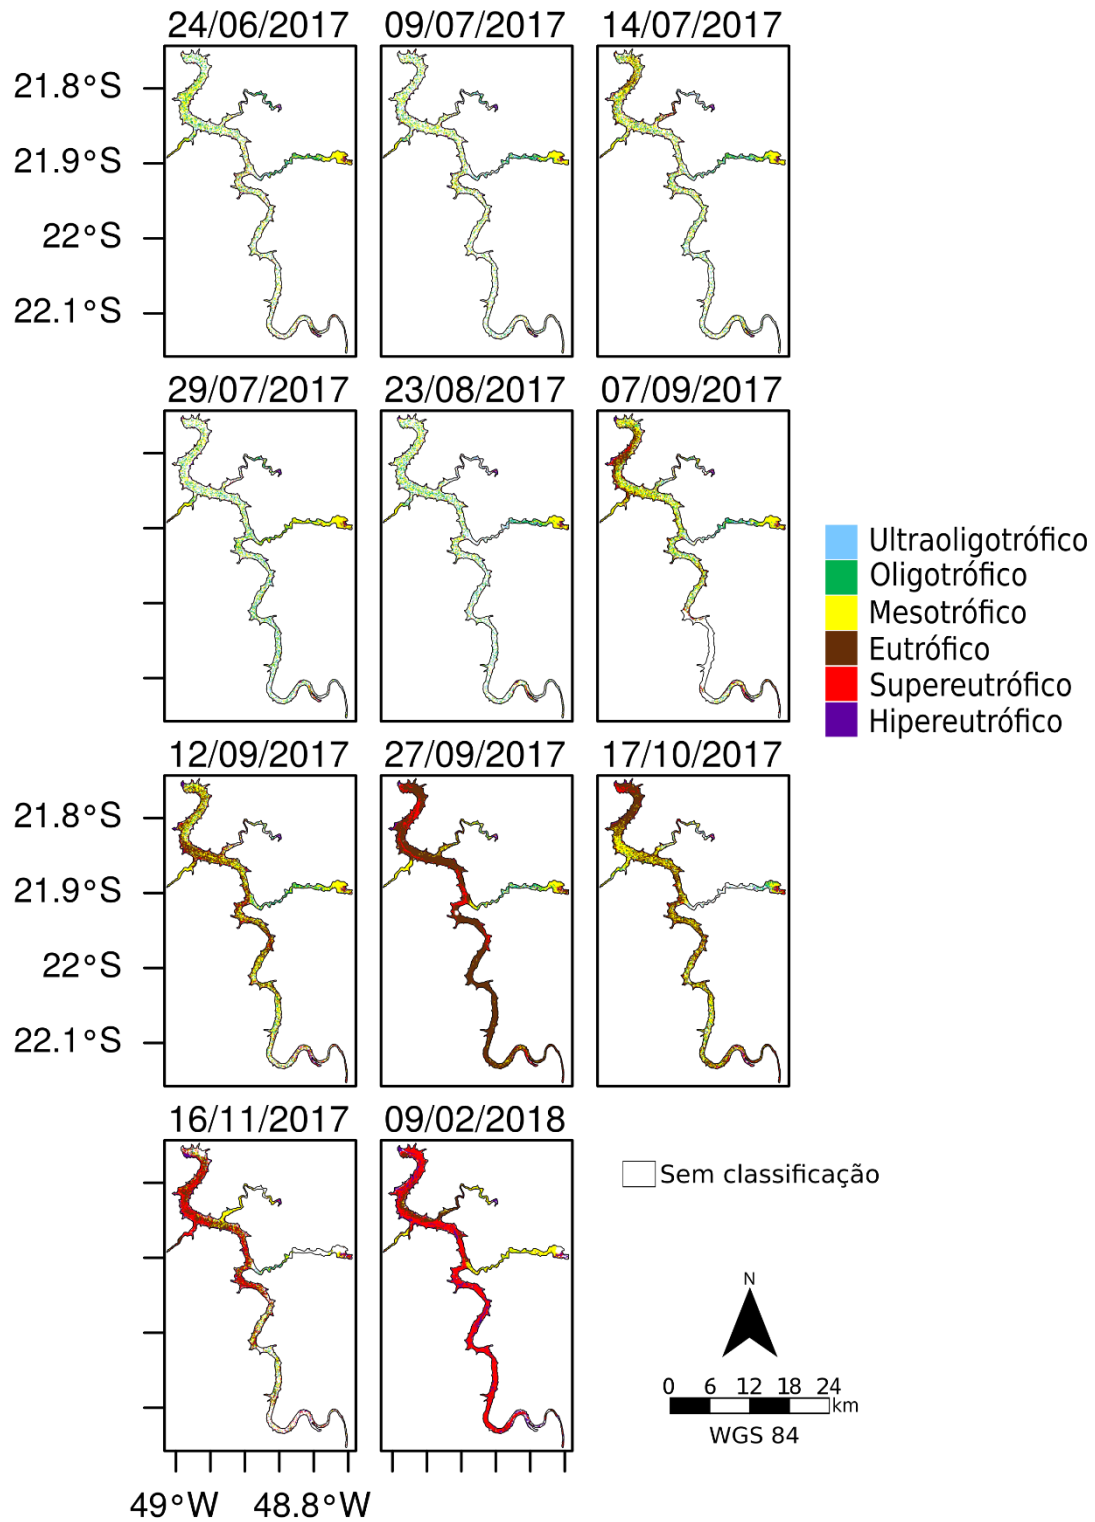


Figura 4.65 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.52), referente aos meses do ano 2018 (conjunto 3).

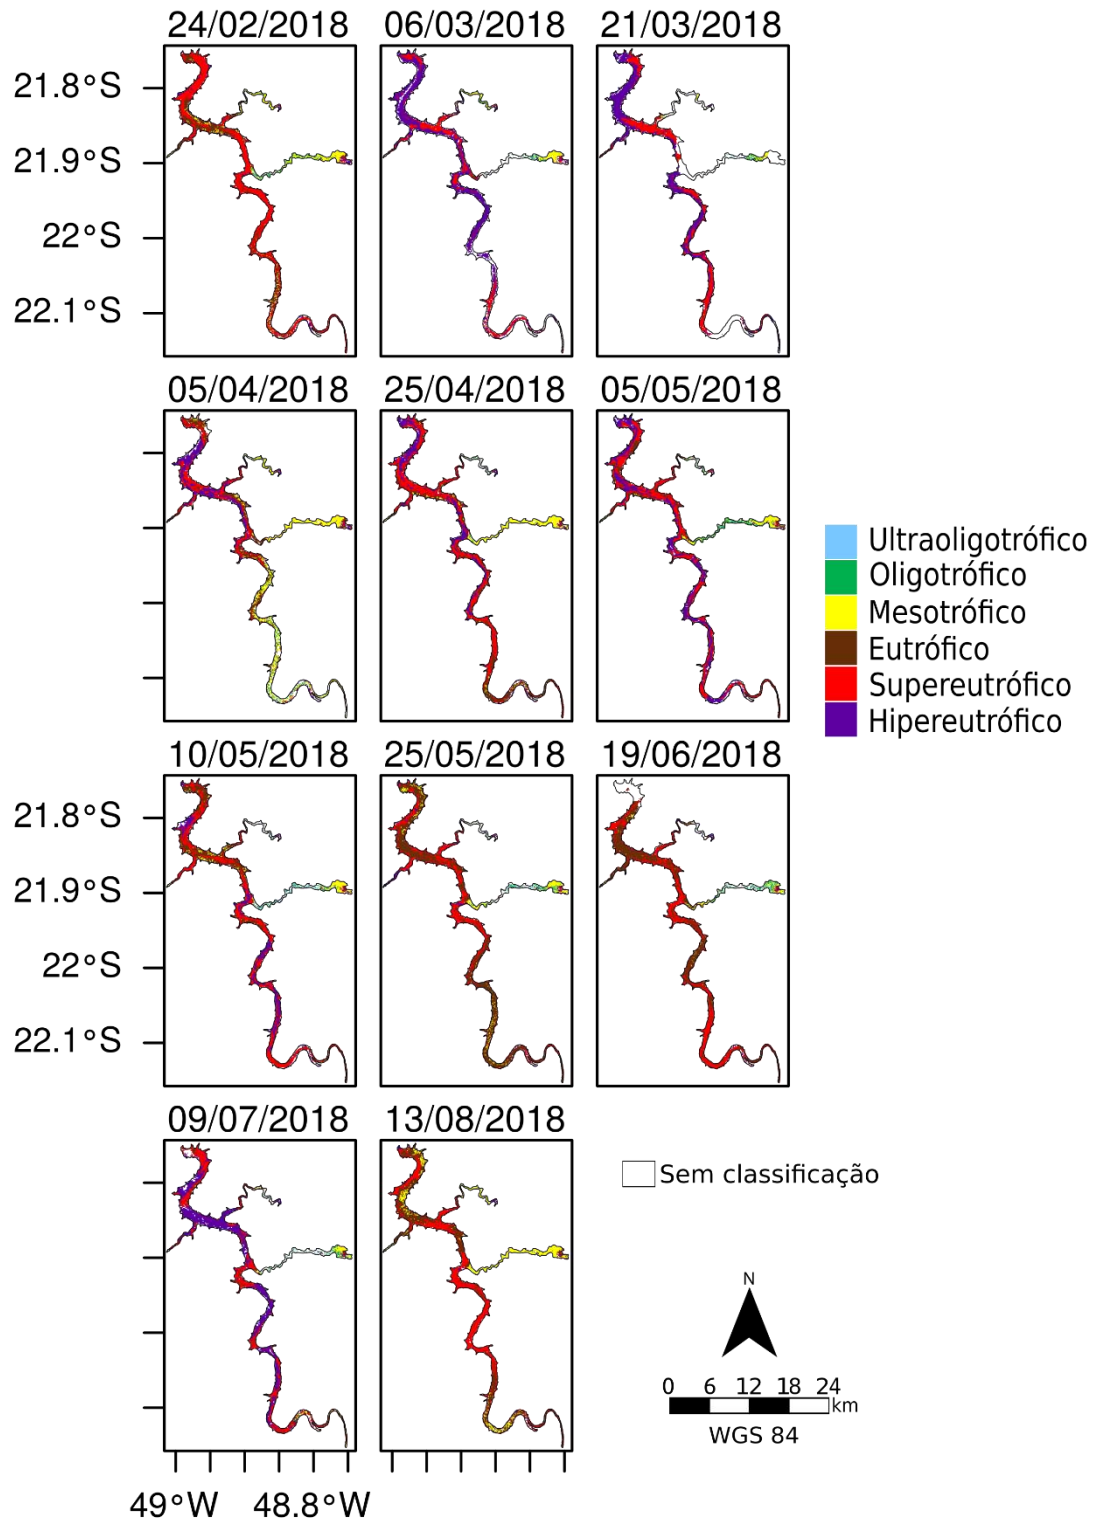


Figura 4.66 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.53), referente aos meses dos anos 2018 e 2019 (conjunto 4).

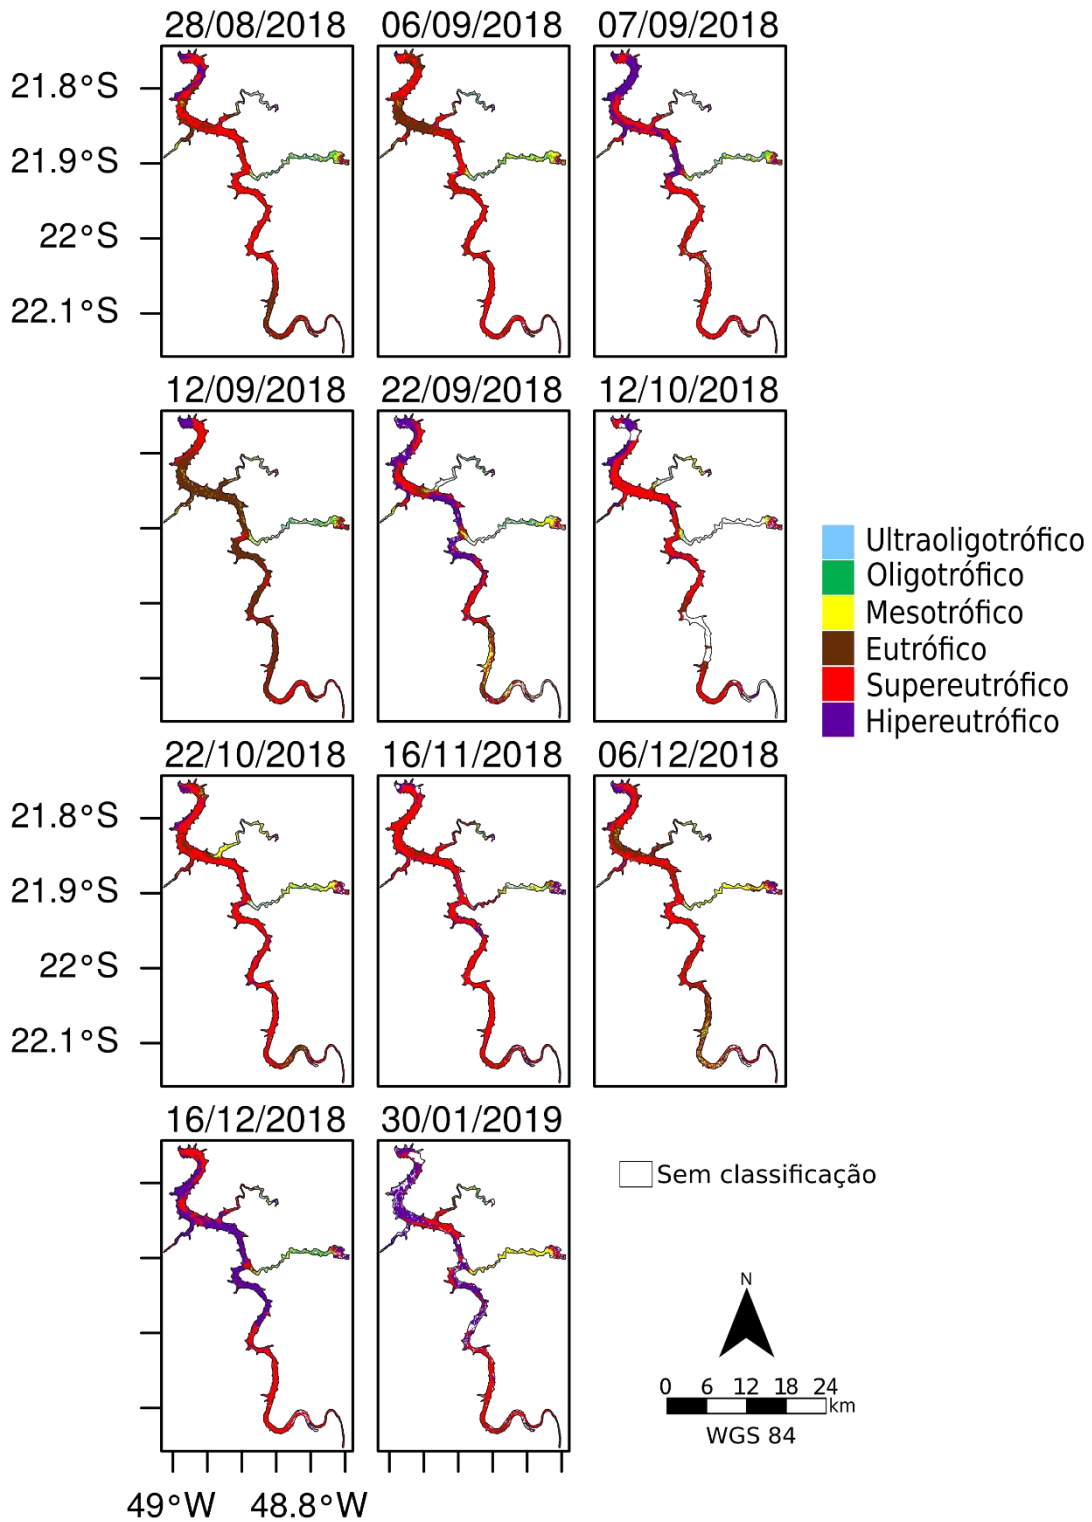


Figura 4.67 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.54), referente aos meses do ano 2019 (conjunto 5).

