



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21c/2019/03.22.19.03-TDI

**PARAMETRIZAÇÃO DE ALGORITMOS EMPÍRICOS E
ALGORITMO QUASI-ANALÍTICO QAA PARA
ESTIMATIVA DE CLOROFILA-A EM LAGOS DA
VÁRZEA DO RIO AMAZONAS**

Rogério Flores Júnior

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Cláudio Clemente Faria
Barbosa, e Felipe de Lucia Lobo,
aprovada em 14 de março de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3SUQ3U2>>

INPE
São José dos Campos
2019

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 INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):

Presidente:

Dr. 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
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

sid.inpe.br/mtc-m21c/2019/03.22.19.03-TDI

**PARAMETRIZAÇÃO DE ALGORITMOS EMPÍRICOS E
ALGORITMO QUASI-ANALÍTICO QAA PARA
ESTIMATIVA DE CLOROFILA-A EM LAGOS DA
VÁRZEA DO RIO AMAZONAS**

Rogério Flores Júnior

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Cláudio Clemente Faria
Barbosa, e Felipe de Lucia Lobo,
aprovada em 14 de março de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3SUQ3U2>>

INPE
São José dos Campos
2019

Dados Internacionais de Catalogação na Publicação (CIP)

Flores Júnior, Rogério.

F663p Parametrização de algoritmos empíricos e algoritmo quasi-analítico QAA para estimativa de clorofila-a em lagos da várzea do rio Amazonas / Rogério Flores Júnior. – São José dos Campos : INPE, 2019.

xxviii + 129 p. ; (sid.inpe.br/mtc-m21c/2019/03.22.19.03-TDI)

Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2019.

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

1. Qualidade da água. 2. Sensoriamento remoto da água. 3. Fitoplâncton. 4. Algoritmos bio-ópticos. 5. Lagos amazônicos. I.Título.

CDU 528.8:556



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/).

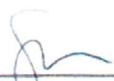
Aluno (a): **Rogério Flores Júnior**

Título: "PARAMETRIZAÇÃO DE ALGORITMOS EMPÍRICOS E ALGORITMO QUASI-ANALÍTICO QAA PARA ESTIMATIVA DE CLOROFILA-A EM LAGOS DA VÁRZEA DO RIO AMAZONAS"

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

Sensoriamento Remoto

Dra. Evlyn Márcia Leão de Moraes Novo

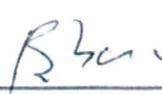


Presidente / INPE / SJCampos - SP

() 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. Fernanda Sayuri Yoshino Watanabe

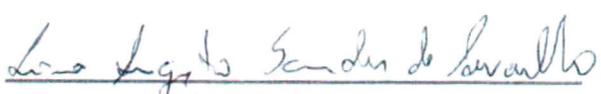


Convidado(a) / UNESP / Presidente Prudente - SP

Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Lino Augusto Sander de Carvalho



Convidado(a) / UFRJ / Rio de Janeiro - RJ

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Este trabalho foi aprovado por:

() maioria simples

unanimidade

São José dos Campos, 14 de março de 2019

“A vida é uma peça de teatro que não permite ensaios.

Por isso, cante,

chore,

dance,

ria e viva intensamente,

antes que a cortina se feche

e a peça termine sem aplausos.”

Charlie Chaplin

*A meus pais e irmão,
com muito amor.*

AGRADECIMENTOS

Agradeço a todos que de alguma forma apoiaram o desenvolvimento desta pesquisa.

Aos funcionários e colegas de INPE.

Aos meus orientadores Dr. Cláudio Barbosa e Dr. Felipe Lobo pela oportunidade de realizar este mestrado e por todo conhecimento compartilhado.

À Dra. Evlyn Novo por toda a orientação, apoio, dedicação e paciência com o desenvolvimento desta pesquisa.

Ao pessoal do LabISA por todas as discussões e ajuda técnico-científica. Em especial o Dr. Lino Sander por seu pensamento crítico e paciência para com a evolução desta pesquisa, sempre pronto para ajudar.

Aos meus orientadores de graduação, Flávio Seixas e Otávio Montanher por terem me mostrado o caminho da pesquisa.

À Mikhaela Pletsch pelas ótimas correções, além de divertidas.

Ao Sr. Nilo por estar aberto e entregando os melhores lanches nos momentos mais difíceis.

A todos os meus amigos que fizeram esta caminhada mais feliz. Principalmente, aos amigos de mestrado que são minha Família fora de casa.

À Ana Carolina Barizão por estar ao meu lado nos melhores e piores momentos desta jornada, sempre me apoiando incondicionalmente”.

Ao meu irmão de mestrado, Daniel Maciel, por todos os cafés e ideias partilhados.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de mestrado e a pós-graduação do INPE pela possibilidade de realizar este mestrado.