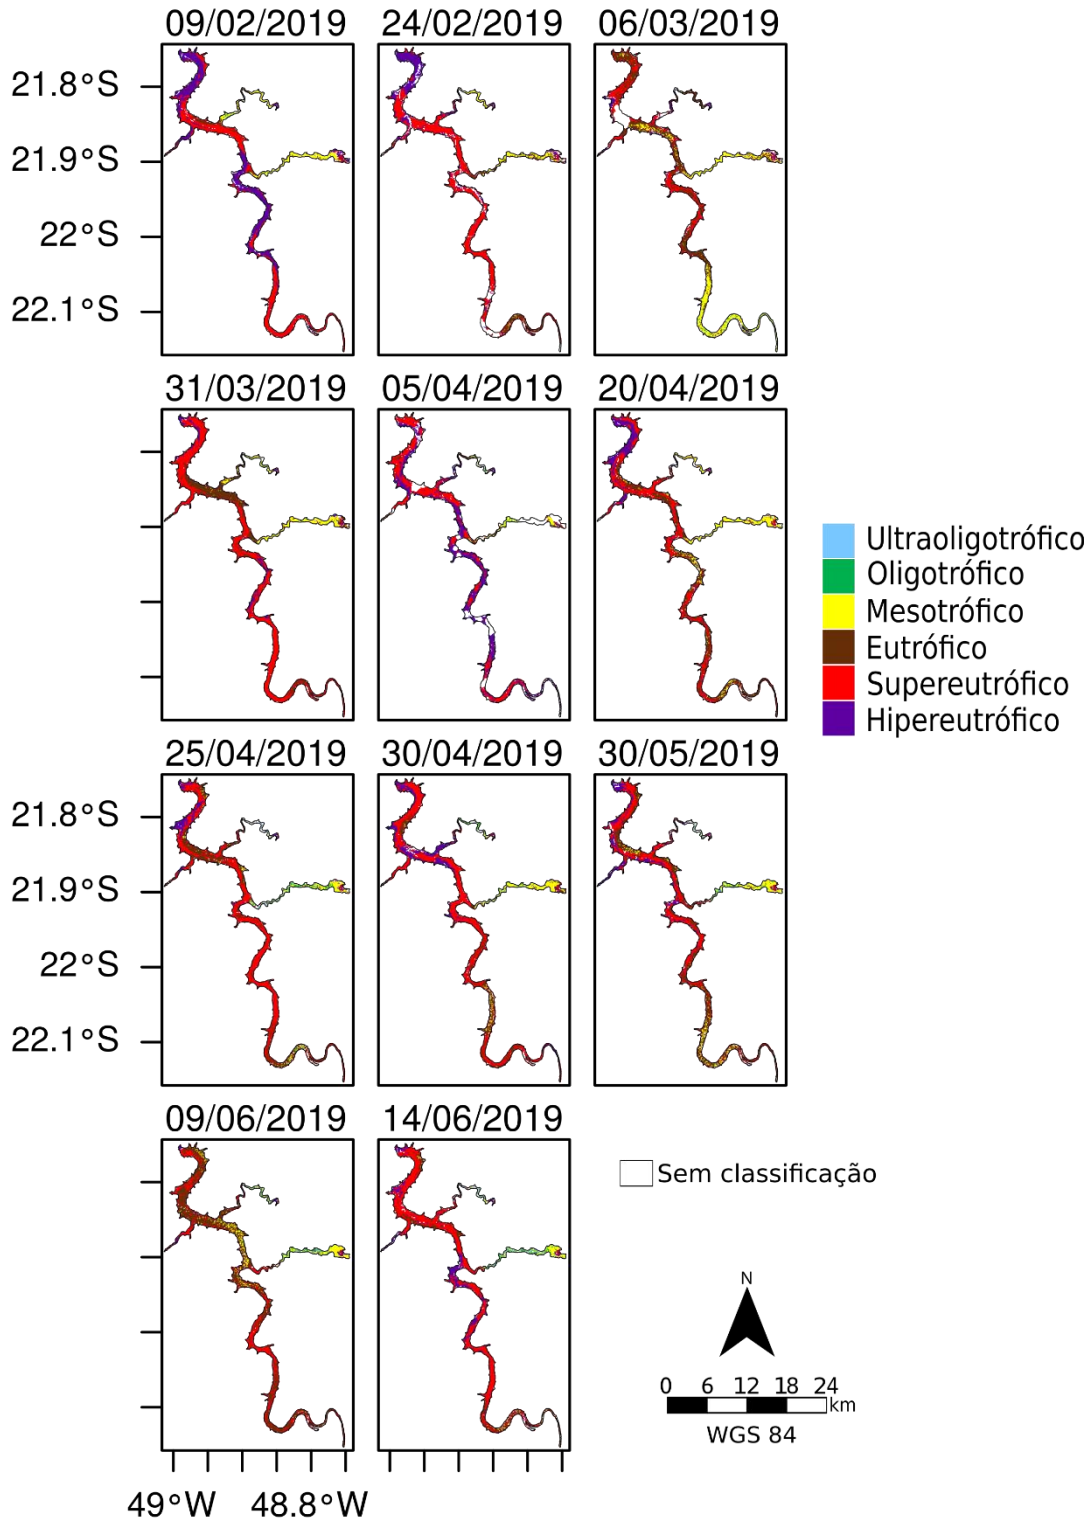
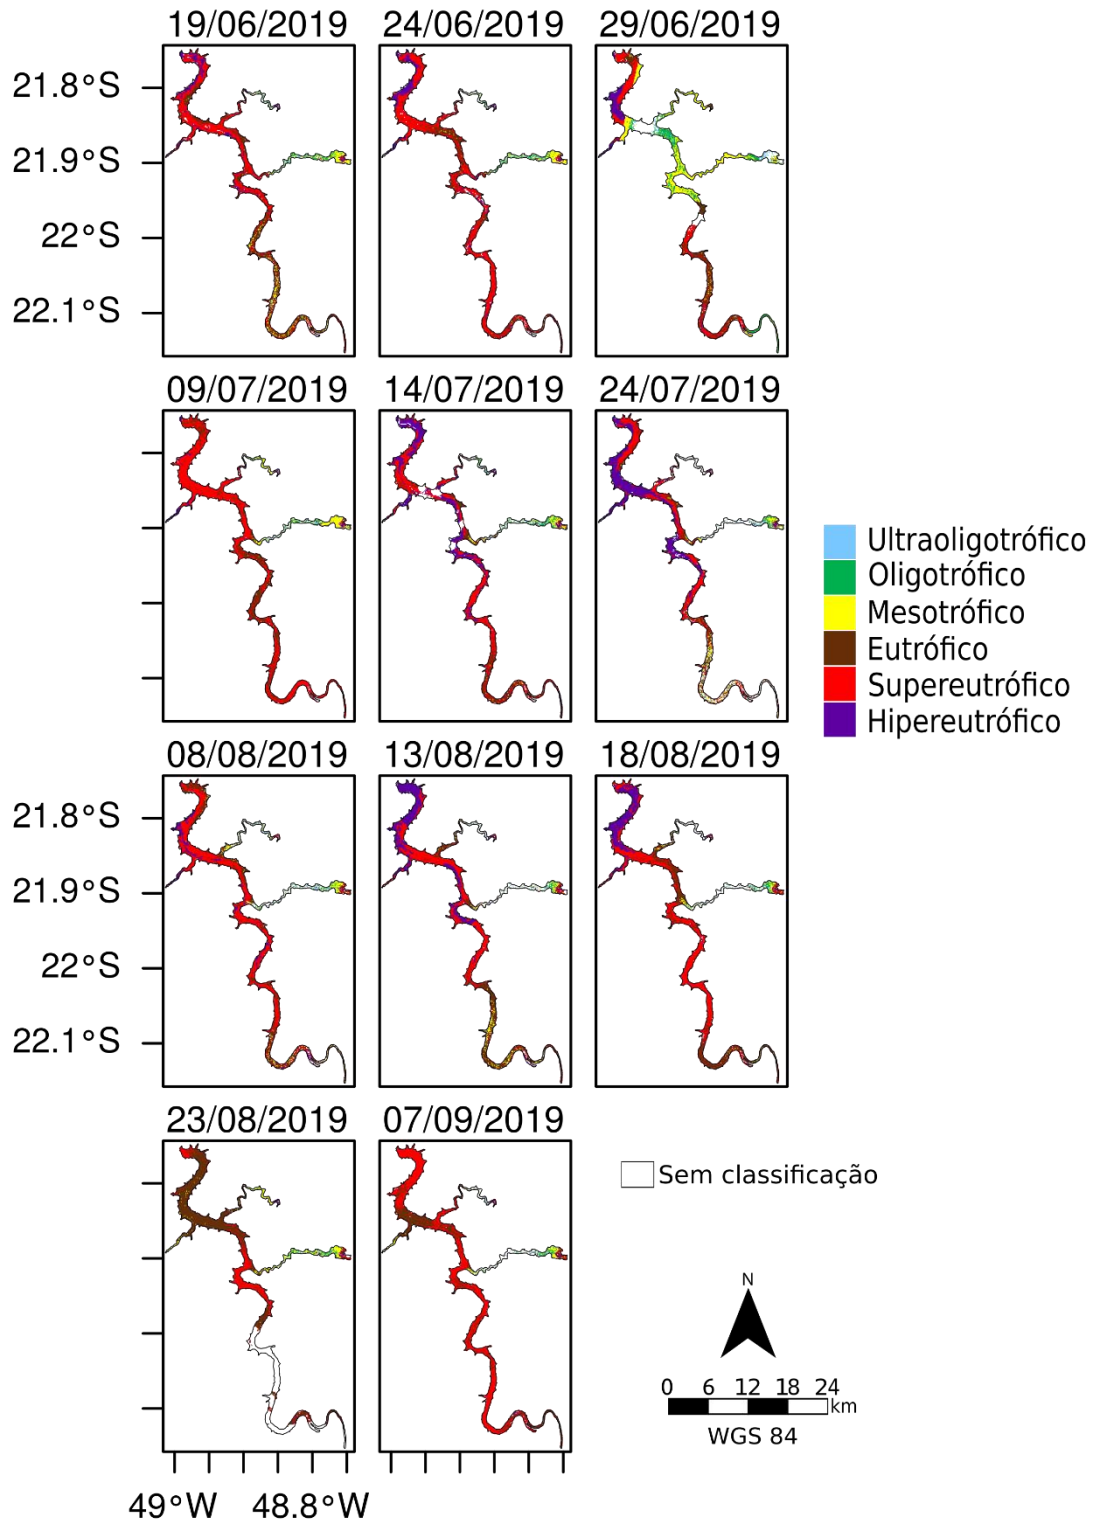


Figura 4.68 – Mapa dos estados tróficos da CETESB (Tabela 2.4) gerado pelo fatiamento do mapa de chl-*a* (Figura 4.55), referente aos meses do ano 2019 (conjunto 6).

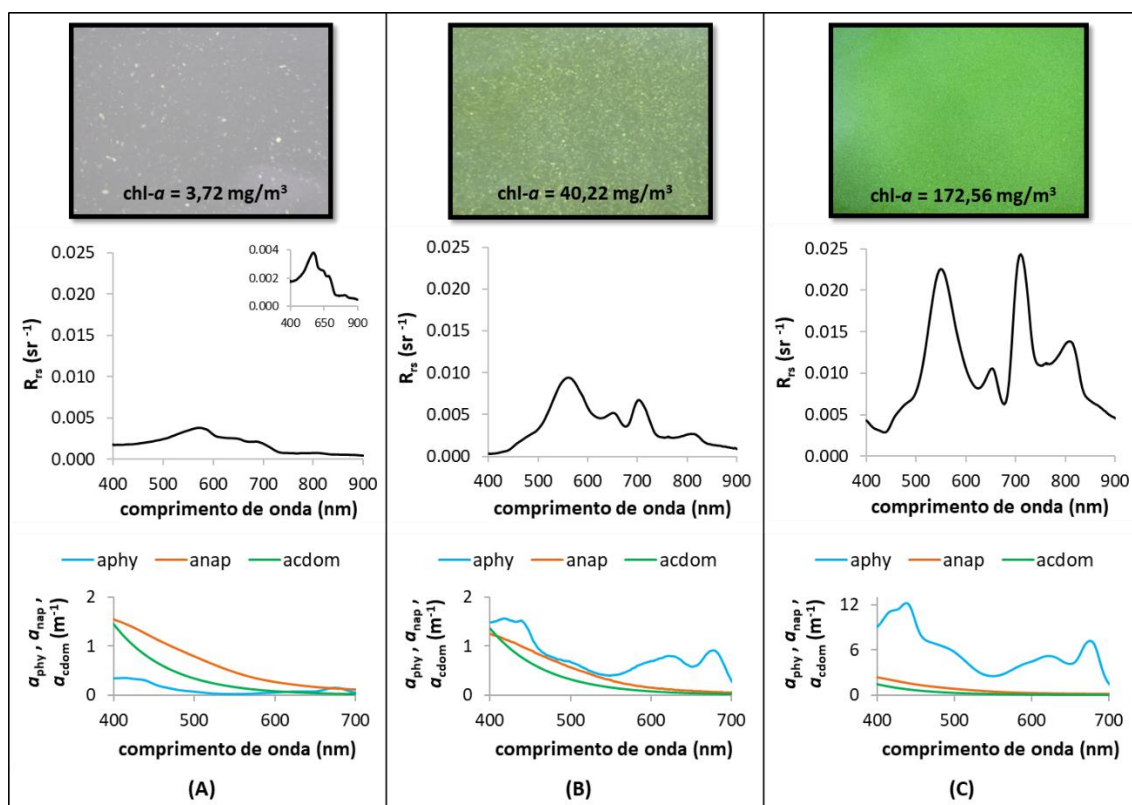


5 DISCUSSÃO DOS RESULTADOS

5.1 Propriedades ópticas das classes ópticas

A diferença entre as três classes ópticas geradas a partir da aplicação dos métodos limnológico e óptico no conjunto de dados pode ser analisada na Figura 5.1. Essa figura mostra três exemplos de espectros de R_{rs} , coeficiente de absorção do fitoplâncton (a_{phy}), coeficiente de absorção do NAP (a_{nap}) e coeficiente de absorção do CDOM (a_{cdom}) de estações amostrais em comum presentes nas classes ópticas de faixas específicas de concentração da chl-*a* de ambos métodos (Tabela 4.1) e suas respectivas cores da água no momento da coleta de campo. Vale ressaltar que a metodologia de aquisição e processamento de a_{phy} , a_{nap} e a_{cdom} pode ser encontrada com detalhe em Cairo (2015).

Figura 5.1 - Análise da mudança da cor da água, do comportamento espectral da R_{rs} e da variação espectral do a_{phy} , a_{nap} e a_{cdom} para as três classes ópticas geradas usando os métodos limnológicos e óptico: (A) Estação P1 de maio/2014, presente nas classes ópticas “OligoMeso” e “Classe 1”; (B) Estação P1 de julho/2014, presente nas classes ópticas “EutroSuper” e “Classe 2”; e (C) Estação P1 de fevereiro/2014, presente nas classes ópticas “Hiper” e “Classe 3”. Obs1: no canto direito de (A) é a R_{rs} com uma escala ampliada, para enfatizar a forma do espectro em relação à (B) e (C). Obs2: em (C) a escala da absorção está diferente de (A) e (B).



É possível verificar que nas três classes ópticas as propriedades espectrais da R_{rs} são bem diferentes, sendo as regiões do vermelho e NIR as mais sujeitas a alterações na intensidade de reflectância com o aumento da concentração da chl-*a*. Essa mudança é explicada pelo aumento da absorção pela chl-*a* em torno de 676 nm e aumento do espalhamento pelas células fitoplanctônicas em torno de 709 nm e 810 nm. À medida que a densidade das células da floração aumenta, a reflectância em toda a região do infravermelho aumenta até formar um platô, tendo assim a R_{rs} da água dominada pelo fitoplâncton acumulado em superfície um comportamento espectral semelhante ao da vegetação. Essas condições são explicadas pela formação de um tapete espesso sobrenadante de fitoplâncton, que dificulta ou impede a interação entre a água e a radiação eletromagnética incidente.

Analisando os espectros de a_{phy} , a_{nap} e a_{cdom} , percebe-se que em condições de baixa intensidade de floração (Figura 5.1A), na região do vermelho (acima de 600 nm), o a_{cdom} (λ) tem menor influência na absorção total que o a_{phy} (λ), enquanto que o a_{nap} (λ) tem maior influência na absorção total que o a_{phy} (λ). Assim, a absorção pelo NAP pode mascarar a feição de absorção pela chl-*a* (~675 nm) nessa condição de floração, podendo afetar o desempenho do algoritmo selecionado para estimar a concentração da chl-*a* nas faixas de chl-*a* das classes ópticas “OligoMeso” ($chl-a \leq 11,03 \text{ mg/m}^3$) e “Classe 1” ($2,89 \leq chl-a \leq 22,83 \text{ mg/m}^3$).

Tal situação pode ser visualizada na Tabela 4.3, em que o desempenho do algoritmo de três bandas (665, 705, 740 nm) de Gitelson et al. (2011a) para a faixa de chl-*a* da “Classe 1” no MHO foi inferior (MAPE = 34,36%) aos selecionados para as outras faixas de concentração (MAPE < 24%). Com relação ao MHL, esse mesmo tipo de algoritmo foi selecionado como o de melhor desempenho para a faixa de chl-*a* da classe “OligoMeso”, mas obteve-se um desempenho melhor (Tabela 4.3). Isso porque essa faixa de concentração de chl-*a* (mais estreita que a da “Classe 1” do SAM) contém espectros de R_{rs} mais representativos de maior influência da absorção pelo NAP e CDOM. Assim, o modelo de três bandas pode ter minimizado com mais eficiência os efeitos desses COAs nos espectros, ressaltando melhor a feição de absorção pela chl-*a*, e consequentemente, tendo uma melhor estimativa da chl-*a* em relação à faixa da “Classe 1” do SAM.

É importante destacar também que com o aumento da concentração da chl-*a* (piores níveis de eutrofização) a influência espectral do a_{cdom} e a_{nap} é reduzida em relação ao a_{phy} (Figuras 5.1B e 5.1C), principalmente na região do vermelho e infravermelho. Isso mostra que quando o reservatório de Ibitinga apresenta condições de média à elevada intensidade de floração, o fitoplâncton é o componente óptico dominante. Assim, isso pode ser um fator que contribuiu para um melhor desempenho dos algoritmos selecionados para as faixas de chl-*a* das classes 2 e 3 do método óptico e para as faixas das classes “EutroSuper” e “Hiper” do método limnológico (Tabela 4.3).

Além disso, pela Figura 5.1, é possível observar também que à medida que a concentração da chl-*a* aumenta, a absorção em torno de 440 nm no espectro de R_{rs} se torna mais evidente, sobrepujando o efeito do a_{cdom} e a_{nap} e assim impedindo-os de mascarar a feição de absorção pela chl-*a* no espectro. a_{cdom} e a_{nap} possuem maior influência na região do azul/verde em condições oligotróficas/mesotróficas ou em condições de maior precipitação na bacia do rio Jacaré-Pepira, que é uma APA e toda a matéria orgânica acumulada é lixiviada para o rio, que deságua no reservatório.

Vale ressaltar que as diferenças no comportamento espectral da água nas classes ópticas são ressaltadas pelas nítidas diferenças na cor da água, indicando a presença de águas com pouca, média e elevada intensidade de floração nas classes ópticas exemplificadas em A, B e C na Figura 5.1, respectivamente. Essa figura também destaca que a cor da água muda para uma mesma estação amostral (estação próxima à barragem – P1) ao longo do tempo. Toda essa diversidade de propriedades ópticas da água mostrada em cada classe óptica para o reservatório de Ibitinga endossa a necessidade de uma abordagem híbrida para descrever toda essa variabilidade espectral e, assim, fornecer boas estimativas da concentração da chl-*a*.

5.2 Avaliação da divisão das faixas específicas de concentração da chl-*a*

A delimitação das faixas específicas de concentração da chl-*a* no presente estudo (seção 3.3; Tabela 4.1) foi baseada em um critério mais robusto em comparação com os modelos híbridos propostos por Matsushita et al. (2015) e Smith et al. (2018). Esses autores estabeleceram os intervalos de concentração empiricamente ($chl-a \leq 10 \text{ mg/m}^3$, $10 < chl-$

$a \leq 25 \text{ mg/m}^3$ e $\text{chl-}a > 25 \text{ mg/m}^3$), alegando que esses valores de concentração foram relatados por estudos anteriores como limiares decisivos para o funcionamento de vários algoritmos. Assim, os autores usaram intervalos de $\text{chl-}a$ definidos para outros fins que não os de dar suporte a um modelo híbrido. Além disso, não foi levado em consideração se as faixas de concentração de $\text{chl-}a$ estabelecidas empiricamente conseguem abranger as características ópticas de cada condição trófica do sistema aquático estudado, uma informação fundamental para a precisão dos algoritmos bio-ópticos em cada faixa específica de concentração de $\text{chl-}a$.

Por outro lado, o presente estudo utilizou dois métodos para delimitar as faixas específicas de concentração da $\text{chl-}a$, no caso o limnológico e o óptico, dividindo o conjunto de dados em três classes ópticas de faixas específicas de concentração da $\text{chl-}a$. Isso proporcionou o desenvolvimento de modelos híbridos que permitem o mapeamento de classes ópticas a partir de uma perspectiva limnológica e óptica, em que para cada faixa específica de concentração da $\text{chl-}a$ há um distinto conjunto espectral de R_{rs} vinculado. O mapeamento das classes ópticas seria menos detalhado, tendo classes que indicam a presença de águas com baixa, média e elevada intensidade de floração (Tabela 4.1; Figuras 4.1 e 4.2), pois considerando um programa de monitoramento do estado trófico por SR, a nível regional, as classes mais gerais seriam mais adequadas e talvez pudessem ser replicadas mais amplamente sem a necessidade de nova calibração. Vale ressaltar também que outros estudos usaram a classificação óptica para estabelecer intervalos de concentrações dos COAs a partir de diferentes tipos ópticos de águas, como por exemplo classificação óptica baseada em algoritmo de classificação de lógica *fuzzy* (MOORE et al., 2014) e método de agrupamento hierárquico (SHI et al., 2013).

Além disso, comparando o valor dos limites das faixas de $\text{chl-}a$, neste trabalho a faixa da “Classe 1” do SAM ($2,89 \leq \text{chl-}a \leq 22,83 \text{ mg/m}^3$) engloba quase que sozinha as duas primeiras faixas de $\text{chl-}a$ de Matsushita et al. (2015) e Smith et al. (2018) ($\text{chl-}a \leq 10 \text{ mg/m}^3$ e $10 < \text{chl-}a \leq 25 \text{ mg/m}^3$). Enquanto que considerando o método limnológico, a amplitude de concentração da segunda faixa (“EutroSuper” = $11,03 < \text{chl-}a \leq 69,05 \text{ mg/m}^3$) é maior que a dos autores. As faixas de $\text{chl-}a$ dos autores citados são mais

estreitas, uma vez que possuem em seu banco de dados espectros de R_{rs} com características espectrais de águas oligotróficas.


Um ponto a se destacar neste trabalho é o fato de haver regiões de transição entre as classes ópticas do SAM (Figura 4.1, Figura 5.2), ocasionando a sobreposição entre duas faixas específicas de concentração da chl-*a* consecutivas (Tabela 4.1). Isso é razoável, uma vez que na natureza há zonas de transição entre as classes, principalmente em reservatórios em decorrência do fluxo em direção à barragem. Nota-se pela Figura 5.2A que embora as concentrações de chl-*a* tenham valores próximos, seus espectros referentes possuem pequenas diferenças em sua forma (principalmente na região entre 600-825 nm, em que foi realizada o SAM), pertencendo a classes diferentes pelo SAM. Isso ocorre porque a forma espectral da R_{rs} está associada não apenas ao valor da concentração da chl-*a*, mas também a sua distribuição na coluna d'água e ao estado fisiológico do fitoplâncton, influenciado por fatores ambientais e pelo impacto dos outros COAs.

No entanto, essa pequena diferença entre a forma dos espectros de R_{rs} na região de transição do SAM pode não ser suficiente para separá-los em classes ópticas diferentes no momento da aplicação da árvore de decisão (Figura 4.4A). Isso aconteceu com os espectros de R_{rs} *in situ* simulados para as bandas do MSI/Sentinel-2 apresentados na Figura 5.2A. No caso, a razão das bandas B5/B4 da estação amostral “P4_Jul_2014”, classificada como “Classe 2” pelo SAM, não foi suficiente ($B5/B4 = 1,18$) para classificá-la também como “Classe 2” pela árvore de decisão ($B5/B4 \leq 1,20$ o espectro/pixel é classificado como “Classe 1”) na validação do MHO (dados *in situ*).

Assim, essas regiões de transição podem também gerar erros de classificação durante a aplicação do modelo híbrido na imagem de satélite (Figura 5.2B). A estação amostral “P6_Aug_2018”, que também está presente na região de transição entre as classes 1 e 2 do SAM, foi a única estação que apresentou erro de classificação pela árvore de decisão quando o MHO foi aplicado na imagem de satélite. Esta estação foi classificada como “Classe 1” pelo SAM e como “Classe 2” pela árvore de decisão. A razão das bandas B5/B4 desta estação considerando a R_{rs} *in situ* simulada foi 1,12 e a R_{rs} do satélite foi 1,28, justificando o erro da classificação pela árvore de decisão (Figura 4.4A). Uma

possível solução para tais confusões na região de transição entre as classes ópticas seria restringir a região espectral para o cálculo do SAM, no caso uma região mais estreita entre 600-825 nm, enfocando os comprimentos de onda considerados no treinamento e teste da árvore de decisão.

Figura 5.2 – (A) Exemplos de espectros (R_{rs} *in situ* simulada para as bandas do MSI/Sentinel-2) de transição entre as classes 1 (linha laranja) e 2 (linha verde) do SAM, com valores de concentração de chl-*a* (mg/m^3) próximos; e de (B) espectros de R_{rs} *in situ* simulado (linha vermelha) e derivado de satélite (linha roxa) da estação amostral “P6_Ago_2018”, mostrando o valor da concentração da chl-*a* *in situ* (vermelha) e estimada pela imagem (roxa).



O método limnológico também possui essas regiões de transição óptica entre as classes ópticas “OligoMeso e EutroSuper” e “EutroSuper e Hiper” (Figura 4.2). Entretanto, diferente do método óptico, não ocorre sobreposição entre as faixas específicas de concentração da chl-*a* (Tabela 4.1).

É importante destacar que quando as classes ópticas são definidas em termos de concentração de chl-*a* (método limnológico), os espectros se superpõem uma vez que apenas um COA está sendo considerado no particionamento das amostras. Assim, é esperado que não haja uma correspondência biunívoca entre uma dada concentração de chl-*a* e uma dada forma e intensidade espectral, pois existem outros COAs que podem alterar a forma do espectro independentemente da concentração da chl-*a*. Já quando se usa o SAM (método óptico), as classes ópticas são divididas em função do conjunto de formas espectrais, ou seja, levando em consideração a presença de outros COAs. Para

aplicações em imagens de satélite, será essa a condição analítica, pois o sensor registra o resultado das diferentes proporções de COAs em um dado pixel. Então, o uso da classificação óptica é mais eficiente para o monitoramento do estado trófico por satélite. Além disso, as classes ópticas do SAM permitem uma aplicação mais ampla, considerando a variabilidade espacial e temporal das propriedades ópticas dos reservatórios.

5.3 Comparações dos algoritmos bio-ópticos de chl-*a*

Neste trabalho, o algoritmo de três bandas do Gitelson et al. (2011a) teve melhor desempenho nas faixas de concentração das classes ópticas “OligoMeso” ($chl-a \leq 11,03 \text{ mg/m}^3$) e “Classe 1” ($2,89 \leq chl-a \leq 22,83 \text{ mg/m}^3$) que os outros algoritmos bio-ópticos testados (Tabela 3.2). Nessas faixas de concentração há maior influência do NAP e do CDOM (Figura 5.1A) que nas outras faixas (Tabela 4.1), sendo que esse algoritmo foi projetado para minimizar os efeitos desses COAs no espectro de R_{rs} e assim ressaltar a feição de absorção pela chl-*a* para conseguir estimar sua concentração em águas opticamente complexas túrbidas (DALL’OLMO et al., 2003; GITELSON et al., 2008). Além disso, os espectros de R_{rs} que abrangem esse intervalo de concentração (Figuras 4.1A e 4.2A) possuem características espectrais semelhantes aos espectros de reflectância extraídos do *Hyperspectral Imager for the Coastal Ocean* (HICO) por Gitelson et al. (2011a), para uma faixa de concentração de $19,67 - 93,14 \text{ mg/m}^3$ na Baía de Taranrog e no mar Azov (Rússia). Os autores relataram que o algoritmo explicou mais de 85% da variação da chl-*a* e permitiu a estimativa da chl-*a* na faixa citada com um RMSE $< 10 \text{ mg/m}^3$. Entretanto, os autores não conseguiram afirmar se o algoritmo é válido para concentrações inferiores a 40 mg/m^3 , por conta da baixa amostragem nessas concentrações, mas o presente estudo mostrou que o algoritmo tem bom desempenho para concentrações inferiores a 23 mg/m^3 (Tabela 4.3).

Gitelson et al. (2009, 2011b) também aplicaram o algoritmo de três bandas nos Lagos Fremont (Nebraska – EUA) para um conjunto de espectros de R_{rs} com característica espectral semelhante ao do presente estudo, e mostraram que esse tipo de algoritmo tem potencial para ser aplicado em concentrações baixas/medianas. Gitelson et al. (2009) relataram que o algoritmo (usando as bandas $\sim 670, 710$ e 750 nm ; próximas as usadas

neste estudo) explicou mais de 89% da variação da chl-*a* em um range de 2 – 20 mg/m³ e pode ser usado para estimar a concentração da chl-*a* com um RMSE < 1,65 mg/m³. Já Gitelson et al. (2011b) mostraram que o algoritmo de três bandas possui sensibilidade ($R^2 = 0,84$) para estimar a concentração da chl-*a* em um range entre 0 – 30 mg/m³.

Além disso, Matsushita et al. (2015) testaram o algoritmo de três bandas para a faixa de concentração de 10 – 25 mg/m³, que também possui espectros de R_{rs} com características espectrais semelhantes ao deste trabalho (Figuras 4.1A e 4.2A), e para todo o conjunto de dados (chl-*a* = 1,8 – 153,9 mg/m³). Os autores obtiveram para a faixa de chl-*a* entre 10 – 25 mg/m³ valores de MAPE 32,5%, RMSE 6,19 mg/m³, NRMSE 35,9% e R^2 0,71, tendo um desempenho semelhante ao obtido para o algoritmo de três bandas calibrado/validado na faixa de chl-*a* da classe óptica “Classe 1” (MAPE = 34,36%, RMSE = 5,34 mg/m³, NRMSE = 26,78% e $R^2 = 0,78$) e um desempenho inferior em relação ao obtido para a faixa de chl-*a* da classe óptica “OligoMeso” (MAPE = 25,17%, RMSE = 1,12 mg/m³, NRMSE = 21,39% e $R^2 = 0,92$). Além do mais, os autores também demonstraram que esse algoritmo possui melhor desempenho quando aplicado para uma faixa específica de concentração de chl-*a* que para uma faixa mais ampla (MAPE = 89,4%, RMSE = 12,06 mg/m³, NRMSE = 261,9% e $R^2 = 0,93$).

O algoritmo NDCI do Mishra e Mishra (2012) teve melhor desempenho para a faixa de chl-*a* da classe óptica “EutroSuper” ($11,03 < chl-a \leq 69,05$ mg/m³), em concordância com os bons resultados de validação obtidos pelos autores para um range bem próximo de chl-*a* de 1 – 60 mg/m³ usando R_{rs} simuladas ($R^2 = 0,93$; RMSE = 4,83 mg/m³) e para um range com valores mais restritos de chl-*a* de 0,9 – 28,1 mg/m³ (medidas *in situ*) usando R_{rs} obtidas pelo sensor MERIS ($R^2 = 0,9$; RMSE = ~ 2 mg/m³), nas regiões das baías de Chesapeake, Delaware e Mobile e no delta do rio Mississippi (EUA). Já o algoritmo *Slope* do Mishra e Mishra (2010) teve melhor desempenho para a faixa de chl-*a* da classe óptica “Classe 2” ($19,51 \leq chl-a \leq 87,63$ mg/m³), faixa com valores bem próximos aos usados pelos autores ($14,14 \leq chl-a \leq 70,97$ mg/m³) para testar o algoritmo em águas do lago Pontchartrain (EUA). No trabalho de Mishra e Mishra (2010), o algoritmo explora a relação entre as mudanças no *slope* usando a R_{rs} das bandas do verde e vermelho do MODIS (553 nm e 645 nm) com as mudanças da concentração da chl-*a* nas águas do

lago. No presente estudo, essa relação foi explorada usando a R_{rs} *in situ* simulada para as bandas do vermelho e *red-edge* do sensor MSI/Sentinel-2 (665 e 705 nm), tendo um desempenho melhor ($R^2 = 0,93$ e $RMSE = 12,09 \text{ mg/m}^3$; Tabela 4.3) que o obtido pelos autores ($R^2 = 0,65$ e $RMSE = 9,43 \text{ mg/m}^3$).

Os algoritmos NDCI e *Slope* também foram testados por Watanabe et al. (2017) no reservatório de Barra Bonita/SP, usando o sensor MSI/Sentinel-2 em uma faixa de concentração de chl-*a* 17,7 – 797,8 mg/m^3 . Analisando os espectros de campo, notou-se que o formato da R_{rs} do presente estudo se encaixa dentre os espectros usados pelos autores para calibração/validação dos algoritmos. Comparando os resultados, os algoritmos tiveram melhor desempenho para as faixas específicas de concentração consideradas neste estudo (NDCI na faixa de chl-*a* da classe óptica “EutroSuper”, ajuste polinomial: $R^2 = 0,79$, MAPE = 24,04%, $RMSE = 7,47 \text{ mg/m}^3$, NRMSE = 15,18%; *Slope* na faixa de chl-*a* da classe óptica “Classe 2”, ajuste exponencial: $R^2 = 0,93$, MAPE = 23,35%, $RMSE = 12,09 \text{ mg/m}^3$, NRMSE = 19,05%) que para a faixa ampla de concentração testada por Watanabe et al. (2017) (NDCI, ajuste polinomial: $R^2 = 0,82$, MAPE = 90,68%, $RMSE = 101,51 \text{ mg/m}^3$ e NRMSE = 47,71%; *Slope*, ajuste linear: $R^2 = 0,76$, MAPE = 49,02%, $RMSE = 74,31 \text{ mg/m}^3$ e NRMSE = 69,65%; *Slope*, ajuste polinomial: $R^2 = 0,76$, MAPE = 64,59%, $RMSE = 87,28 \text{ mg/m}^3$ e NRMSE = 43,85%).

Os algoritmos de razões simples de bandas B5/B3 e B6/B3 e o algoritmo *Slope* do Mishra e Mishra (2010), usando as bandas B6 e B4, foram os de melhor desempenho para estimar a concentração de chl-*a* em condições extremamente críticas de eutrofização (faixas de chl-*a* das classes ópticas “Hiper” e “Classe 3”, Tabela 4.1). Tais bandas foram consideradas tendo em vista que quanto maior a concentração da chl-*a*, maior a diferença entre os valores das bandas B5 (705 nm) e B3 (560 nm), B6 (740 nm) e B4 (665 nm), e B6 (740 nm) e B3 (560 nm). Em elevadas concentrações, os espectros de R_{rs} têm mais sinal nos comprimentos de onda 705 nm e 740 nm que em menores concentrações. Isso ocorre devido a maior influência do espalhamento pelas células fitoplânctônicas (florações mais densas na superfície da água) e consequente redução da influência da absorção pela água nos maiores comprimentos de onda. Até o presente momento, não foi encontrado na literatura aplicações desses tipos de combinações de bandas para estimar

elevadas concentrações de chl-*a* usando o sensor MSI/Sentinel-2, sendo assim uma opção inovadora para tal finalidade.