RESUMO

O monitoramento sistemático, essencial para a manutenção dos serviços ecossistêmicos, visa auxiliar na gestão, manutenção e recuperação de recursos hídricos diante das ações antrópicas. Suplementando as metodologias tradicionais, o sensoriamento remoto (SR) de ambientes aquáticos relaciona as propriedades ópticas e biogeoquímicas do meio, possibilitando uma visão sinóptica de seus padrões de distribuição no tempo e espaço. A determinação do estado trófico e da produtividade primária do ambiente, estimadas por meio da concentração de clorofila-a (Chl-a), podem ser utilizados como índice da qualidade do recurso hídrico. A quantificação de Chl-a por SR embasa-se na aplicação empírica e/ou semi-analítica de algoritmos, geralmente desenvolvidos para águas oceânicas e costeiras, necessitando assim serem calibrados para sua utilização em águas continentais complexas como às da planície de inundação amazônica. Assim, este trabalho objetivou: i) A aplicação e validação de algoritmos empíricos em dados *in situ* e imagens orbitais simulados para os sensores OLI e MSI, por meio de simulação de Monte Carlo (MC); ii) Aplicação do algoritmo quasi analítico QAA da literatura, calibração e Parametrização de uma versão para às águas complexas da planície amazônica (QAA_{LGC}) e aplicação de Índices para a estimativa de Chl-a com os produtos gerados, utilizando dados *in situ* ($R_{rs}(\lambda)$) simulados para o sensor OLCI. Para isto, foram obtidos dados ópticos e limnológicos em lagos da planície de inundação do baixo Amazonas para quatro campanhas de campo entre 2015 e 2017, formando um conjunto de 94 pontos amostrais. Foram utilizadas as métricas estatísticas R^2 , MAPE, NRMSE e bias, para a avaliação do desempenho dos algoritmos. A calibração dos algoritmos empíricos esbarra na heterogeneidade dos dados das campanhas, coletadas em diferentes fases da hidrógrafa, apresentando resultados insatisfatórios no conjunto com todos os dados. A calibração e validação (MC) apenas para a campanha de 2017 foi satisfatória e possibilitou a aplicação do algoritmo às imagens dos sensores OLI e MSI de mesma data. Os algoritmos empíricos aplicados às imagens de satélite não foram satisfatórios para quantificação da Chl-a, o que pode ser atribuído a alta dinâmica observada entre a data de aquisição das imagens e a aquisição de medidas *in situ*, mesmo considerando-se uma defasagem de apenas 2 dias. A calibração e parametrização das relações empíricas do QAA_{LGC} foram essenciais para o bom desempenho do algoritmo. Os coeficientes de absorção derivados do QAA_{LGC}, obtiveram resultados satisfatórios para o conjunto de dados testado, porém com tendência a subestimar os valores como os demais algoritmos avaliados. A alta concentração de partículas inorgânicas na campanha independente, utilizada para validar o QAA_{LGC}, limitou a obtenção de resultados satisfatórios para a estimativa de Chl-a utilizando os coeficientes de absorção modelados pelo algoritmo. Os resultados obtidos pelo QAA_{LGC} para as águas complexas da planície de inundação amazônica foram satisfatórios. A alta dinâmica sazonal e espacial da região de estudo dificulta a modelagem dos constituintes

presentes no meio aquático, porém os algoritmos (empíricos e semi-analítico) testados mostraram potencial para a quantificação da Chl-a.

Palavras-chave: Qualidade da Água. Sensoriamento remoto da Água. Fitoplancton. Algoritmos bio-ópticos. Lagos Amazônicos.

PARAMETRISATION OF EMPIRICAL ALGORITHMS AND THE QUASI-ANALYTICAL ALGORITHM QAA TO ESTIMATE CHLOROPHYL-A IN LAKES OF THE AMAZON RIVER FLOODPLAINS

ABSTRACT

Systematic monitoring, essential to maintain the ecosystem services, aim to assist the management, maintenance, and recovery of the water resources in contrast to anthropic actions. Supporting the traditional methodologies, the remote sensing (SR) of aquatic environments associate optical and biogeochemical properties of the medium, allowing a synoptic view of its distribution patterns in time and space. The determination of the environment trophic state and primary productivity, estimated by the concentration of chlorophyll-a (Chl-a), can be used as quality index to water resources. The quantification of Chl-a by SR is based on empirical and/or semi-analytical application of algorithms, generally developed for oceanic and coastal waters, needing to be calibrated for use in complex inland waters such as those on the Amazon floodplains. Thus, this study aimed to: i) application and validation of empirical algorithms in in situ data and satellite images simulated to OLI and MSI sensors, through Monte Carlo simulation (MC); ii) Application of the quasi-analytical algorithm QAA from literature, calibration and parameterization of a version for the complex waters of the Amazon floodplain (QAA_{LCG}), and application of Indices to estimate Chl-a with the products generated, using in situ data ($R_{rs}(\lambda)$) simulated for the OLCI sensor. So, optical and limnological data were obtained in lakes from the lower Amazon floodplains in four field campaigns between 2015 and 2017, composing a dataset of 94 sampling points. The statistical metrics R^2 , MAPE, NRMSE and bias were used to evaluate the performance of the algorithms. The calibration of the empirical algorithms faces the heterogeneity of the campaigns, collected in different phases of the hydrograph, presenting unsatisfactory results when calibrated with all data. However, Calibration and validation (MC) only for the 2017 campaign was satisfactory and allowed the application of the algorithm to OLI and MSI sensor images of the same date. Yet, the empirical algorithms applied to the satellite images were not satisfactory to quantify Chl-a, which can be attributed to high dynamics observed between the images date of acquisition and in situ measurements, even only with two days gap. Therefore, calibration and parameterization of the empirical relations on the QAA_{LCG} were essential for optimizing its performance. The absorption coefficients derived from the QAA_{LCG} obtained satisfactory results for the dataset tested, but with a tendency to underestimate it as well as the other algorithms evaluated. The high concentration of inorganic particles in the independent campaign, used to validate the QAA_{LCG}, limited the achievement of satisfactory results of Chl-a using the absorption coefficients modeled by the algorithm. However, the results obtained by QAA_{LCG} for complex waters of the Amazon floodplain lakes were satisfactory considering that the algorithm was developed for