5.4 Avaliação da estrutura dos modelos híbridos

A escolha do modelo de classificação por árvore de decisão para desenvolver a estrutura da condicional dos modelos híbridos (Figuras 4.3A e 4.4A) decorreu de sua simplicidade e fácil reprodutibilidade. Outros trabalhos também usaram estruturas simples de condicionais para a operação do modelo híbrido (GÓMEZ et al., 2011; LE et al., 2011; MATSUSHITA et al., 2015; SMITH et al., 2018; SHI et al., 2013), permitindo alternar entre a aplicação de diferentes algoritmos bio-ópticos conforme a faixa de concentração de chl-*a* ou tipo óptico de água. Por exemplo, Matsushita et al. (2015) usaram o algoritmo MCI, Shi et al. (2013) utilizaram os valores e razões das bandas 7, 8 e 9 do MERIS (665, 681 e 709 nm), Le et al. (2011) testaram os *slopes* entre os comprimentos de onda de 650 nm e o de máxima reflectância na região do verde e na região do infravermelho próximo, e Smith et al. (2018) aplicaram razão de bandas entre as reflectâncias nos comprimentos de onda de 708 e 665 nm. Nesses trabalhos, os limiares da condicional da abordagem híbrida foram determinados de maneira empírica. Além disso, não houve a avaliação do desempenho de como essas estruturas particionam os dados.

Para superar essa limitação, neste estudo o conjunto de dados foi dividido em treino e teste. Além disso, métricas de desempenho, como a matriz de confusão, precisão e *recall*, foram usadas para avaliar o desempenho do modelo de classificação. Os resultados das métricas de desempenho (Figuras 4.3B e 4.4B; Tabela 4.5) mostraram que a estrutura da condicional dos modelos híbridos permite dividir o conjunto de dados de forma precisa, garantindo que as diferentes classes ópticas de faixas específicas de concentração da chl-*a* sejam classificadas adequadamente antes da aplicação do modelo híbrido sobre a imagem de satélite. Além do mais, torna a estrutura híbrida aplicável em outros sistemas aquáticos tropicais interiores com condições ópticas semelhantes.

Uma das diferenças entre os modelos híbridos deste trabalho e os desenvolvidos por Matsushita et al. (2015) e Smith et al. (2018) é que, neste estudo, o algoritmo bio-óptico selecionado para cada faixa específica de concentração da chl-*a* foi calibrado/validado

usando a simulação Monte Carlo, enquanto que os outros autores testaram os algoritmos em sua forma original, sem quaisquer parametrizações. Em geral, os algoritmos de melhor desempenho para as faixas de concentração de chl-*a* de Matsushita et al. (2015) apresentaram estatísticas de validação (dados *in situ*) que variaram de: 9 – 16% para o NMAE (*normalized mean absolute error*, que é equivalente ao MAPE), 0,30 – 10,28 mg/m³ para o RMSE, e 0,54 – 0,90 para o R². Já com relação aos algoritmos bio-ópticos usados por Smith et al. (2018), houve uma variação de 37,9 – 44,5% para o MARD (*median absolute relative difference*; a estatística MARD é comparável ao MAPE, pois os valores de mediana e média são geralmente próximos; foi mostrado somente esta estatística pois o valor de RMSE está em log10). Em comparação com o presente estudo (método limnológico = MAPE: 21,78 – 26,65%, RMSE 1,12 – 123,63 mg/m³, R² 0,79 – 0,92 / método óptico = MAPE: 20,12 – 34,36%, RMSE 5,34 – 58,90 mg/m³, R² 0,78 – 0,98 - Tabela 4.3), a validação dos algoritmos bio-ópticos no trabalho de Matsushita et al. (2015) teve melhor resultado, mas vale lembrar que eles foram testados em um range mais estreito.

Comparando-se o desempenho da validação *in situ* dos modelos híbridos deste estudo (Figuras 4.7D, 4.8D, 4.9D e 4.10D) com os presentes na literatura, foi possível observar que o desempenho do MHL e do MHO (MAPE = 22,55 – 26,33%, RMSE = 24,13 – 74,31 mg/m³, NRMSE = 4,05 – 8,82%, R² = 0,94 – 0,98) é melhor que o do modelo híbrido de Smith et al. (2018) (MARD = 36,4%, R² = 0,81) e um pouco inferiores ao de Matsushita et al. (2015) (MAPE = 13,3%, RMSE = 8,63 mg/m³, NRMSE = 16,5% e R² = 0,94). Além disso, para os dados de satélite, a validação dos modelos híbridos (Figura 4.14 C e D, respectivamente) apresentou desempenho de MAPE = 33,99% e R² = 0,56 para o MHL e MAPE = 28,32% e R² = 0,42 para o MHO. Ao comparar esse resultado com o de Smith et al. (2018) (MARD = 45,7%, R² = 0,69), nota-se que embora o modelo híbrido dos autores explica 69% da variação da chl-*a* para um intervalo de 0,43 – 309 mg/m³ (mais do que este estudo: 42% para o MHO e 56% para o MHL, para uma faixa de 14,96 – 59,19 mg/m³) sua porcentagem de erro é maior que o do presente estudo (sendo quase 2 vezes maior para o MHO).

O MHL e o MHO também tiveram um desempenho melhor na estimativa da concentração da chl-*a* que o algoritmo semi-analítico parametrizado (com base nas bandas do OLCI/Sentinel-3) para o reservatório altamente produtivo de Barra Bonita/SP (chl-*a* > 700 mg/m³; WATANABE et al., 2018). A validação desse algoritmo foi realizada com dados medidos no reservatório de Bariri (reservatório eutrófico; chl-*a* = 25,1 – 694,3 mg/m³), o segundo reservatório do sistema em cascata do rio Tietê. Os resultados de validação (MAPE = 62,3%, R² = 0,81, chl-*a* < 300 mg/m³) foram inferiores aos dos modelos híbridos deste trabalho, e o algoritmo semi-analítico não foi capaz de estimar com precisão a chl-*a* para valores mais elevados de concentração (> 600 mg/m³). É importante ressaltar que essa diferença no desempenho pode ser resultado de outros fatores além do tipo de modelo aplicado, como o uso de dados de validação de outro reservatório do sistema em cascata, obtenção dos dados *in situ* em datas diferentes e uso de sensores do Sentinel (MSI e OLCI) com resoluções espaciais e espectrais distintas. Além disso, Andrade et al. (2018) mostraram que nem as versões original e parametrizada do QAA, testadas no reservatório de Ibitinga, foram capazes de estimar os coeficientes de absorção em todos os comprimentos de onda. Os resultados dos autores indicaram que é desafiador lidar com a alta variabilidade óptica no sistema em cascata e destacaram a limitação de um esquema quase-analítico para o monitoramento espaço-temporal dos COAs nesse tipo de água interior tropical.

Uma das vantagens da metodologia proposta é que a estrutura da condicional dos modelos híbridos, gerada pela árvore de decisão, é independente do desenvolvimento dos algoritmos bio-ópticos em cada faixa específica de concentração da chl-*a* e não se preocupa com a forma como os algoritmos são implementados. Assim, outros tipos de algoritmos podem ser combinados usando a mesma estrutura para estimar a concentração da chl-*a*, considerando diferentes condições ópticas e faixas específicas de concentração. Ou seja, outros tipos de modelos híbridos podem ser construídos usando a mesma estrutura da condicional. Além disso, considerando a aplicabilidade dos modelos híbridos em imagens de satélite, a estrutura da condicional desenvolvida (Figuras 4.5 e 4.6) tornou esse processo mais operacional. Isso porque é necessário apenas usar relações entre as razões simples de bandas B4, B5 e B6 do sensor MSI/Sentinel-2 para classificar cada

pixel em uma das faixas específicas de concentração da chl-*a* (classes ópticas), e assim estimar a chl-*a* usando o algoritmo bio-óptico correspondente àquela faixa.


Uma desvantagem a ser ressaltada desse processo, é que a aplicação bem-sucedida da estrutura da condicional para alternar entre os algoritmos e dos algoritmos bio-ópticos para estimar a concentração da chl-*a* em cada faixa depende da qualidade da correção atmosférica usada na imagem. No presente estudo, a correção atmosférica teve melhor desempenho considerando a correção do *glint*, embora algumas bandas tenham sido supercorrigidas (Figura 4.13B e Tabela 4.6). As incertezas na estimativa da R_{rs} influenciam a precisão geral dos modelos híbridos. No entanto, é importante observar que apesar dos baixos valores de R^2 para as R_{rs} derivadas por satélite quando comparadas aos dados *in situ*, os valores de MAPE foram em geral inferiores a 29%. Essa incerteza é comumente observada em águas interiores. Por exemplo, Maciel et al. (2019) obtiveram valores de MAPE de aproximadamente 20% para as águas turvas dos lagos da várzea Amazônica. Wang et al. (2019) também observaram valores de MAPE de cerca de 20% para a correção atmosférica 6SV nas bandas do verde e vermelho do OLI/Landsat-8 em ambientes eutróficos nos lagos da China. No presente trabalho, a variabilidade entre a R_{rs} *in situ* e a derivada pelo satélite pode ter influenciado os resultados da validação dos modelos híbridos na imagem, obtendo-se um desempenho inferior (MHL, Figura 4.14C: MAPE: 33,99%, RMSE: 10,79 mg/m³, NRMSE: 24,40% e R^2 : 0,56 / MHO, Figura 4.14D: MAPE: 28,32%, RMSE: 12,98 mg/m³, NRMSE: 29,35% e R^2 : 0,42) em relação à validação com dados de R_{rs} *in situ* (MHL_ate1000, Figura 4.8D: MAPE = 22,55%, RMSE = 74,31 mg/m³, NRMSE = 8,82% e R^2 = 0,94 / MHO_ate1000, Figura 4.10D: MAPE = 26,33%, RMSE = 34,07 mg/m³, NRMSE = 4,05% e R^2 = 0,98). Um ponto que também pode ter influenciado nesses resultados é a diferença entre a resolução espacial do dado *in situ* e da imagem MSI/Sentinel-2, bem como a heterogeneidade espacial dentro da janela 3x3 pixels, utilizada para extrair os valores estimados de chl-*a*.

Outro fator que pode ter afetado o desempenho do MHL e MHO quando aplicados na imagem foi que nem todas as estações amostrais foram coletadas no mesmo dia da passagem do satélite. Além disso, os dados *in situ* foram coletados aproximadamente ao longo de 4 horas (~10hr às 14hr), enquanto a imagem foi obtida quase instantaneamente,

por volta das 10:30hr. Assim, o baixo valor de R^2 observado na Figura 4.14 C e D entre a comparação da chl-*a* medida e modelada, a partir da imagem de satélite, pode ser devido a diferenças nas condições hidrodinâmicas e ambientais de cada estação amostral. O reservatório hidroelétrico de Ibitinga possui hidrodinâmica variável, influenciada principalmente pelo tempo de residência hidráulica, demanda de energia e liberação de água devido a questões de controle de qualidade da água (LONDE et al., 2016). Esses processos podem levar a uma mudança na dinâmica da floração do fitoplâncton e seu impacto não é constante em todo o reservatório. Em geral, as regiões mais próximas à barragem são mais afetadas por choques mecânicos e lavagem hidráulica, enquanto as regiões a montante podem permanecer mais protegidas dessas ações. Vale ressaltar também que a dinâmica da floração do fitoplâncton pode ser influenciada pelo vento.

Isso pode ser visualizado na Figura 5.3, em que uma comparação entre as imagens em cores verdadeiras (mesmo contraste aplicado) do OLI/Landsat-8 do dia 12/08/2018 e do MSI/Sentinel-2 do dia 13/08/2018 (usada neste trabalho para a validação dos modelos híbridos) demonstrou a variabilidade da floração do fitoplâncton entre esses dias. As regiões das estações P1 e P2 (coletadas em 12/08/2018; círculos azuis e vermelhos na Figura 4.14) tiveram uma floração mais densa um dia antes da passagem do satélite (13/08/2018), e isso pode ter subestimado a concentração da chl-*a* nessas duas estações. Além disso, a dinâmica da floração no reservatório também pode ser influenciada pelos tributários, como pode ser visto na Figura 5.3. Nesta figura, a região da estação P6 (coletada em 13/08/2018; círculo laranja na Figura 4.14), localizada na foz do rio Jacaré-Pepira e próxima a uma piscicultura, teve mais formação de floração no dia da passagem do satélite. Entretanto, como a estação amostral foi coletada uma hora antes da aquisição da imagem, ela não teve uma boa estimativa da chl-*a* pelo MHL e MHO, se tornando um *outlier*.

Figura 5.3 - Variabilidade da cor da água no reservatório de Ibitinga para (A) 12/08/2018 (OLI/Landsat-8, RGB composição das bandas 4-3-2) e (B) 13/08/2018 (MSI/Sentinel-2, RGB composição das bandas 4-3-2). Ambas imagens possuem o mesmo contraste aplicado. Os pontos se referem às estações amostrais P1, P2 e P6 coletadas no campo de Agosto/2018.



É importante ressaltar também que, no presente estudo, o MHL e MHO não diferenciam entre a formação de *surface scum* na superfície das águas do reservatório e a presença de macrófitas. No caso, os algoritmos bio-ópticos usados para estimar elevadas concentrações de chl-*a* (algoritmos das classes ópticas “Hiper” e “Classe 3”, Tabela 4.3) estimam a chl-*a* em ambos casos, e os modelos híbridos geram um resultado único, que

seria a chl-*a* estimada em uma condição de elevada intensidade de floração. Como o reservatório de Ibitinga possui banco de macrófitas em algumas épocas do ano, tal diferenciação seria interessante e necessária antes da aplicação do modelo híbrido na imagem, sendo uma sugestão a ser incrementada para trabalhos futuros.

No geral, considerando a espacialização das classes ópticas e da estimativa da concentração da chl-*a* no reservatório de Ibitinga (Figuras 4.17 e 4.18), pode-se dizer que a classificação utilizando a árvore de decisão realmente foi eficiente, uma vez que classificou toda a extensão do rio Jacaré-Pepira (área de preservação ambiental) como classe 1 (baixa intensidade de floração) e classificou uma fração do rio Jacaré-Guaçu (recebe o esgoto sem tratamento da cidade de Ibitinga) como classe 2 (média intensidade de floração). A região em vermelho (classe 3) nas Figuras 4.17A e 4.18A também era de se esperar uma maior intensidade de florações, visto que é uma região de piscicultura. Os meandros do reservatório e a região próxima à barragem (parte superior da figura) também possuem uma presença marcante de ocorrência de florações, pois são regiões que tendem a ter baixa velocidade de fluxo da água (CAIRO et al., 2017), o que facilita o desenvolvimento das cianobactérias *Microcystis aeruginosa* (LONDE, 2008; REYNOLDS, 2006). As cianobactérias são normalmente encontradas em águas eutrofizadas, podendo vir a dominar o fitoplâncton devido a várias adaptações, como por exemplo a regulação da flutuação na coluna d'água pela presença de vacúolos e o uso eficiente da luz na região do amarelo/laranja para a fotossíntese (REYNOLDS; WALSBY, 1975). Uma questão preocupante do seu domínio no reservatório de Ibitinga, em diferentes condições de eutrofização, é que as cianobactérias produzem uma variedade de toxinas que afetam negativamente tanto a saúde humana quanto a vida aquática (CHORUS; BARTRAM, 1999).

5.5 Análise temporal – comparação entre o MHL e MHO – limitações

A partir da comparação da série temporal gerada pelo MHL e MHO, percebeu-se que os resultados são bem diferentes em alguns casos. A diferença na espacialização das classes ópticas entre a classe 1 (cor verde – baixa intensidade de floração) do MHL e MHO era esperada, uma vez que o intervalo de concentração da classe 1 do MHL é duas vezes menor que do MHO. Assim, usando o MHL, a espacialização das classes ópticas teria

uma quantidade menor de área verde no mapa em relação ao MHO, para uma mesma data.

Além disso, uma outra diferença identificada foi a presença de área com a classe “não classificada” (cor branca) no mapa de chl-*a* do MHO em comparação com o do MHL, em condições de baixa intensidade de floração (classe 1), indicando a presença de valores negativos de concentração de chl-*a* estimada. Embora nesse tipo de classe óptica, em ambos modelos híbridos, o algoritmo de três bandas do Gitelson et al. (2011a) (Tabela 3.2) tenha sido o de melhor desempenho, os resultados dos ajustes foram diferentes. No caso, o algoritmo de 3 bandas para a “Classe 1” do MHL possuiu um ajuste exponencial ($y = a \cdot \exp^{(bx)}$), em que nos resultados da Monte Carlo “*a*” foi um valor positivo. Assim o valor da função, que é a concentração da chl-*a*, sempre será positivo, independente se o valor do expoente da função exponencial for positivo ou negativo (o sinal do expoente indica se a função é crescente ou decrescente acima do eixo x), não ocorrendo a classe “sem classificação”.