oceanic waters. The highly seasonal and spatial dynamics of the study region makes it difficult to model the constituents present in the water bodies, but the algorithms (empirical and semi-analytical) tested showed potential for quantification of Chl-a.

Key words: Water quality. Water remote sensing; Phytoplankton. Bio-optical models. Amazon Lakes.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 - Esquema dos fluxos absorvidos, espalhados e transmitidos.	11
Figura 2.2 - Comparação dos coeficientes de absorção do fitoplâncton, partículas não algais, CDOM e a água.....	16
Figura 2.3 – Coeficientes de α e b da água pura.	17
Figura 2.4 – Coeficiente normalizado de absorção da Chl-a no fitoplâncton. ..	20
Figura 3.1 - Lagos da área de estudo.	32
Figura 3.2 - Cota da estação Óbidos e precipitação da estação Curuai.	33
Figura 4.1 - Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmos empíricos aplicados a $R_{rs}(\lambda)$ simulada para o sensor OLI nas campanhas 2015, 2016 e 2017 (n=71).	54
Figura 4.2 - Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmo empíricos ajustados no conjunto de dados 2017 para o sensor OLI (n=16).....	56
Figura 4.3- Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmo empíricos aplicados às bandas simuladas do sensor MSI.	59
Figura 4.4 - Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmo empíricos aplicados no conjunto de 2017 para o sensor MSI (n=16).....	61
Figura 4.5 – Algoritmos calibrados com dados <i>in situ</i> e especializados para o sensor OLI (n=16).	65
Figura 4.6 – Algoritmos calibrados com dados <i>in situ</i> especializados para o sensor MSI.	67
Figura 5.1 - Fluxograma esquemático conceitual do QAA.	70
Figura 5.2 - Fluxograma de Parametrização (azul) e validação (verde) do QAA_{LGC}	84
Figura 5.3 - Coeficientes $\alpha_{\phi}(\lambda)$, $\alpha_{CDM}(\lambda)$, e $\alpha_w(\lambda)$ obtidos em laboratório e simulados para as bandas do sensor OLCI para as campanhas a) 2015, b) 2016 e c) 2017.	88

Figura 5.4 - Espectro da $R_{rs}(\lambda)$ simulados para as bandas do sensor OLCI para as campanhas a) 2015 (n=30), b) 2016 (n=06) e c) 2017 (n = 22).	91
Figura 5.5 - Gráfico ternário comparando as frações α_{φ} , α_{CDOM} e α_{Det} nos comprimentos de onda a) 400 nm, b) 443 nm, c) 560 nm e d) 665 nm.	92
Figura 5.6 - Contribuição da água na absorção total nas campanhas: a) 2015, b) 2016 e c) 2017.	93
Figura 5.7 - MAPE médio de $\alpha_t(\lambda)$ estimado para cada modelo nos λ_0 selecionados, comparados com os dados do AC-S + água (POPE; FRY, 1997).	94
Figura 5.8 - Espectro $\alpha_t(\lambda)$ determinado para cada modelo testado e a versão parametriza QAA _{LGC} .	97
Figura 5.9 - Dispersão de $\alpha_t(\lambda)$ estimados em relação aos dados de campo.	99
Figura 5.10 - Resultados de MAPE e NRMSE para $\alpha_t(\lambda)$ estimado em relação aos dados de campo.	100
Figura 5.11 – Frações $\alpha_{CDM}(\lambda)$ e $\alpha_{\varphi}(\lambda)$ estimadas pelas parametrizações a) V_{RDSM} , b) dados laboratoriais medidos e c) V_{v5} .	103
Figura 5.12 - Espectro $\alpha_{CDM}(\lambda)$ determinado para cada modelo testado e a versão parametriza QAA _{LGC} .	105
Figura 5.13 - Dispersão de $\alpha_{CDM}(\lambda)$ estimados em relação aos dados de campo.	106
Figura 5.14 - Resultados de MAPE e NRMSE para $\alpha_{CDM}(\lambda)$ estimado em relação aos dados de campo.	107
Figura 5.15 - Espectro $\alpha_{\varphi}(\lambda)$ determinado para cada modelo testado e a versão parametriza QAA _{LGC} .	108
Figura 5.16 - Dispersão de $\alpha_{\varphi}(\lambda)$ estimados em relação aos dados de campo.	109
Figura 5.17 - Resultados de MAPE e NRMSE para $\alpha_{\varphi}(\lambda)$ estimado em relação aos dados de campo.	110
Figura 5.18 - Gráfico de dispersão mostrando os ajustes entre a concentração de Chl-a e os índices empíricos aplicados a $R_{rs}(\lambda)$ (a, b e c) e suas derivações aplicadas às IOPs (d, e, f).	111

Figura A.1 - Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmos empíricos com a campanha de março de 2016, aplicados a $R_{rs}(\lambda)$ para o sensor OLI.	128
Figura A.2 - Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmos empíricos com a campanha de março de 2016, aplicados a $R_{rs}(\lambda)$ para o sensor MSI.....	129

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 2.1 - Características do sensor OLI – Landsat 8.	27
Tabela 2.2 - Características do sensor MSI – Sentinel-2.	28
Tabela 2.3 - Características do sensor OLCI – Sentinel-3.	29
Tabela 4.1 - Índices de modelos e bandas testados para os sensores OLI e MSI.	50
Tabela 4.2 - Estatísticas descritivas dos parâmetros de qualidade da água medidos in situ.	52
Tabela 4.3 - Avaliação estatística dos algoritmos aplicados aos dados das campanhas 2015, 2016 e 2017 simulados para o sensor OLI.	55
Tabela 4.4 - Avaliação estatística dos algoritmos aplicados aos dados simulados OLI para a campanha de 2017.	57
Tabela 4.5 - Coeficientes da regressão para o sensor OLI aplicado à campanha 2017.	58
Tabela 4.6 - Avaliação estatística dos algoritmos aplicados aos dados das campanhas 2015, 2016 e 2017 simulados para o sensor MSI.	60
Tabela 4.7 - Avaliação estatística dos algoritmos aplicados aos dados simulados MSI para a campanha de 2017.	62
Tabela 4.8 - Coeficientes da regressão para o sensor MSI aplicado à campanha 2017.	63
Tabela 4.9 - Estatísticas dos algoritmos aplicados na imagem do sensor OLI comparados aos dados de Chl-a <i>in situ</i> (n=16).	64
Tabela 4.10 - Estatísticas dos algoritmos aplicados na imagem do sensor MSI.	66
Tabela 5.1- Etapas originais do QAA _{v5}	75
Tabela 5.2 - Comprimentos de onda de referência.	76
Tabela 5.3 - Estatísticas descritivas dos parâmetros de qualidade da água medidos in situ.	87
Tabela 5.4 - Estatística descritiva das IOPs (α_φ e α_{CDM}) medidas em laboratório.	89

Tabela 5.5 - Validação dos modelos para estimativa de Chl-a utilizando simulações Monte Carlo.....	112
Tabela 5.6 - Validação dos modelos para estimativa de Chl-a utilizando o conjunto de dados independentes de março 2016.....	113

LISTA DE SIGLAS E ABREVIATURAS

INPE	Instituto Nacional de Pesquisas Espaciais
6S	<i>Second Simulation of The Satellite Signal in The Solar Spectrum</i>
RDSM	Reserva de Desenvolvimento Sustentável Mamirauá
MSI	<i>MultiSpectral Instrument</i>
OLCI	<i>Ocean and Land Colour Instrument</i>
OLI	<i>Operational Land Imager</i>
NRMSE	<i>Normalized Root Mean Squared Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
REM	Radiação Eletromagnética
COAs	Componentes Opticamente Ativos
MOD	Matéria Orgânica Dissolvida
CDOM	<i>Coloured Dissolved Organic Matter</i>
UV	Ultravioleta
Chl-a	Clorofila-a
TSS	Total de Sólidos em Suspensão
TSI	Sólidos Inorgânicos em Suspensão
TSO	Sólidos Orgânicos em Suspensão
NAP	<i>Non Algae Particles</i>
VSF	Função de Espalhamento de Volume
IOPs	<i>Inherent Optical Properties</i>
AOPs	<i>Apparent Optical Properties</i>
HCl	Ácido Clorídrico

AC-S	<i>Absorption and attenuation spectral</i>
FOV	Campo de Visada
RAMSES	<i>Radiation Measurement Sensor with Enhanced Spectral Resolution</i>
LAQUATEC	Laboratório de Pesquisa Ambiental em Aerossóis, Soluções Aquosas e Tecnologia
T-R	Método “Transmitância-Reflectância”
TTR	Teoria de Transferência Radiativa
SNR	<i>Signal-to-Noise Ratio</i>

LISTA DE SÍMBOLOS

α	Coeficiente de absorção
$\alpha_{\varphi}(\lambda)$	Coeficiente de absorção do fitoplâncton
$\alpha_{\varphi}^*(\lambda)$	Coeficiente específico de absorção da clorofila-a
$\alpha_t(\lambda)$	Coeficiente de absorção total
$\alpha_w(\lambda)$	Coeficiente de absorção da água pura
$\alpha_{\text{CDM}}(\lambda) ; \alpha_{\text{dg}}(\lambda)$	Coeficiente de absorção do detrito+CDOM
$\alpha_{\text{CDOM}}(\lambda)$	Coeficiente de absorção do CDOM
$\alpha_{\text{det}}(\lambda)$	Coeficiente de absorção do detrito
b	Coeficiente de espalhamento
b_f	Coeficiente de espalhamento frontal
b_b	Coeficiente de retroespalhamento
b_{bw}	Coeficiente de retroespalhamento da água pura
b_{bp}	Coeficiente de retroespalhamento do material particulado
c	Coeficiente de atenuação
λ	Comprimento de onda
ρ	Refletância interface ar-água
$\beta(\psi)$	Função de espalhamento de volume
R^2	Coeficiente de determinação
φ_i	Fluxo radiante incidente
φ_s	Fluxo radiante espalhado