Já para o MHO, o algoritmo de três bandas da “Classe 1” teve um ajuste linear ($y = ax + b$), em que nos resultados da Monte Carlo os coeficientes angular e linear da reta foram valores positivos. Nesse caso, ocorrem valores negativos de concentração de chl-*a* quando a R_{rs} da B5 (~705 nm) do MSI/Sentinel-2 é muito menor em comparação à B4 (~665nm), e resulta em um valor negativo de “*ax*” maior que o valor de “*b*”. Com isso, o algoritmo de três bandas com ajuste linear possui baixa sensibilidade em condições muito oligotróficas da água. Dessa forma, o valor de R_{rs} da B5 do MSI/Sentinel-2, considerando correção atmosférica e correção do *glint*, abaixo do qual gera valores negativos de concentração de chl-*a* é $0,065 \text{ sr}^{-1}$. Além disso, os valores mínimos de R_{rs} das bandas B4 e B6 do MSI/Sentinel-2 a partir dos quais não geram valores negativos de chl-*a* são $0,092 \text{ sr}^{-1}$ e $0,059 \text{ sr}^{-1}$, respectivamente.

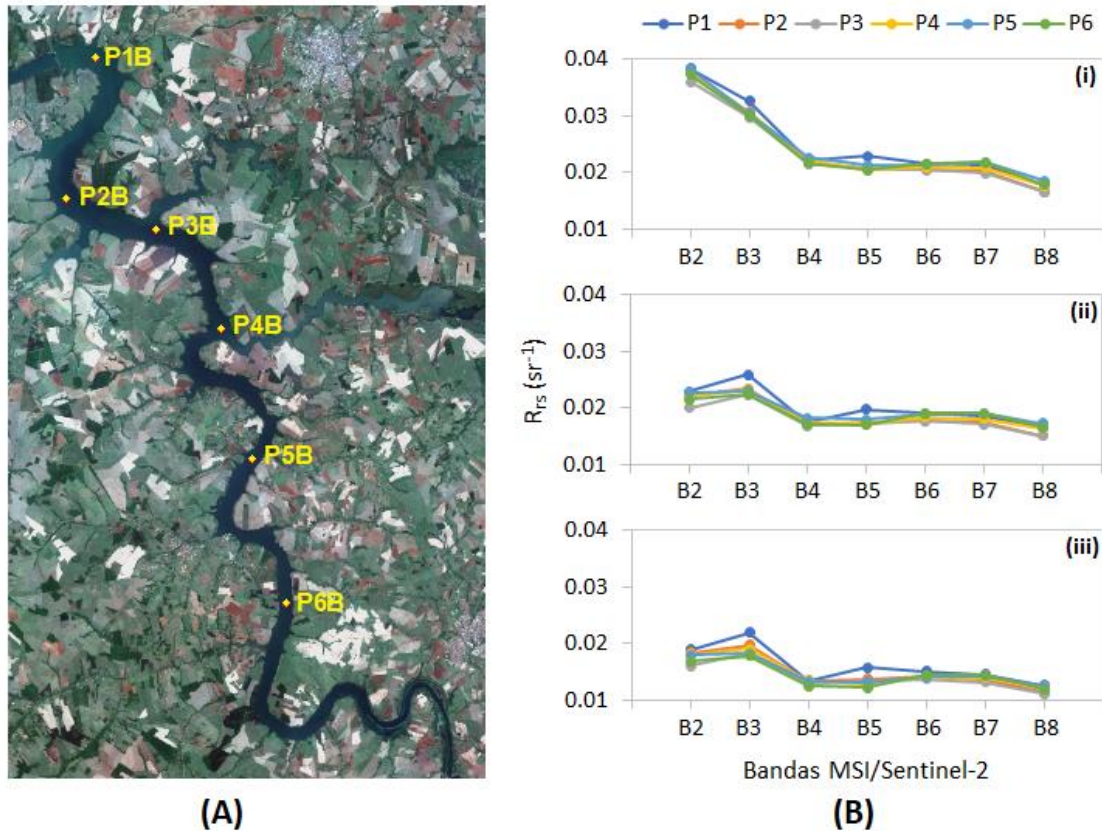
Uma outra limitação a ser destacada que gera diferenças entre os modelos híbridos é em condições de elevada intensidade de floração, com relação à correção do *glint* utilizada. Quando tem muita floração, as bandas do SWIR do MSI/Sentinel-2 (B11 e B12) possuem sinal e isso pode gerar valores negativos das bandas B4, B5 e B6 após a correção do *glint*.

Dessa forma, todo o processo de aplicação do modelo híbrido é prejudicado, uma vez que determina a classe óptica errada na árvore de decisão para o pixel e, conseqüentemente, aplica o modelo errado, não representando a real condição trófica do sistema aquático.

Uma possível solução para tal problemática seria avaliar a existência de elevada intensidade de floração antes de aplicar o modelo híbrido na imagem. Assim, caso existir essa condição de floração na imagem, a correção do *glint* utilizada no presente estudo não seria aplicada ou então utilizaria uma correção do *glint* própria para esse caso (não encontrado na literatura – vale ressaltar que pode haver *glint* na imagem em condições de *surface scum*). Uma sugestão para trabalhos futuros seria: a) fazer uma análise de sensibilidade das bandas B11 e B12 do MSI/Sentinel-2 de forma a verificar a intensidade do sinal a partir do qual gera valores negativos das bandas utilizadas nos algoritmos após a correção do *glint*, em caso de presença de *superbloom*; e b) estabelecer uma condicional no *script* para identificar as imagens com valores das bandas B11 ou B12 acima do limite de sinal estabelecido no tópico anterior, excluindo-as do processo de correção do *glint* utilizado neste trabalho ou aplicando uma correção do *glint* apropriada para condições de *superbloom*.

Um caso especial de grande diferença entre a espacialização das classes ópticas do MHL e MHO foi verificado no dia 17/09/2016. Nessa data, a árvore de decisão do MHL classificou a imagem toda como “Classe 3” e do MHO como “Classe 1” (Figuras 4.19 e 4.37). Verificando a imagem RGB do MSI/Sentinel-2 deste dia (Figura 5.4A), nota-se que as condições de intensidade de floração se aproximam mais da classificação estabelecida pelo MHO. Assim, de forma a analisar mais a fundo sobre uma possível explicação para tal situação, pontos aleatórios (P1B a P6B) foram determinados ao longo do reservatório (Figura 5.4A), na imagem MSI/Sentinel-2 desta data, com o intuito de obter os espectros de R_{rs} em três tipos de condições (Figura 5.4B): i) sem correção atmosférica e correção do *glint* (subtração B11); ii) somente com correção atmosférica; e iii) com correção atmosférica e correção do *glint* (subtração B11). Tal análise teve o objetivo de verificar se houve algum problema após a correção atmosférica ou após a correção do *glint*.

Figura 5.4 – (A) Imagem RGB MSI/Sentinel-2 do dia 17/09/2016 (composição das bandas 4-3-2); os pontos amarelos (P1B a P6B) foram obtidos de maneira aleatória para realizar a análise. (B) Espectros de R_{rs} da imagem MSI/Sentinel-2 em três tipos de condições: i) sem correção atmosférica e correção do *glint* (subtração B11); ii) somente com correção atmosférica; e iii) com correção atmosférica e correção do *glint* (subtração B11).



Observou-se na Figura 5.4B, em todos os pontos (P1B a P6B), que após a correção atmosférica 6S a banda B6 do MSI/Sentinel-2 aparentemente não teve uma boa correção e após a correção do *glint* o formato do espectro é mantido, com apenas a redução em sua magnitude (como esperado). Analisando visualmente a imagem, os pontos selecionados parecem ter uma baixa intensidade de floração, sendo que nessa condição a banda B6 teria valores menores de R_{rs} que as bandas B5 e B4. Pela análise da Figura 5.4B, após a correção atmosférica (Figura 5.4B ii e iii), a maioria dos espectros extraídos da imagem possuem a banda B6 com valores de R_{rs} maiores que as bandas B5 e B4, assim a banda B6 parece ter sido superestimada. Outros trabalhos em águas interiores que usam a correção atmosférica 6S (MARTINS et al., 2017; MACIEL et al., 2019) mostraram que a banda B6 é superestimada. Como o MHL usa a razão B6/B4 como a primeira condição da árvore de decisão (Figura 4.5), a classificação do pixel pode ser prejudicada. Assim,

uma possível solução seria desenvolver, testar e avaliar uma correção atmosférica híbrida para águas interiores. No caso, a ideia seria utilizar para cada conjunto de bandas do MSI/Sentinel-2 as correções atmosféricas que tiveram resultados satisfatórios na literatura para esse tipo de água. Como por exemplo, utilizar a correção atmosférica 6S nas bandas do visível e Acolite ou Sen2Cor para estimar a R_{rs} nas bandas do NIR do MSI/Sentinel-2 (MARTINS et al., 2017).

Mesmo diante de todas as limitações e desafios mostrados acima, os resultados das séries temporais (Figuras 4.38 a 4.43 e Figuras 4.63 a 4.68) mostraram que a eutrofização do reservatório de Ibitinga foi intensificada a partir do ano de 2018, ao longo dos meses. Tal afirmação corrobora com os resultados mostrados nos relatórios de qualidade de águas interiores do estado de São Paulo, realizados pela CETESB (disponíveis em <https://cetesb.sp.gov.br/aguas-interiores/publicacoes-e-relatorios/>). Vale ressaltar que essa análise foi baseada em uma estação de monitoramento situada após a barragem de Ibitinga (estação “TIET 02600” – presente na UGRHI 16), uma vez que no reservatório de Ibitinga (inserido na UGRHI 13) não existe uma rede básica de monitoramento (o que dificulta a validação da análise temporal dos modelos híbridos), apenas uma estação de balneabilidade da água presente no município de Arealva. A estação de monitoramento “TIET 02600” está localizada a jusante do canal de fuga da casa de força da Usina Hidrelétrica de Ibitinga, na margem direita do rio Tietê. Assim, devido ao intenso movimento da água na saída da usina, o resultado do monitoramento dessa estação provavelmente não seja tão fidedigno as reais condições tróficas do reservatório de Ibitinga, mas fornece uma noção.

De acordo com a análise dos relatórios de 2015-2018, foi possível verificar que o IET médio anual na estação “TIET 02600” foi melhorando de 2015 a 2017, evoluindo de supereutrófico em 2015, para eutrófico em 2016 e mesotrófico em 2017. Em 2018, o estado trófico volta a ser eutrófico e, segundo descrito no relatório de 2018 da CETESB, o rio Tietê a partir do município de Suzano até o município de Ibitinga exibiu condições extremamente tróficas.

Um dos fatores que pode impactar a qualidade da água no reservatório de Ibitinga é que, embora a população vem crescendo ao longo dos anos, o índice de tratamento de esgoto ainda não é satisfatório. Analisando os dados referentes aos indicadores de esgotamento sanitário, a situação da UGRHI 13 ainda requer grande atenção. Isso porque, em média (anos 2016-2018), apenas 67% dos efluentes da UGRHI 13 são tratados, sendo a 8ª bacia com menor porcentagem de tratamento no estado de São Paulo (CBH-TJ, 2018). Além disso, de acordo com o relatório de 2018 da CETESB, o município de Ibitinga ainda não possui tratamento de esgoto (não é o único caso). Uma outra questão que pode influenciar o processo de eutrofização é a eficiência não satisfatória do tratamento de esgoto em alguns municípios da UGRHI 13, não reduzindo a carga poluidora orgânica doméstica lançada nos rios. Vale ressaltar também que a UGRHI 13 é classificada como “em industrialização”, com a presença de usinas de açúcar e álcool em todas as regiões da bacia, além de possuir destaque na produção e processamento de cítricos (principalmente laranja) (CBH-TJ, 2018). Por fim, as UGRHIs a montante do reservatório de Ibitinga, como as UGRHIs 5 e 6, também podem contribuir de forma negativa para a qualidade da água do reservatório, visto que são as regiões de maior densidade populacional do estado de São Paulo.

É importante destacar que não foi possível realizar neste trabalho uma avaliação espaço-temporal da eutrofização no reservatório de Ibitinga em resposta à expansão da cana-de-açúcar, a partir da série temporal gerada pelos modelos híbridos. Isso porque o ano de lançamento do Sentinel-2 (ano de 2015) não converge com os dados disponíveis de monitoramento anual do cultivo da cana-de-açúcar no estado de São Paulo (safra de 2003/2004 a 2013/2014), presentes no site do CANASAT (<http://www.dsr.inpe.br/laf/canasat/index.html>).

6 CONCLUSÕES

Este foi o primeiro estudo no Brasil a usar uma abordagem híbrida para estimar a concentração da chl-*a* em águas interiores opticamente complexas. A partir deste trabalho, foi possível verificar que, para reservatórios tropicais, os algoritmos bio-ópticos usados na estimativa da concentração da chl-*a* possuem melhor desempenho quando calibrados/validados para faixas específicas de concentração da chl-*a* que para faixas mais amplas. Além disso, mesmo com as limitações enumeradas, a análise dos resultados respondeu de forma positiva a hipótese deste trabalho. Assim, é possível ter uma melhor descrição espaço-temporal da concentração da chl-*a* e da condição trófica da água por SR utilizando uma abordagem híbrida.

Após a análise de todos os resultados, percebeu-se que a estrutura de desenvolvimento do MHO apresentou resultados melhores que a do MHL, embora tenha gerado valores negativos de concentração da chl-*a* em condições muito oligotróficas da água. De maneira geral, notou-se que quando a divisão das classes ópticas é bem estruturada, todo o processo de desenvolvimento do modelo híbrido vai gerando resultados com menor erro de classificação. No caso, as classes ópticas de faixas específicas de chl-*a* do método óptico estariam menos sujeitas a variações na intensidade da R_{rs} decorrentes de incertezas na coleta de campo, uma vez que foram divididas em função da forma espectral da R_{rs} e o SAM não é sensível às diferenças de magnitudes das curvas. Isso pode ter favorecido a árvore de decisão do MHO a ter o melhor resultado de treinamento, dessa forma seu algoritmo de classificação conseguiu separar os registros de treino em subconjuntos mais puros. No processo de validação dos modelos híbridos com dados *in situ*, o MHO não teve nenhum erro de classificação da árvore de decisão, já o MHL teve três erros. Considerando o processo de validação dos modelos híbridos na imagem do dia 13 de agosto de 2018 (com correção atmosférica e do *glint* – subtração da B11 do MSI/Sentinel-2), o MHO teve apenas um erro de classificação da árvore de decisão, enquanto que o MHL teve cinco. Com isso, o MHO consegue gerar menos erros de classificação dos pixels e também de estimativa de chl-*a*. Vale ressaltar também que a condicional da árvore de decisão do MHO não apresentou razão de bandas considerando a B6 do MSI/Sentinel-2. Assim, o desempenho da aplicação do MHO na imagem, pixel a pixel, é menos prejudicado em relação aos erros na correção atmosférica, visto que os erros

umentam em comprimentos de onda mais longos. Isso pode reduzir a possibilidade de classificação errada do pixel, e consecutivamente da estimativa errada da concentração da chl-*a*.

O presente estudo observou que os modelos híbridos de estimativa da concentração da chl-*a* podem ter variações em sua estrutura de construção de acordo com dois tipos de condições ópticas da água, em sistemas aquáticos opticamente complexos: i) águas com o fitoplâncton sendo o componente opticamente dominante (que é o caso deste estudo), e ii) águas com diferentes combinações dos COAs. No primeiro caso, o modelo híbrido enfoca a variação do nível trófico e os algoritmos bio-ópticos que o compõem são calibrados/validados para faixas específicas de concentração da chl-*a*. Já no segundo caso, o modelo híbrido enfocaria os diferentes tipos ópticos de água e os algoritmos bio-ópticos que o compõem estimariam a chl-*a* em cada classe óptica considerada, sendo que cada classe iria abranger diferentes proporções das concentrações dos COAs. Além disso, nesse segundo caso, talvez seria interessante incorporar modelos semianalíticos ou outros tipos de modelos que conseguiriam resolver melhor cada COA separadamente, no caso de não haver um dominante (mistura óptica maior).

Vale ressaltar também que os modelos híbridos desenvolvidos neste trabalho permitem derivar dois tipos de mapeamento da qualidade da água: i) um mapa de classes ópticas, gerado pela aplicação da árvore de decisão na imagem e que fornece um indicativo da intensidade de floração no reservatório, antes mesmo de estimar a concentração da chl-*a*; e ii) um mapa de estimativa da concentração da chl-*a*, derivado do algoritmo bio-óptico englobado em cada faixa de concentração. A partir do MHO, o mapeamento do estado trófico passa a ter uma visão óptica, uma vez que é atribuído ao comportamento espectral de cada pixel da água uma condição de eutrofização.

Uma questão a se considerar também no presente estudo é que como as propriedades espectrais das R_{rs} coletadas são representações de condições ópticas da água que são instantâneas de um contínuo, não é possível afirmar se todos os tipos possíveis de propriedades espectrais da R_{rs} das águas do reservatório de Ibitinga/SP são representados no conjunto de dados. Assim, o desenvolvimento dos modelos híbridos foi limitado aos

dados utilizados neste estudo, e pode-se supor que sejam aplicáveis a sistemas aquáticos tropicais interiores em que o fitoplâncton é o componente óptico dominante. A sugestão é que mais sistemas aquáticos com diferentes combinações dos COAs, propriedades espectrais da R_{rs} e condições ambientais sejam inseridos no conjunto de dados, para assim gerar um modelo híbrido de estimativa da concentração da chl-*a* mais representativo de diferentes tipos ópticos de água em regiões tropicais.