Φ_a	Fluxo radiante absorvido
Δ_r	Espessura óptica da camada
dI	Intensidade radiante para o ângulo Θ
dV	Elemento volumétrico
$d\Theta$	Ângulos zenitais
$D\omega$	Ângulos sólidos entre 0 e 4π sr
K_d	Coefficiente de atenuação
$R_{rs}(\lambda)$	Reflectância de sensoriamento remoto
$r_{rs}(\lambda)$	Reflectância de sensoriamento remoto de subsuperfície
E_d	Irradiância descendente
E_u	Irradiância ascendente
E_s	Irradiância incidente na superfície
L_w	Radiância emergente da coluna d'água
L_{sky}	Radiância difusa do céu
L_u	Radiância ascendente na coluna d'água
f/Q	Fatores proporcionais ao campo de luz incidente
σ	Desvio padrão

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO.....	1
1.1 Hipótese.....	4
1.2 Objetivos.....	5
1.2.1 Objetivo geral	5
1.2.2 Objetivos específicos	5
1.3 Estrutura da dissertação	6
2 REFERÊNCIAL TEÓRICO	9
2.1 Sensoriamento remoto de ambientes aquáticos.....	9
2.2 Propriedades ópticas de ambientes aquáticos	10
2.3 Componentes Opticamente Ativos	15
2.3.1 Água pura.....	16
2.3.2 Matéria Orgânica Dissolvida.....	17
2.3.3 Total de Sólidos em Suspensão.....	18
2.3.4 Fitoplâncton.....	19
2.3.5 Partículas Não Algais	21
2.4 Algoritmos bio-ópticos.....	22
2.4.1 Abordagens empíricas e semi-empíricas	22
2.4.2 Abordagens semi-analíticas	23
2.5 Sensores orbitais	26
2.5.1 Sensor OLI – Landsat 8	26
2.5.2 Sensor MSI – Sentinel-2	27
2.5.3 Sensor OLCI – Sentinel-3	28
2.5.4 Correções atmosféricas	29
3 METODOLOGIAS DE AQUISIÇÃO E PROCESSAMENTO DE DADOS	
<i>IN SITU</i> E ORBITAIS	31
3.1 Área de estudo	31
3.2 Materiais	33
3.2.1 Dados coletados <i>in situ</i>	34
3.2.1.1 TriOS.....	34

3.2.1.2	AC-S.....	36
3.2.2	Dados laboratoriais	37
3.2.3	Dados orbitais	41
3.2.3.1	Reamostragem dos dados <i>in situ</i> para as bandas espectrais de sensores orbitais.	42
3.3	Estatísticas	42
4	ALGORITMOS EMPÍRICOS PARA ESTIMATIVA DE CLOROFILA-A	44
4.1	Introdução.....	44
4.2	Dados e métodos.....	47
4.2.1	Dados <i>in situ</i>	47
4.2.2	Algoritmos empíricos.....	48
4.2.3	Mapas de Chl-a	50
4.3	Resultados e discussão.....	51
4.3.1	Parâmetros de qualidade da água	51
4.3.2	Calibração dos algoritmos com dados <i>in situ</i>	53
4.3.2.1	Sensor OLI	53
4.3.2.2	Sensor MSI.....	58
4.3.3	Avaliação dos algoritmos em imagens orbitais.....	63
4.3.3.1	Sensor OLI	63
4.3.3.2	Sensor MSI.....	65
4.4	Conclusão.....	67
5	ALGORITMO QAA PARA DETERMINAÇÃO DAS IOPS DOS PRINCIPAIS LAGOS DA PLANÍCIE DE INUNDAÇÃO DO BAIXO AMAZONAS	69
5.1	Introdução.....	69
5.2	Dados e métodos.....	73
5.2.1	Algoritmos QAA.....	74
5.2.1.1	Parte 1 - Derivação de α_t	76
5.2.1.2	Parte 2 – Derivação de α_{CDM} e α_φ	79
5.2.2	Parametrização do QAA _{LGC}	81
5.2.3	Validação.....	84
5.2.3.1	Índices de clorofila-a adaptados às IOPs	85

5.3	Resultados e discussão.....	86
5.3.1	Parâmetros de qualidade da água	86
5.3.2	Caracterização biótica	90
5.3.3	Etapa 1 – Estimativa de $\alpha_t(\lambda)$	92
5.3.4	Etapa 2 – Separação de $\alpha_{\text{CDM}}(\lambda)$ e $\alpha_\phi(\lambda)$	101
5.3.4.1	Estimativa de $\alpha_{\text{CDM}}(\lambda)$	103
5.3.4.2	Estimativa de $\alpha_\phi(\lambda)$	107
5.3.5	Concentração de Chl-a utilizando as IOPs do QAA _{LGC}	111
5.4	Conclusão.....	114
6	CONCLUSÕES E TRABALHOS FUTUROS	116
	REFERÊNCIAS BIBLIOGRÁFICAS	118
	APÊNDICE A - ALGORITMOS EMPÍRICOS AJUSTADOS COM A CAMPANHA DE MARÇO DE 2016.....	128

1 INTRODUÇÃO

Com aproximadamente 6,5 milhões de Km² a Bacia Amazônica é formada pelo rio Amazonas e seus tributários, sendo considerada a maior bacia hidrográfica do mundo (SIOLI, 1984). a Bacia Amazônica possui uma vasta planície de inundação, cerca de 17% de sua área total, contendo grandes riquezas em recursos naturais e biodiversidade (MELACK et al., 2004). Além disso, ainda provê serviços ecossistêmicos e que são essenciais para os ciclos biogeoquímicos de carbono e de nutrientes. Entretanto, estes ambientes vêm sendo ameaçados por diversos fatores antrópicos como, por exemplo, a degradação e fragmentação de florestas primárias, potencializando impactos como os efeitos de borda, corte seletivo, incêndios e mineração ilegal de ouro (LAURANCE; PERES, 2006). Além disso, a criação de barragens hidrelétricas nas regiões Amazônicas pode afetar a geometria hidráulica de rios e conseqüentemente a carga de sedimentos, provocando profundas alterações na dinâmica hidrológica (JUNK; MELLO, 1990). Nesse contexto, a intensificação destes fatores antrópicos pode afetar a qualidade dos recursos hídricos, acarretando um desequilíbrio nos ecossistemas e auxiliando no desenvolvimento de florações de algas, deteriorando o ambiente e potencialmente promovendo questões de saúde pública (JUNK; MELLO, 1990). Portanto, o monitoramento deste recurso se faz necessário para a compreensão dos efeitos destas alterações, auxiliando na tomada de decisões.

O monitoramento dos ecossistemas aquáticos é tradicionalmente realizado de forma pontual, com a coleta de amostras *in situ* e análise laboratorial dos parâmetros ambientais. Estas metodologias são muito dependentes do acesso ao local de estudo, tornando-as complexas e custosas, restringindo a representatividade espacial dos dados coletados, devido ao número limitado de amostras. Além disso, a representatividade das amostras no tempo também é limitada, porque os dados são coletados com baixa frequência. Com um custo-benefício relativamente baixo e uma grande abrangência temporal e espacial, em comparação com as metodologias tradicionais, a utilização do

Sensoriamento Remoto (SR) como ferramenta para o monitoramento dos sistemas aquáticos surge como forma de apoio e até mesmo uma alternativa às medições *in situ* (MOUW et al., 2015).

A interação da radiação eletromagnética (REM) com os Componentes Ópticamente Ativos (COAs) presentes no meio aquático determina a cor da água, diretamente relacionadas com as concentrações destes constituintes na coluna d'água (IOCCG, 2006). Desta forma, diversos parâmetros de qualidade da água podem ser estimados por meio de SR, como os total de sólidos em suspensão (TSS), a matéria orgânica colorida dissolvida (CDOM) e a Clorofila-a (Chl-a) (KIRK, 2011). A avaliação em larga escala (temporal e espacial) das características da água, por meio de seus constituintes, utilizando o SR, permite o desenvolvimento de estudos voltados à qualidade da água (MOBLEY et al., 2017) e entendimento do transporte e origem destes materiais.

Dentre os parâmetros de qualidade da água que podem ser avaliados por SR, a concentração de Chl-a tem grande importância, pois pode ser utilizada para estudos da produtividade primária e na determinação da biomassa do fitoplâncton (MOSES et al., 2012). Além disto, pode ser utilizado como indicador do estado trófico do corpo d'água, por ser o principal pigmento encontrado (geralmente em maiores quantidades) em todas as espécies de fitoplâncton (ESTEVES, 1998).

Para o desenvolvimento de produtos relacionados com a concentração de Chl-a por SR são utilizados algoritmos que buscam modelar a influência deste componente nos dados de reflectância coletados pelos sensores orbitais (MATTHEWS, 2011). De forma simplificada, estes algoritmos podem ser classificados em empíricos (semi-empíricos) ou semi-analíticos. Os algoritmos empíricos buscam encontrar relações estatísticas entre a reflectância do corpo d'água e os constituintes presentes na coluna d'água (MATTHEWS, 2011; MOSES et al., 2009). Desta forma, nas abordagens empíricas, a concentração Chl-a é correlacionada estatisticamente com as bandas espectrais em que a influência da Chl-a é predominante (ODERMATT et al., 2012).