Além disso, o mapeamento da chl-*a* e do estado trófico usando a estrutura do modelo híbrido desenvolvido neste estudo tem potencial para ser expandido para outros tipos de sistemas aquáticos (ex.: lagos, rios, reservatórios), em diferentes condições ambientais e regiões do mundo. Isso porque cada algoritmo bio-óptico que compõe o modelo híbrido poderia ser ajustado para descrever cada conjunto de comportamento espectral decorrente das diferentes combinações dos COAs na água. Assim, o uso da abordagem híbrida seria ideal para se obter um monitoramento sistemático da concentração da chl-*a* em sistemas aquáticos com elevada variabilidade óptica e trófica no espaço/tempo, tendo potencial para se consolidar como metodologia de importantes projetos de monitoramento da qualidade da água. Essa abordagem permitirá no futuro criar séries temporais de concentração de chl-*a* para avaliar o impacto da expansão da cana-de-açúcar no aumento da proliferação de algas em diferentes reservatórios do estado de São Paulo.

Por fim, este trabalho pode ajudar os gestores de sistemas aquáticos a estabelecer novas estações de monitoramento em pontos estratégicos e representativos do reservatório, como perto da barragem e nos meandros. Além disso, a aplicação da metodologia de monitoramento desenvolvida pode auxiliar os gestores dos comitês das bacias do estado de São Paulo na elaboração de políticas ambientais e planejamento estratégico nos casos de extrema eutrofização. Vale ressaltar também que após o estabelecimento de um programa de monitoramento com o uso da abordagem híbrida (ex.: MAPAQUALI), os mapas resultantes podem alimentar o catálogo de informações ambientais do DataGEO (<http://datageo.ambiente.sp.gov.br/>), que é uma infraestrutura de dados espaciais ambientais do estado de São Paulo. Assim, facilitando o acesso à informação pela comunidade científica e gestores ambientais.

REFERÊNCIAS BIBLIOGRÁFICAS

AIKEN, J.; MOORE, G.F.; TREES, C.C.; HOOKER, S.B.; CLARK, D.K. The SeaWiFS CZCS-type pigment algorithm. In: HOOKER, S. B.; FIRESTON, E. R. (Ed.). **SeaWiFS technical report series**. Greenbelt, MD: NASA Goddard Space Flight Center, 1995.

ANDRADE, C.; BERNARDO, N.; CARMO, A.; ALCÂNTARA, E.; KAMPEL, M. Assessment of quasi-analytical algorithm for estimating the inherent optical properties in a complex cascade system. **Journal of Applied Remote Sensing**, v. 12, e036014, 2018.

ANSPER, A.; ALIKAS, K. Retrieval of chlorophyll a from Sentinel-2 MSI data for European Union Water Framework Directive Reporting Purposes. **Remote Sensing**, v. 11, n. 64, p. 1-26, 2019.

ARCEIVALA, S. J. **Wastewater treatment and disposal: eEngineering and ecology in pollution control**. New York: Marcel Dekker, 1981. 892 p.

AUGUSTO-SILVA, P.B.; OGASHAWARA, I.; BARBOSA, C.C.; CARVALHO, L.A.S.; JORGE, D.S.F.; FORNARI, C.I.; STECH, J. Analysis of MERIS reflectance algorithms for estimating chlorophyll-a concentration in a Brazilian reservoir. **Remote Sensing**, v. 6, p. 11689–11707, 2014.

AZEVEDO, S.M.F.O.; VASCONCELOS, V.M. Toxinas de cianobactérias: causas e consequências para a saúde pública. In: ZAGATTO, P. A.; BERTOLETTI, E. (Ed.). **Ecotoxicologia aquática: princípios e aplicações**. São Carlos: RiMa, 2006.

BABAN, S. M. J. Trophic classification and ecosystem checking of lakes using remotely sensed information. **Hydrological Sciences Journal**, v. 41, n. 6, p. 939–957, 1996.

BARBOSA, C. C. F. **Sensoriamento remoto da dinâmica de circulação da água do sistema planície de Curai/Rio Amazonas**. 2005. 286p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005.

BARBOSA, C. C. F.; NOVO, E. M. L. M.; MARTINS, V. S. **Introdução ao sensoriamento remoto de sistemas aquáticos: princípios e aplicações**. São José dos Campos: INPE, 2019. 161p.

BERNARDO, N.; WATANABE, F.; RODRIGUES, T.; ALCANTARA, E. Atmospheric correction issues for retrieving total suspended matter concentrations in inland waters using OLI/Landsat-8 image. **Advances in Space Research**, v. 59, p. 2335–2348, 2017.

BINDINGS, C. E.; GREENBERG, T. A.; JEROME, J. H.; BUKATA, R. P.; LETOURNEAU, G. An assessment of MERIS algal products during an intense bloom in Lake of the Woods. **Journal of Plankton Research**, v. 33, n. 5, p. 793–806, 2011.

BRANCO, S. M.; ROCHA, A. A. **Poluição, proteção e usos múltiplos de represas**. São Paulo: Edgard Blucher, 1977. 185p.

BRIVIO, P. A.; GIARDINO, C.; ZILIOLI, E. Determination of chlorophyll concentration changes in Lake Garda using an image-based radiative transfer code for Landsat TM images. **International Journal of Remote Sensing**, v. 22, p. 487–502, 2001.

BUDDS, J.; TEIXEIRA, P. S. Ensuring the right to the city: pro-poor housing, urban development and tenure legalization in São Paulo, Brazil. **Environment and Urbanization**, v. 17, n. 1, p. 89–113, 2005.

CAIRO, C. T. **Caracterização temporal das propriedades bio-ópticas do reservatório de Ibitinga/SP**. 2015. 147p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2015.

CAIRO, C. T.; BARBOSA, C. C. F.; NOVO, E. M. L. M.; CALIJURI, M. C. Spatial and seasonal variation in diffuse attenuation coefficients of downward irradiance at Ibitinga Reservoir, São Paulo, Brazil. **Hydrobiologia**, v. 784, n. 1, p. 265-282, 2017.

CAIRO, C.; BARBOSA, C.; LOBO, F.; NOVO, E.; CARLOS, F.; MACIEL, D.; FLORES JÚNIOR, R.; SILVA, E.; CURTARELLI, V. Hybrid chlorophyll-a algorithm for assessing trophic states of a tropical brazilian reservoir based on MSI/Sentinel-2 data. **Remote Sensing**, v. 12, n. 40, 2020.

CAMPANHA, M. B.; AWAN, A. T.; SOUSA, D. N.; GROSSELI, G. M.; MOZETO, A. A.; FADINI, P. S. A 3-year study on occurrence of emerging contaminants in an urban stream of São Paulo State of Southeast Brazil. **Environmental Science and Pollution Research**, v. 22, n. 10, p. 7936-7947, 2015.

CAMPBELL, D.; HURRY, V.; CLARKE, A. K.; GUSTAFSSON, P.; OQUIST G. Chlorophyll fluorescence analysis of cyanobacterial photosynthesis and acclimation. **Microbiology and Molecular Biology Reviews**, v. 62, n. 3, p. 667- 683, 1998.

CANASAT. **Dados da área cultivada com cana-de-açúcar no Estado de São Paulo**. Disponível em: <<http://www.dsr.inpe.br/laf/canasat/tabelas.html>>. Acesso em: 22 nov 2017.

CARDER, K. L.; CHEN, F. R., LEE, Z. P.; HAWES, S. K. Semianalytic moderate-resolution imaging spectrometer algorithms for chlorophyll a and absorption with biooptical domains based on nitrate-depletion temperatures. **Journal of Geophysical Research**, v. 104, p. 5403-5421, 1999.

CARLOS, F. M.; MARTINS, V. S.; BARBOSA, C. C. F. Sistema semi-automático de correção atmosférica para multi-sensores orbitais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos. **Anais...** São José dos Campos: INPE, 2019. Disponível em: < <https://proceedings.science/sbsr-2019/papers/sistema-semi-automatico-de-correcao-atmosferica-para-multi-sensores-orbitais> >. Acesso em: 06 jun. 2019.

CARLSON, R.E. A trophic state index for lakes. **Limnology and Oceanography**, v. 22, p. 361–369, 1977.

CHORUS, I.; BARTRAM, J. **Toxic cyanobacteria in water: a guide to their public health consequences, monitoring, and management.** [S.l.]: Taylor & Francis, 1999.

CLARK, D.K. **MODIS algorithm theoretical basis document: bio-optical algorithms – case 1 waters, version 1.2.** Washington, DC: NOAA, 1997.

COMITÊ DA BACIA HIDROGRÁFICA DO TIETÊ-JACARÉ – CBH-TJ. **Relatório de situação dos recursos hídricos 2016.** UGRHI 13 – Bacia Hidrográfica Tietê-Jacaré: ano base 2015. São Paulo, 2016. Disponível em: <<http://www.sigrh.sp.gov.br/public/uploads/documents/CBH-TJ/11832/2016-12-12-relatorio-situacao-ugrhi13.pdf>>. Acesso em: 17 jan. 2019.

COMITÊ DA BACIA HIDROGRÁFICA DO TIETÊ-JACARÉ – CBH-TJ. **Relatório de situação dos recursos hídricos 2018.** UGRHI 13 – Bacia Hidrográfica Tietê-Jacaré: ano Base 2017. São Paulo, 2018. Disponível em: <<http://www.sigrh.sp.gov.br/public/uploads/documents/CBH-TJ/13920/relatorio-situacao-2018.pdf>>. Acesso em: 17 jan. 2019.

COMPANHIA AMBIENTAL DO ESTADO DE SÃO PAULO – CETESB. **Relatório de qualidade das águas interiores do Estado de São Paulo: apêndice D – índices de qualidade da água.** São Paulo: CETESB, 2017. Disponível em: <https://cetesb.sp.gov.br/aguas-interiores/wp-content/uploads/sites/12/2018/06/Appendice-D-%C3%8Dndices-de-Qualidade-das-%C3%81guas.pdf>. Acesso em: 07 jun. 2019.

COMPANHIA AMBIENTAL DO ESTADO DE SÃO PAULO – CETESB. **Resumo executivo: relatório de qualidade das águas interiores no Estado de São Paulo – 2018.** Disponível em: <<https://cetesb.sp.gov.br/aguas-interiores/wp-content/uploads/sites/12/2019/07/Resumo-Executivo-Relatorio-de-Qualidade-das-%C3%81guas-Interiores-no-Estado-de-S%C3%A3o-Paulo-2018.pdf>>. Acesso em: 30 jul. 2019.

CUNHA, D. G. F.; CALIJURI, M. C.; LAMPARELLI, M. C. A trophic state index for tropical/subtropical reservoirs (TSEtsr). **Ecological Engineering**, v. 60, p. 126-134, 2013.

DALL'OLMO, G.; GITELSON, A. A.; RUNDQUIST, D. C. Towards a unified approach for remote estimation of chlorophyll-a in both terrestrial vegetation and turbid productive waters. **Geophysical Research Letters**, v. 30, n. 18, 2003.

DODDS, W.K. Trophic state, eutrophication and nutrient criteria in streams. **Trends in Ecology and Evolution**, v. 22, p. 669–676, 2007.

DUPOUY, C.; NEVEUS J.; DIRBERG, G.; ROTTGERS, R.; OUILLO, S. Bio-optical properties of the marine cyanobacteria *Trichodesmium* spp. **Journal of Applied Remote Sensing**, v. 2, n. 1, p. 1-17, 2008.

EMPINOTTI, V. L.; BUDDS, J.; AVERSA, M. Governance and water security: the role of the water institutional framework in the 2013–15 water crisis in São Paulo, Brazil. **Geoforum**, v. 98, p. 46-54, 2019.

ESTEVEZ, F. A. **Fundamentos de limnologia**. 2.ed. Rio de Janeiro: Interciência, 1998. 602 p.

EUROPEAN SPACE AGENCY - ESA. **Sentinel-2 Spectral Response Functions (S2-SRF)**. Disponível em: https://earth.esa.int/web/sentinel/user-guides/sentinel-2-msi/document-library/-/asset_publisher/Wk0TKajiISaR/content/sentinel-2a-spectral-responses. Acesso em: 13 out. 2018.

EUROPEAN SPACE AGENCY - ESA. **Resolutions**. Disponível em: <https://earth.esa.int/web/sentinel/user-guides/sentinel-2-msi/resolutions>. Acesso em: 20 ago. 2019.

FENG, H.; CAMPBELL, J. W.; DOWELL, M. D.; MOORE, T. S. Modeling spectral reflectance of optically complex waters using bio-optical measurements from Tokyo Bay. **Remote Sensing of Environment**, v. 99, p. 232-243, 2005.

FIA, R.; MATOS, A. T.; CORADI, P. C.; PEREIRA-RAMIREZ, O. Estado trófico da água na bacia hidrográfica da Lagoa Mirim, RS, Brasil. **Revista Ambiente & Água**, v. 4, n. 1, p. 132-141, 2009.

FILOSO, S.; MARTINELLI, L. A.; WILLIAMS, M. R.; LARA, L. B.; KRUSCHE, A.; BALLESTER, M. V.; CAMARGO, P. B. Land use and nitrogen export in the Piracicaba River Basin, Southeast Brazil. **Biogeochemistry**, v. 65, n. 3, p. 275–294, 2003.

FLORES JUNIOR, R.; MACIEL, D. A.; CAIRO, C. T.; CARLOS, F. M.; LOBO, F. L.; SANDER DE CARVALHO, L.; NOVO, E. M. L. M.; BARBOSA, C. C. F. Assessment of satellite algorithms for deriving chlorophyll-a from turbid waters of amazon floodplain lakes. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019, Santos. **Anais...** São José dos Campos: INPE, 2019. Disponível em: < <https://proceedings.science/sbsr-2019/papers/assessment-of-satellite-algorithms-for-deriving-chlorophyll-a-from-turbid-waters-of-amazon-floodplain-lakes> >. Acesso em: 06 jun. 2019.

GIARDINO, C.; BRANDO, V. E.; GEGER, P.; PINNEL, N.; HOCHBERG, E.; KNAEPS, E.; REUSEN, I.; DOERFFER, R.; BRESCIANI, M.; BRAGA, F. Imaging spectrometry of inland and coastal waters: state of the art, achievements and perspectives. **Surveys in Geophysics**, v. 40, p. 401–429, 2019.

GILERSON, A.; GITELSON, A.; ZHOU, J.; GULRIN, D.; MOSES, W.; IOANNOU, I.; AHMED, S. Algorithms for remote sensing of chlorophyll-a in coastal and inland waters using red and near infrared bands. **Optics Express**, v. 18, n. 23, p. 24109–24125, 2010.

GITELSON, A. The peak near 700 nm on reflectance spectra of algae and water: relationships of its magnitude and position with chlorophyll concentration. **International Journal of Remote Sensing**, v. 13, p. 3367–73, 1992.

GITELSON, A. A.; DALL'OLMO, G.; MOSES, W.; RUNDQUIST, D.C.; BARROW, T.; FISHER, T. R. A simple semi-analytical model for remote estimation of chlorophyll-a in turbid waters: validation. **Remote Sensing of Environment**, v. 112, p. 3582–3593, 2008.

GITELSON, A.; GURLIN, D.; MOSES, W. J.; BARROW, T. A bio-optical algorithm for the remote estimation of the chlorophyll-a concentration in case 2 waters. **Environmental Research Letters**, v. 4, p. 1 – 5, 2009.

GITELSON, A.; GAO, B. -C.; LI, R. -R.; BERDNIKOV, S.; SAPRYGIN, V. Estimation of chlorophyll-a concentration in productive turbid waters using a hyperspectral imager for the coastal ocean: the Azov Sea case study. **Environmental Research Letters**, v. 6, p. 1-6, 2011a.

GITELSON, A. A.; GURLIN, D.; MOSES, W. J.; YACOBI, Y. Z. Remote estimation of chlorophyll-a concentration in inland, estuarine and coastal waters. In: WENG, Q. (Ed). **Advances in environmental remote sensing: sensors, algorithms, and applications**. [S.l.]: CRC Press, 2011b. p. 439-468.

GÓMEZ, J. A. D.; ALONSO, C. A.; GARCÍA, A. A. Remote sensing as a tool for monitoring water quality parameters for Mediterranean Lakes of European Union water framework directive (WFD) and as a system of surveillance of cyanobacterial harmful algae blooms (SCyanoHABs). **Environmental Monitoring and Assessment**, v. 181, p. 317-334, 2011.

GONS, H. J., AUER, M. T., EFFLER, S. W. MERIS satellite chlorophyll mapping of oligotrophic and eutrophic waters in the Laurentian Great Lakes. **Remote Sensing of Environment**, v. 112, n. 11, p. 4098–4106, 2008.

GOWER, J. F. R.; DOERFFER, R.; BORSTAD, G. A. Interpretation of the 685nm peak in water-leaving radiance spectra in terms of fluorescence, absorption and scattering, and its observation by MERIS. **International Journal of Remote Sensing**, v. 20, n. 9, p. 1771–1786, 1999.

GOWER, J. F. R.; KING, S.; YAN, W.; BORSTAD, G.; BROWN, L. Use of the 709 nm band of MERIS to detect intense plankton blooms and other conditions in coastal waters. In: MERIS USER WORKSHOP, 2003, Frascati, Italy. **Proceedings...** 2003.

GOWER, J.; KING, S.; BORSTAD, G.; BROWN, L. Detection of intense plankton blooms using the 709 nm band of the MERIS imaging spectrometer. **International Journal of Remote Sensing**, v. 26, n. 9, p. 2005-2012, 2005.