A utilização de razões de bandas, como em algoritmos de 2 (MOSES et al., 2009), 3 (GILERSON et al., 2010; GITELSON et al., 2006) ou mais bandas, visa remover os efeitos de outros constituintes nas estimativas, melhorando seu desempenho. Diversos algoritmos para estimativa da concentração de Chl-a são encontrados na literatura (MATTHEWS, 2011; ODERMATT et al., 2012; WERDELL et al., 2018). Entretanto, a maior parte destes algoritmos foram desenvolvidos para águas oceânicas, onde seus constituintes covariam principalmente com concentração de Chl-a. Para as águas túrbidas da planície Amazônica, opticamente complexas, a influência do pulso de inundação sazonal modifica as características físico-químicas do meio, alterando assim a dinâmica dos constituintes dissolvidos e em suspensão (BARBOSA, 2005). Desta forma, os algoritmos desenvolvidos para águas oceânicas ao serem aplicados a águas interiores podem não ser capazes de estimar a influência da Chl-a, resultando em resultados imprecisos (MATTHEWS, 2011; MISHRA; MISHRA, 2012). Portanto, a adaptação e calibração dos algoritmos para as características das águas interiores faz-se necessária.

Alternativamente às abordagens empíricas, os algoritmos semi-analíticos utilizam-se de um embasamento teórico mais robusto, apoiados sobre as propriedades ópticas do meio aquático. Os algoritmos semi-analíticos relacionam as propriedades ópticas inerentes (IOPs) e aparentes (AOPs) modelando-as matematicamente a partir de aproximações da equação de transferência radiativa (CHEN et al., 2014; LEE et al., 2002; ODERMATT et al., 2012). Apesar desse arcabouço teórico, estes algoritmos não são completamente analíticos, incorporando aproximações empíricas que demandam parametrizações e calibrações. O *Quasi Analytical Algorithm* (LEE, 2014; LEE et al., 2002, 2009) é um exemplo de algoritmo semi-analítico que utiliza as relações entre os coeficientes de absorção e espalhamento com a reflectância, para a quantificação dos constituintes presentes no meio aquático.

Para a utilização do SR nas estimativas de Chl-a, são necessários dados de campo para o desenvolvimento e validação dos algoritmos. Porém, a qualidade dos dados, tanto na aquisição *in situ* quanto no seu processamento, é determinante na obtenção de bons resultados. Em relação ao processamento

desses dados, a manutenção de um padrão de análise e filtragem dos dados é essencial para a consistência dos algoritmos. As características dos sensores orbitais representam outro fator relevante para o desempenho dos algoritmos quando aplicados às imagens de satélite. Características tais como resolução espectral, radiométrica, temporal e espacial afetam a acurácia das medidas. Sensores de alta resolução espacial e com bandas espectrais em regiões de interesse para estimativas de Chl-a, como o Operational Land Imager (OLI), a bordo do satélite Landsat 8, e o MultiSpectral Instrument (MSI), a bordo dos satélites Sentinel-2A e 2B, podem apresentar boas estimativas (DIERSSEN, 2010; WATANABE et al., 2017). A fim de uma cobertura temporal e espacial maior, a utilização de sensores como OLCI, a bordo do Sentinel-3, pode ser uma alternativa em ambientes com grandes dimensões (WATANABE et al., 2018). A utilização de imagens orbitais pode garantir uma visão sinóptica dos meios aquáticos através da criação de mapas com as concentrações estimadas de Chl-a.

Dada as dimensões da planície de inundação Amazônica e sua alta dinâmica, a utilização do SR orbital para o seu monitoramento sistemático apresenta-se como uma opção viável. Com a utilização do SR como ferramenta para a viabilização do mapeamento da concentração de Chl-a, por meio da calibração de algoritmos empíricos e semi-analíticos, será possível não só auxiliar no monitoramento da área de estudo, como ampliar o conhecimento das características bio-ópticas das águas interiores turbidas. Desta forma, o presente trabalho pretende combinar técnicas de SR, dados in situ e orbitais para a estimativa da concentração de Chl-a, expandindo o conhecimento sobre os processos físicos, químicos e biológicos da região do Baixo Amazonas.

1.1 Hipótese

Considerando a importância no monitoramento dos ambientes aquáticos continentais e suas implicações para as atividades humanas, este trabalho visa desenvolver o conhecimento destes ambientes. Porém, em regiões como as das planícies de inundação amazônica em que os ambientes aquáticos são altamente complexos e dinâmicos, existem poucos estudos no contexto da

óptica hidrológica por SR. Assim, este trabalho levanta a pergunta científica: com que acurácia podem ser aplicados algoritmos bio-ópticos para a estimativa de concentração de Chl-a em águas túrbidas dos lagos da planície de inundação do rio Amazonas?

A partir disto, levanta-se a hipótese de que com a disponibilidade dos novos sensores OLI, MSI e OLCI, é possível desenvolver algoritmos bio-ópticos para o monitoramento sistemático da dinâmica de Chl-a em lagos de elevada turbidez da planície de inundação do Baixo Amazonas. Portanto, são definidas as seguintes premissas para o desenvolvimento deste trabalho:

- O pulso de inundação sazonal controla a entrada de matéria orgânica, de sedimentos e nutrientes, e com isso, a concentração de Chl-a nos lagos da planície de inundação amazônica;
- As imagens dos sensores disponíveis OLI, MSI e OLCI são adequadas para estimar os algoritmos em função das suas bandas;
- O conjunto de medidas *in situ* coletado, é suficiente para calibrar e implementar os algoritmos selecionados.