GUIMARÃES JUNIOR, C.; LEOPOLDO, P. R.; CRUZ, J. A.; FONTANA, S. C. Aspectos limnológicos do reservatório de Ibitinga - SP. **RBRH - Revista Brasileira de Recursos Hídricos**, v. 13, n. 1, p. 89-103, 1998.

GURLIN, D.; GITELSON, A. A.; MOSES, W. J. Remote estimation of Chl-a concentration in turbid productive waters – return to a simple two-band NIR–red model? **Remote Sensing of Environment**, v. 115, n. 12, p. 3479–3490, 2011.

HA, N.T.T.; THAO, N.T.P.; KOIKE, K.; NHUAN, M.T. Selecting the best band ration to estimate chlorophyll-a concentration in a tropical freshwater lake using Sentinel 2A images from a case study of Lake Ba Be (Northern Vietnam). **ISPRS International Journal of Geo-Information**, v. 6, n. 290, 2017.

HORION, S.; BERGAMINO, N.; STENUITE, S.; DESCY, J. P.; PLISNIER, P. D.; LOISELLE, S. A.; CORNET, Y. Optimized extraction of daily bio-optical time series derived from MODIS/Aqua imagery for Lake Tanganyika, Africa. **Remote Sensing of Environment**, v. 114, n. 4, p. 781–791, 2010.

HU, C.; LEE, Z.; FRANZ, B. Chlorophyll a algorithms for oligotrophic oceans: a novel approach based on three-band reflectance difference. **Journal of Geophysical Research Oceans**, v. 117, p. 1–25, 2012.

HUOT, Y.; BABIN, M. Overview of fluorescence protocols: theory, basic concepts, and practice. In: SUGGETT, D. J.; PRÁŠIL, O.; BOROWITZKA, M.A. (Ed.). **Chlorophyll a fluorescence in aquatic sciences: methods and applications**. Dordrecht, The Netherlands: Springer, 2010. 323 p.

JOHNSEN, G.; SAKSHAUG, E. Biooptical characteristics of PSII and PSI in 33 species (13 pigment groups) of marine phytoplankton, and the relevance for pulse-amplitude-modulated and fast-repetition-rate fluorometry. **Journal of Phycology**, v. 43, n. 6, p. 1236-1251, 2007.

JORGE, D. S. F.; BARBOSA, C. C. F.; CARVALHO, L. A. S.; AFFONSO, A. G.; LOBO, F. L.; NOVO, E. M. L. M. SNR (signal-to-noise ratio) impact on water constituent retrieval from simulated images of optically complex Amazon lakes. **Remote Sensing**, v. 9, p. 1–18, 2017.

KIRK, J. T. O. **Light and photosynthesis in aquatic ecosystems**. 3 ed. Cambridge: Cambridge University Press, 2011. 528p.

KRUSE, F. A.; LEFKOFF, A. B.; DIETZ, J. B. Expert system-based mineral mapping in Northern Death Valley, California/Nevada, using the Airbone Visible/Infrared Imaging Spectrometer (AVIRIS). **Remote Sensing of Environment**, v. 44, p. 309-336, 1993.

KUTSER, T.; ARST, H.; MILLER, T.; KÄÄRMANN, L.; MILIUS, A. Telespectrometrical estimation of water transparency, chlorophyll-a and total phosphorus concentration of Lake Peipsi. **International Journal of Remote Sensing**, v. 16, n. 16, p. 3069–3085, 1995.

KUTSER, T.; VAHTMÄE, E.; PAAVEL, B. E KAUER, T. Removing glint effects from field radiometry data measured in optically complex coastal and inland Waters. **Remote Sensing of Environment**, v. 133, p. 85-89, 2013.

LAMPARELLI, M.C. **Graus de trofia em corpos d'água do estado de São Paulo: avaliação dos metodos de monitoramento.** Tese de (Doutorado em Ecologia Aplicada) - Universidade de São Paulo (USP), São Paulo, 2004.

LE, C.; LI, Y.; ZHA, Y.; SUN, D.; HUANG, C.; ZHANG, H. Remote estimation of chlorophyll a in optically complex waters based on optical classification. **Remote Sensing of Environment**, v. 115, p. 725-737, 2011.

LE, C.; HU, C.; ENGLISH, D.; CANNIZZARO, J.; KOVACH, C. Climate driven chlorophyll-a changes in a turbid estuary: observations from satellites and implications for management. **Remote Sensing of Environment**, v. 130, p.11-24, 2013a.

LE, C.; HU, C.; CANNIZZARO, J.; DUAN, H. Long-term distribution patterns of remotely sensed water quality parameters in Chesapeake Bay. **Estuarine Coastal and Shelf Science**, v. 128, p. 93–103, 2013b.

LEE, Z.; CARDER, K.L.; ARNONE, R.A. Deriving inherent optical properties from water color: a multiband quasi-analytical model for optically deep waters. **Applied Optics**, v. 41, n. 27, p. 5755-5772, 2002.

LINS, R.C.; MARTINEZ, J.-M.; MARQUES, D.M.; CIRILO, J.A.; FRAGOSO JUNIOR, R. Assessment of chlorophyll-a remote sensing algorithms in a productive tropical estuarine-lagoon system. **Remote Sensing**, v. 9, n. 516, 2017.

LIU, G.; LI, L.; SONG, K.; LI, Y.; LYU, H.; WEN, Z.; FANG, C.; BI, S.; SUN, X.; WANG, Z.; CAO, Z.; SHANG, Y.; YU, G.; ZHENG, Z.; HUANG, C.; XU, Y.; SHI, K. An OLCI-based algorithm for semi-empirically partitioning absorption coefficient and estimating chlorophyll *a* concentration in various turbid case-2 waters. **Remote Sensing of Environment**, v. 239, e111648, 2020.

LONDE, L. R. **Comportamento espectral do fitoplâncton de um reservatório brasileiro eutrofizado - Ibitinga/SP.** 2008. 223p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2008.

LONDE, L. R.; NOVO, E. M. L. M.; BARBOSA, C.; ARAUJO, C. A. S. Water residence time affecting phytoplankton blooms: study case in Ibitinga Reservoir (São Paulo, Brazil) using Landsat/TM images. **Brazilian Journal of Biology**, n. 76, p. 664–672, 2016.

LUBAC, B.; LOISEL, H. Variability and classification of remote sensing reflectance spectra in the eastern English Channel and southern North Sea. **Remote Sensing of Environment**, v. 110, p. 45-58, 2007.

LUZIA, A. P. **Estrutura organizacional do fitoplâncton nos sistemas lóticos e lênticos da bacia do Tietê/Jacaré (UGRHI-Tietê-Jacaré) em relação à qualidade da água e estado trófico**. 2009. 186p. Tese (Doutorado em Ciências Biológicas) - Universidade de São Paulo, São Carlos, 2009.

MACIEL, D.; NOVO, E.; SANDER DE CARVALHO, L.; BABOSA, C.; FLORES JÚNIOR, R.; LOBO, F.L. Retrieving total and inorganic suspended sediments in Amazon floodplain lakes: a multisensory approach. **Remote Sensing**, v. 11, n. 1744, 2019.

MAIA, A. A. D.; CARVALHO, S. L.; CARVALHO, F. T. Comparação de dois índices de determinação do grau de trofia nas águas do Baixo Rio São José dos Dourados, São Paulo, Brasil. **Engenharia Sanitária Ambiental**, v. 20, n. 4, p. 613-622, 2015.

MAKRIDAKIS, S. Accuracy concerns measures : theoretical and practical concerns. **International Journal of Forecasting**, v. 9, p. 527–529, 1993.

MARGALEF, R. Typology of reservoirs. **Verhandlungen des Internationalen Verein Limnologie**, v. 19, p. 1841–1848, 1975.

MARTINELLI, L. A.; FILOSO, S. Expansion of sugarcane ethanol production in Brazil: environmental and social challenges. **Ecological Applications**, v. 18, n. 4, p. 885–898, 2008.

MARTINS, V. S.; BARBOSA, C. C. F.; CARVALHO, L. A. S.; JORGE, D. S. F.; LOBO, F. L.; NOVO, E. M. L. M. Assessment of atmospheric correction methods for sentinel-2 MSI images applied to Amazon floodplain lakes. **Remote Sensing**, v. 9, 2017.

MATSUSHITA, B. M.; YANG, W.; YU, G.; OYAMA, Y.; YOSHIMURA, K. E FUKUSHIMA, T. A hybrid algorithm for estimating the chlorophyll-a concentration across different trophic states in Asian inland waters. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 28-37, 2015.

MATTHEWS, M. W. A current review of empirical procedures of remote sensing in inland and near-coastal transitional waters. **International Journal of Remote Sensing**, v. 32, n. 21, p. 6855–6899, 2011.

MATTHEWS, M. W.; BERNARD, S.; ROBERTSON, L. An algorithm for detecting trophic status (chlorophyll-a), cyanobacterial- dominance, surface scums and floating vegetation in inland and coastal waters. **Remote Sensing of Environment**, v. 124, p. 637-652, 2012.

MATTHEWS, M. W. Bio-optical modeling of phytoplankton chlorophyll-a. In: MISHRA, D. R.; OGASHAWARA, I.; GITELSON, A. A. (Ed.). **Bio-optical modeling and remote sensing of inland waters**. [S.l.]: Elsevier, 2017. p. 157-188.

MILTON, E.J. Principles of field spectroscopy. **International Journal of Remote Sensing**, v.8, n.12, p. 1807-1927, 1987.

MISHRA, D. R.; MISHRA, S. Plume and bloom: effect of the Mississippi River diversion on the water quality of Lake Pontchartrain. **Geocarto International**, v. 25, n. 7, p. 555-568, 2010.

MISHRA, S.; MISHRA, D. R. Normalized difference chlorophyll index: a novel model for remote estimation of chlorophyll-a concentration in turbid productive waters. **Remote Sensing of Environment**, v. 117, p. 394-406, 2012.

MOBLEY, C. D. **Light and water: radiative transfer in natural waters**. [S.l.]: Academic Press, 1994. 593p.

MOBLEY, C. D. Estimation of the remote-sensing reflectance from above-surface measurements. **Applied Optics**, v. 38, n. 36, p. 7442–7455, 1999.

MOBLEY, C. D. Polarized reflectance and transmittance properties of windblown sea surfaces. **Applied Optics**, v. 54, n. 15, p. 4828-4849, 2015.

MOORE, T. S.; DOWELL, M. D.; BRADT, S.; VERDU, A. R. An optical water type framework for selecting and blending retrievals from bio-optical algorithms in lakes and coastal waters. **Remote Sensing of Environment**, v. 143, p. 97-111, 2014.

MOREL, A.; GORDON, H. R. Report of the working group on water color. **Boundary-Layer Meteorology**, v. 18, n. 3, p. 343–355, 1980.

MOUW, C. B. ET AL. Remote sensing of environment aquatic color radiometry remote sensing of coastal and inland waters: challenges and recommendations for future satellite missions. **Remote Sensing of Environment**, v. 160, p. 15– 30, 2015.

MUELLER, J. L.; FARGION, G. S.; MCCLAIN, C. R.; MUELLER, J. L.; MOREL, A.; FROUIN, R.; DAVIS, C.; ARNONE, R.; CARDER, K.; STEWARD, R. G.; HOOKER, S. B.; MOBLEY, C. D.; MCLEAN, S.; HOLBEN, B.; PIETRAS, C.; KNOBELSPIESSE, K. D.; PORTER, J. **Ocean optics protocols for satellite ocean color sensor validation**. [S.l.], 2003. Revision 4, Volume III: Radiometric Measurements and Data Analysis Protocols NASA / TM-2003 - Ocean Optics Protocols For Satellite Ocean Color Sensor Validation(NASA/TM-2003-21621/Rev-Vol III), n. January. Washington: NASA, 2003.

NOVO, E. M. L. M.; LONDE, L. R.; BARBOSA, C.; ARAUJO, C. A. S.; RENNÓ, C. D. Proposal for a remote sensing trophic state index based upon Thematic Mapper/Lansat images. **Revista Ambiente Água**, v. 8, n. 3, 2013.

NUSCH, E. A. Comparison of different methods for chlorophyll and phaeopigment determination. **Archiv fur Hydrobiologie**, v.14, p. 14-36, 1980.

ODERMATT, D.; GITELSON, A.; BRANDO, V.E. E SCHAEPMAN, M. Review of constituent retrieval in optically deep and complex waters from satellite imagery. **Remote Sensing of Environment**, v. 118, p. 116–126, 2012.

OLEM, H.; FLOCK, G. **Lake and reservoir restoration guidance manual**. 2.ed. Washington DC: North American Lake Management Society, 1990.

ONDA, K.; LOBUGLIO, J.; BARTRAM, J. Global access to safe water: accounting for water quality and the resulting impact on MDG progress. **International Journal of Environment Research and Public Health**, n. 9, p. 880–894, 2012.

OCEAN OPTICS WEB BOOK - OOWB. **Atmosferic correction: normalized reflectances**. 2020. Disponível em: <http://www.oceanopticsbook.info/view/atmospheric_correction/normalized_reflectances>. Acesso em: 28 abr. 2020.

O'REILLY, J., MARITORENA, S., MITCHELL, G., et al. Ocean color chlorophyll algorithms for SeaWiFS. **Journal of Geophysical Research**, v. 103, n. C11, p. 24937–24–953, 1998.

O'REILLY, J. E.; MARITORENA, S.; SIEGEL, D. A.; O'BRIEN, M. C.; TOOLE, D.; MITCHELL, B. G.; KAHRU, M.; CHAVEZ, F.P.; STRUTTON, P.; COTA, G. F. Ocean color chlorophyll a algorithms for SeaWiFS, OC2, and OC4: version 4. In: TOOLE, D. et al. (Ed.). **SeaWiFS postlaunch calibration and validation analyses: part 3**. Greenbelt, Maryland: NASA, Goddard Space Flight Center 2000. p. 9–23.

PALMER, S.C.J.; KUTSER, T.; HUNTER, P.D. Remote sensing of inland waters: challenges, progress and future directions. **Remote Sensing of Environment**, v. 157, p. 1–8, 2015.

RANDOLF, K.; WILSON, J.; TEDESCO, L.; LI, L.; PASCUAL, D.L.; SOYEUX, E. Hyperspectral remote sensing of cyanobacteria in turbid productive water using optically active pigments, chlorophyll a and phycocyanin. **Remote Sensing of Environment**, v. 112, p. 4009–4019, 2008.

REYNOLDS, C. S. **Ecology of phytoplankton**. Cambridge: Cambridge University Press, 2006. 535p.

REYNOLDS, C. S.; WALSBY, A. E. Water-blooms. **Biological Reviews**, v. 50, p. 437–481, 1975.

RIGOSI, A.; CAREY, C.C.; IBELINGS, B.W.; BROOKES, J.D. The interaction between climate warming and eutrophication to promote cyanobacteria is dependent on trophic state and varies among taxa. **Limnology and Oceanography**, v. 59, p. 99–114, 2014.

RUDORFF, B. F. T.; AGUIAR, D. A.; SILVA, W. F.; SUGAWARA, L. M.; ADAMI, M.; MOREIRA, M. A. Studies on the rapid expansion of sugarcane for ethanol production in São Paulo State (Brazil) using Landsat data. **Remote Sensing**, n. 2, v. 4, p. 1057–1076, 2010.

SALAS, H. J.; MARTINO, P. A simplified phosphorus trophic state model for warm-water tropical lakes. **Water Research**, v. 25, n. 3, p. 341-350, 1991.

SANDER DE CARVALHO, L. A.; BARBOSA, C. C. F.; LOBO, F. L.; NOVO, E. M. L. M. Comparison for chlorophyll-a remote sensing retrieval algorithms based on standard laboratory procedures and on in-situ absorption measurements. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., 2019, Santos. **Anais...** São José dos Campos: INPE, 2019. Disponível em: <<https://proceedings.science/sbsr-2019/papers/comparison-for-chlorophyll--a-remote-sensing-retrieval-algorithms-based-on-standard-laboratory-procedures-and-on-in-situ>>. Acesso em: 06 jun. 2019.

SASS, G. Z.; CREED, I. F.; BAYLEY, S. E.; DEVITO, K. J. Understanding variation in trophic status of lakes on the Boreal Plain: a 20-year retrospective using Landsat TM imagery. **Remote Sensing of Environment**, v. 109, p. 127–141, 2007.

SATHYENDRANATH, S.; LAZZARA, L.; PRIEUR, L. Variations in the spectral values of specific absorption of phytoplankton. **Limnology and Oceanography**, v. 32, n. 2, p. 403-415, 1987.

SIMIS, S. G. H.; HUOT, Y.; BABIN, M.; SEPPALA, J.; METSAMAA, L. Optimization of variable fluorescence measurements of phytoplankton communities with cyanobacteria. **Photosynthesis Research**, v. 112, n. 1, p. 13-30, 2012.

SINHA, E.; MICHALAK, A. M.; BALAJI, V. Eutrophication will increase during the 21st century as a result of precipitation changes. **Science**, v. 357, n. 6349, p. 405-408, 2017.

SISTEMA INTEGRADO DE GERENCIAMENTO DE RECURSOS HÍDRICOS DO ESTADO DE SÃO PAULO (SIGRH). **Comitê da bacia hidrográfica Tietê-Jacaré - apresentação**. Disponível em: <<http://www.sigrh.sp.gov.br/cbhtj/apresentacao>>. Acesso em: 24 dez. 2014.

SHI, K.; LI, Y.; LI, L.; LU, H.; SONG, K.; LIU, Z.; XU, Y.; LI, Z. Remote chlorophyll-a estimates for inland waters based on a cluster-based classification. **Science of the Total Environment**, v. 444, p. 1-15, 2013.

SMITH, M. E.; ROBERTSON LAIN, L.; BERNARD S. An optimized chlorophyll-a switching algorithm for MERIS and OLCI in phytoplankton-dominated waters. **Remote Sensing of Environment**, v. 215, p. 217-227, 2018.

SVENSEN, Ø.; FRETTE, Ø.; ERGA, S. R. Scattering properties of microalgae: the effect of cell size and cell wall. **Applied Optics**, v. 46, p. 5762-5769, 2007.

TAN, P. N.; STEINBACH, M.; KUMAR, V. **Introduction to datamining**. Boston: Pearson Addison Wesley, 2006. 900 p.

TANRE, D.; HERMAN, M.; DESCHAMPS, P. Y. Influence of the background contribution upon space measurements of ground reflectance. **Applied Optics**, v. 20, p. 3676–3684, 1981.

THIEMANN, S.; KAUFMANN, H. Determination of chlorophyll content and trophic state of lakes using field spectrometer and IRS-1C satellite data in the Mecklenburg Lake District, Germany. **Remote Sensing of Environment**, v. 73, p. 227–235, 2000.

THOMANN, R. V.; MUELLER, J. A. **Principles of surface water quality modeling and control**. [S.l.]: Harper International, 1987. 644 p.

TILSTONE, G. H.; PETERS, S.W.M.; VAN DER WOERD, H.J.; ELEVELD, M.A.; RUDDICK, K.; SCHONFELD, W. Variability in specific-absorption properties and their use in a semi-analytical ocean colour algorithm for MERIS in North Sea and Western English Channel coastal waters. **Remote Sensing of Environment**, v. 118, p. 320–38, 2012.

TOLEDO, A. P.; TALARICO, M.; CHINEZ, S. J.; AGUDO, E. G. A aplicação de modelos simplificados para a avaliação de processo da eutrofização em lagos e reservatórios tropicais. In: CONGRESSO BRASILEIRO DE ENGENHARIA SANITÁRIA, 12., 1983. **Anais...** Camboriú, SC: Associação Brasileira de Engenharia Sanitária, 1983.

TOLEDO, A. P.; AGUDO, E. G.; TALARICO, M.; CHINEZ, S. J. A aplicação de modelos simplificados para a avaliação de processo da eutrofização em lagos e reservatórios tropicais. In: CONGRESSO INTERAMERICANO DE ENGENHARIA SANITÁRIA AMBIENTAL (AIDIS), 19., 1984, Santiago, Chile. **Anais...** 1984.

TOLEDO, A. P. **Informe preliminar sobre os estudos para a obtenção de um índice para a avaliação do estado trófico de reservatórios em regiões quentes tropicais**. São Paulo: Companhia de Tecnologia de Saneamento Ambiental, 1990. 12p. (Relatório interno CETESB).

TUNDISI, J.G. Reservatórios como sistemas complexos: teoria, aplicações e perspectivas para usos múltiplos. In: HENRY, R. (Ed.). **Ecologia de reservatórios: estrutura, função e aspectos sociais**. Botucatu, Brasil: FUNDBIO, 1999.

TUNDISI, J. G.; MATSUMURA-TUNIDSI, T.; PARESCHI, D. C.; LUZIA, A. P.; VON HAELING, P. H.; FROLLINI, E. H. A bacia hidrográfica do Tietê/Jacaré: estudo de caso em pesquisa e gerenciamento. **Estudos Avançados**, v. 22, n. 63, p. 159-172, 2008.

VERMOTE, E. F.; TANRÉ, D.; DEUZÉ, J. L.; HERMAN, M.; MORCRETTE, J. J. J. Second Simulation of the Satellite Signal in the Solar Spectrum (6S): 6S user guide version 2. appendix III: description of the subroutines. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, p. 675–686, 1997.

VIEIRA, M. S.; FERREIRA, J. R. P.; CASTRO, M. G.; ROCHA, A. A. Aspectos da química da água e do sedimento do reservatório de Ibitinga (São Paulo- Brasil - 21° 45' S e 48° 50' W). **Boletim do Instituto de Pesca, São Paulo**, v. 28, n. 1, p. 77-91, 2002.

VOLLENWEIDER, R. A. **Scientific fundamentals of the eutrophication of lakes and flowing waters, with particular reference to nitrogen and phosphorus as factors in eutrophication**. Paris: UNESCO, 1968. (OECD Technical Report, DAS/CSI/68).

VON SPERLING, E. Avaliação do estado trófico de lagos e reservatórios tropicais. **Bio Engenharia Sanitária e Ambiental**, v.3, p. 68-76, 1994.

VON SPERLING, M. **Introdução à qualidade das águas e ao tratamento de esgotos**. 3.ed. Belo Horizonte: Universidade Federal de Minas Gerais, 2005. 452 p.

WANG, M.; SHI, W. The NIR-SWIR combined atmospheric correction approach for MODIS ocean color data processing. **Optics Express**, v. 15, p. 15722–15733, 2007.

WANG, D.; MA, R.; XUE, K.; LOISELLE, S. The assessment of Landsat-8 OLI atmospheric correction algorithms for inland waters. **Remote Sensing**, v. 11, n. 169, 2019.

WATANABE, F.S.Y.; ALCÂNTARA, E.; RODRIGUES, T.W.P.; IMAI, N. N.; BARBOSA, C. C. F.; ROTTA, L. H. S. Estimation of chlorophyll-a concentration and the trophic state of the Barra Bonita Hydroelectric Reservoir using OLI/Landsat-8 images. **International Journal of Environmental Research and Public Health**, v. 12, p. 10391-10417, 2015.

WANG, S.; LI, J.; ZHANG, B.; SPYRAKOS, E.; TYLER, A. N.; SHEN, Q.; ZHANG, F.; KUTSER, T.; LEHMANN, M.K.; WU, Y.; PENG, D. Trophic state assessment of global inland waters using a MODIS-derived Forel-Ule index. **Remote Sensing of Environment**, v. 217, p. 444–460, 2018.

WATANABE, F. S. Y.; ALCÂNTARA, E.; RODRIGUES, T.; ROTTA, L.; BERNARDO, N.; IMAI, N. Remote sensing of the chlorophyll-a based on OLI/Landsat-8 and MSI/Sentinel-2A (Barra Bonita reservoir - Brazil). **Anais da Academia Brasileira de Ciências**, p. 1-14, 2017.

WATANABE, F.; ALCANTARA, E.; IMAI, N.; RODRIGUES, T.; BERNARDO, N. Estimation of chlorophyll-a concentration from optimizing a semi-analytical algorithm in productive inland waters. **Remote Sensing**, v. 10, n. 227, 2018.

WETZEL, R.G. **Limnology: lake and river ecosystems**. 3.ed. Cambridge, MA: Academic Press 2001. 1006p.

WEZERNAK, C. T.; TANIS, F. J.; BAJZA, C. A. Trophic state analysis of inland waters. **Remote Sensing of Environment**, v. 5, p. 147-165, 1976.

WHITMIRE, A.L.; PEGAU, W. S.; KARP-BOSS, L.; BOSS, E.; COWLES, T. J. Spectral backscattering properties of marine phytoplankton cultures. **Optics Express**, v. 18, n. 14, p. 15073-15093, 2010.

WILSON, R. T. Py6S: A Python interface to the 6S radiative transfer model. **Computer and Geosciences**, v. 51, p. 166–171, 2013.

XING, X-G; ZHAO, D-Z; LIU, Y-G; YANG, J-H; XIU, P.; WANG, L. An overview of remote sensing of chlorophyll fluorescence. **Ocean Science Journal**, v. 42, p. 49-59, 2007.

XU, H. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3025-3033, 2006.

YANG, W.; MATSUSHITA, B.; CHEN, J.; FUKUSHIMA, T. Estimating constituent concentrations in case II waters from MERIS satellite data by semi-analytical model optimizing and look-up tables. **Remote Sensing of Environment**, v. 115, p. 1247–1259, 2011.

APÊNDICE A – FIGURAS E TABELAS COMPLEMENTARES

As Figuras A.1 e A.2 complementam o resultado mostrado na Tabela 4.3, a Figura A.3 complementa o resultado mostrado na Tabela 4.4 e a Tabela A.1 complementa o resultado mostrado na Figura 4.15, do tópico dos resultados.

Figura A.1 – Gráficos de dispersão da validação da Monte Carlo para os algoritmos de melhor desempenho do MHL (Tabela 4.3), em cada faixa específica de concentração da chl-a. Os algoritmos são: (A) três bandas do Gitelson et al. (2011a) com ajuste exponencial; (B) NDCI do Mishra e Mishra (2012) com ajuste polinomial; (C) razão B5/B3 com ajuste exponencial e (D) *Slope* do Mishra e Mishra (2010) com ajuste polinomial.

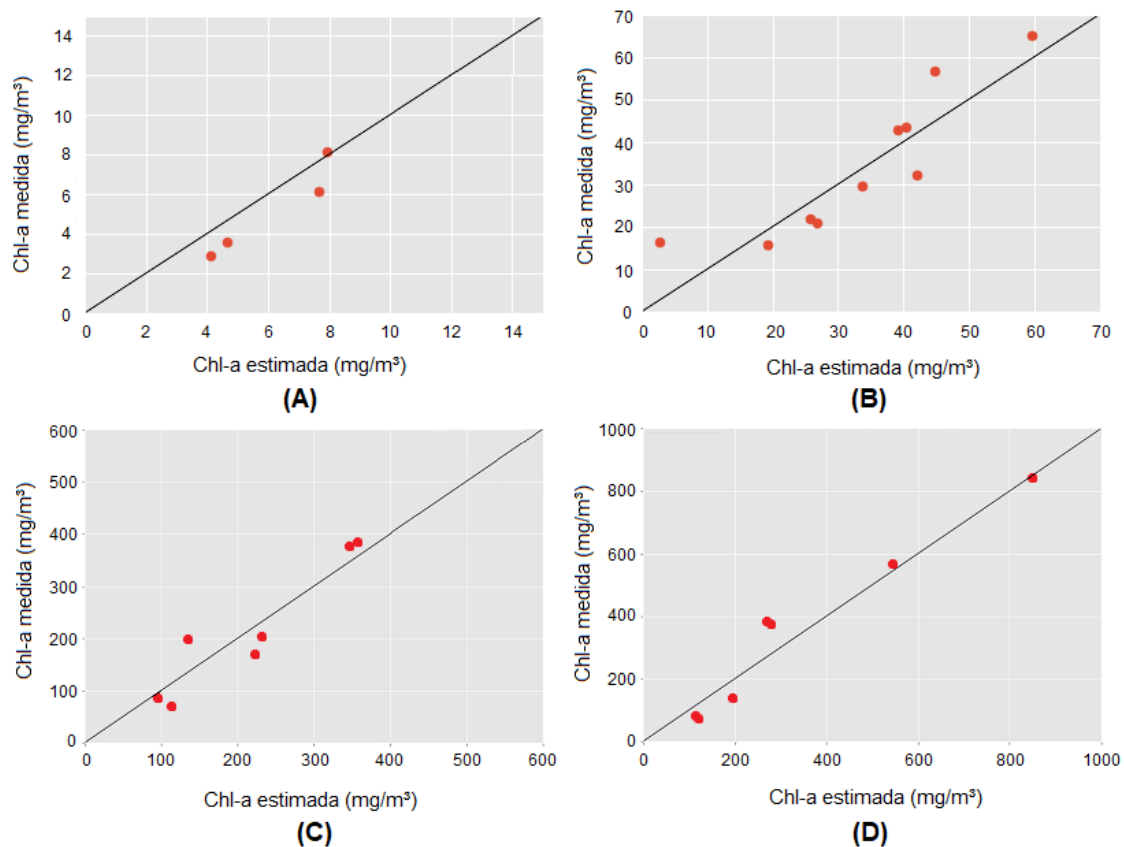


Figura A.2 – Gráficos de dispersão da validação da Monte Carlo para os algoritmos de melhor desempenho do MHO (Tabela 4.3), em cada faixa específica de concentração da chl-*a*. Os algoritmos são: (A) três bandas do Gitelson et al. (2011a) com ajuste linear; (B) *Slope* do Mishra e Mishra (2010) com ajuste exponencial; (C) razão B5/B3 com ajuste exponencial e (D) razão B6/B3 com ajuste polinomial.

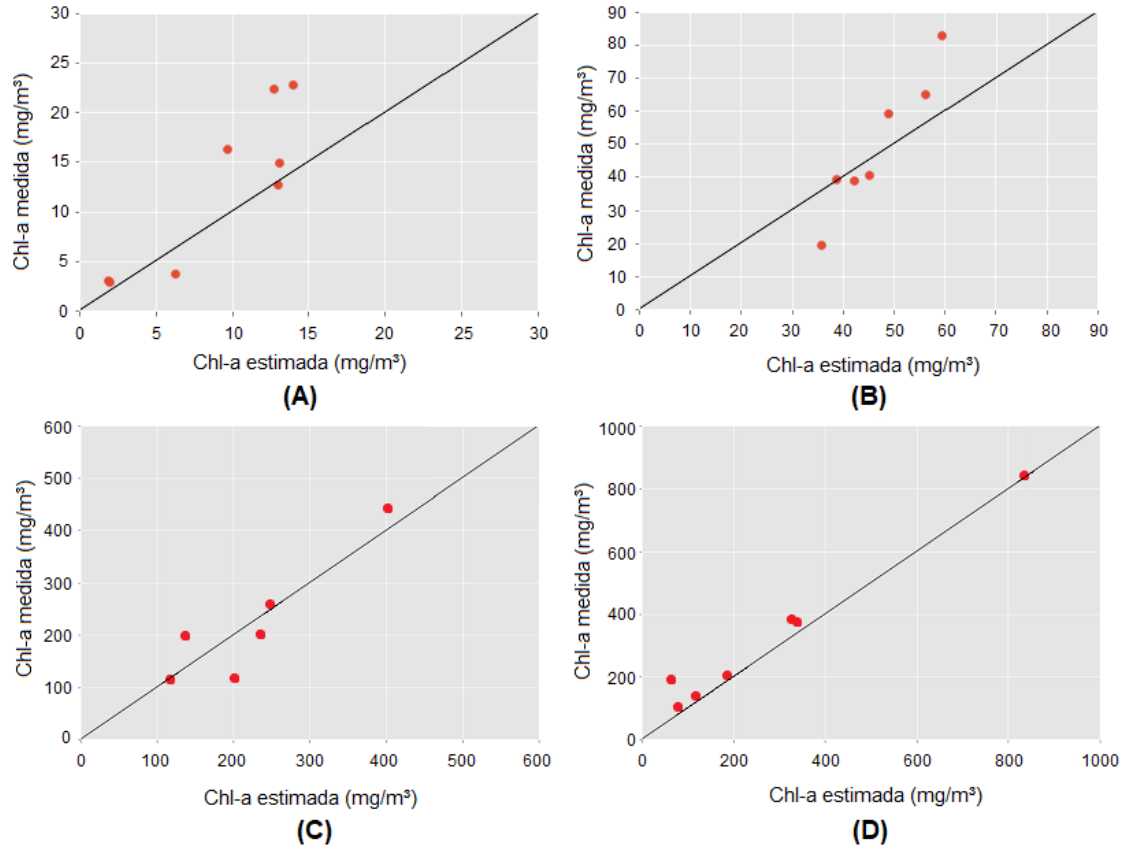


Figura A.3 – Resultado da validação do algoritmo NDCI de Mishra e Mishra (2012) para uma faixa mais ampla de concentração de chl-*a*, até 600 mg/m³. Sendo: MAPE (%), RMSE (mg/m³) e NRMSE (%).




Tabela A.1 – Resultado da validação do MHL e MHO com a imagem MSI/Sentinel-2, considerando as 8 estações amostrais do campo de Agosto/2018. Sendo: MAPE (%), RMSE (mg/m³) e NRMSE (%).

Somente correção atmosférica				
Modelos Híbridos	MAPE	R²	RMSE	NRMSE
MHL_ate600	33,30	0,58	11,47	25,93
MHL_ate1000	33,30	0,58	11,47	25,93
MHO_ate600	32,65	0,32	14,90	33,69
MHO_ate1000	32,65	0,32	14,90	33,69
Com correção atmosférica e correção do glint (B11)				
Modelos Híbridos	MAPE	R²	RMSE	NRMSE
MHL_ate600	34,59	0,58	10,83	24,48
MHL_ate1000	33,99	0,56	10,79	24,40
MHO_ate600	28,32	0,42	12,98	29,35
MHO_ate1000	28,32	0,42	12,98	29,35
Com correção atmosférica e correção do glint (B12)				
Modelos Híbridos	MAPE	R²	RMSE	NRMSE
MHL_ate600	34,26	0,62	10,86	24,54
MHL_ate1000	32,85	0,60	10,72	24,23
MHO_ate600	28,32	0,42	12,98	29,35
MHO_ate1000	28,32	0,42	12,98	29,35

Tabela A.2 – Frequência de imagens por mês do MSI/Sentinel-2 para os anos de 2016 a 2019.

Quantidade de Imagens MSI/Sentinel-2				
Mês	2016	2017	2018	2019
1	1			1
2			2	2
3	1		2	2
4	1	1	2	4
5		1	3	1
6		2	1	5
7		3	1	3
8	1	1	2	4
9	1	3	4	1
10	1	1	2	
11	1	1	1	
12	1		2	