1.2 Objetivos

1.2.1 Objetivo geral

Estimar a concentração de Chl-a em águas túrbidas de lagos amazônicos a partir da parametrização de algoritmos bióticos (empíricos e semi-analíticos) utilizando dados *in situ* e posterior validação e espacialização com sua aplicação a imagens de satélite de média/alta resolução atualmente disponíveis, OLI/Landsat-8, MSI/Sentinel-2 e OLCI/Sentinel-3.

1.2.2 Objetivos específicos

- Avaliar o desempenho de algoritmos semi-empíricos consolidados na literatura, visando estimativas de Chl-a a partir de dados de reflectância

de sensoriamento remoto ($R_{rs}(\lambda)$) in situ simulados para os sensores OLI/Landsat-8 e MSI/Sentinel-2, utilizando simulações de Monte Carlo.

- Avaliar a eficácia da aplicação dos algoritmos semi-empíricos parametrizados anteriormente em imagens orbitais dos respectivos sensores (OLI e MSI), adquiridas concomitantemente às campanhas de campo.
- Avaliar o desempenho do algoritmo quasi-analítico QAA para determinação das IOPs utilizando dados de $R_{rs}(\lambda)$ simulados para o sensor OLCI/Sentinel-3, utilizando versões da literatura e uma versão parametrizada para o ambiente de estudo, por meio de simulações de Monte Carlo.
- Avaliar a eficácia das IOPs derivadas do QAA parametrizado em estimar a concentração de Chl-a utilizando algoritmos empíricos derivados de índices espectrais propostos na literatura, aplicados à uma campanha de campo independente aos dados de calibração.

1.3 Estrutura da dissertação

Este trabalho de dissertação está organizado em 6 capítulos. Os capítulos 1, 2 e 3 contextualizam o tema deste trabalho, o aporte teórico necessário para seu desenvolvimento e as metodologias de coleta e preparação dos dados in situ e orbitais utilizados nos capítulos 4 e 5. Visando a confecção de artigos científicos, os capítulos 4 e 5 são estruturados para tal. A seguir, são apresentados os principais tópicos tratados em cada capítulo:

- **Capítulo 1 – Introdução**

Introdução aos ecossistemas aquáticos amazônicos, a complexidade de seus constituintes e ao sensoriamento remoto aplicado a estimativa dos COAs. Este capítulo fundamenta também a importância da Chl-a no monitoramento da qualidade da água e a motivação e objetivos deste trabalho;

- **Capítulo 2 – Referencial Teórico**

Neste capítulo, são apresentadas a fundamentação teórica entorno da interação da REM com o meio aquático, as propriedades ópticas de águas naturais e as características dos COAs. Também são apresentados neste capítulo, o referencial teórico e o embasamento físico para utilização de algoritmos empíricos e semi-analíticos para a estimativa da concentração de Chl-a. Por fim, são apresentadas as características dos sensores OLI, MSI e OLCI, utilizados nos capítulos 4 (OLI e MSI) e capítulo 5 (OLCI).

- **Capítulo 3 – Metodologias de aquisição e processamento de dados *in situ* e orbitais**

São descritos neste capítulo as metodologias de aquisição, pré e pós processamento de dados *in situ* e orbitais. Primeiramente, são apresentados os lagos da área de estudo e uma breve caracterização do ambiente e da dinâmica hidrológica. Os materiais e métodos utilizados neste capítulo visam preparar os dados de entrada para os capítulos 4 e 5 desta dissertação;

- **Capítulo 4 – Algoritmos empíricos para a estimativa de Chl-a**

Neste capítulo, são avaliados algoritmos empíricos da literatura para determinação da Chl-a em águas turbidas. Foram selecionados algoritmos baseados na relação entre as bandas do Vermelho e infravermelho próximo (NIR), devido às características do ambiente de estudo, sendo: 2B e 3B (GITELSON et al., 2008), NDCI (MISHRA; MISHRA, 2012), Slope model (MISHRA; MISHRA, 2010). Os algoritmos foram validados com dados *in situ* e orbitais utilizando simulação de Monte Carlo para determinação das modas de cada método estatístico testado;

- **Capítulo 5 – Algoritmo QAA para determinação das IOPs dos principais lagos da planície de inundação do baixo amazonas**

Neste capítulo, são apresentadas as principais versões do algoritmo QAA desenvolvidas para águas oceânicas e para águas interiores. Versões da literatura selecionadas foram aplicados aos dados *in-situ* e comparados com a parametrização para as águas túrbidas dos lagos do baixo amazonas (QAA_{LGC}). Por fim, a eficiência do QAA_{LGC} foi testada com a aplicação de índices para a estimativa de Chl-a, modelados com as IOPs derivadas do QAA_{LGC} e com os dados de $R_{rs}(\lambda)$ simulados para as bandas do sensor OLCI.

- **Capítulo 6 - Conclusão e Trabalhos Futuros**

Por fim, neste capítulo são apresentadas as conclusões gerais para a modelagem da concentração Chl-a nas águas altamente túrbidas dos lagos amazônicos, avaliando dos resultados obtidos nos algoritmos empíricos e quasi-analítico QAA.

2 REFERÊNCIAL TEÓRICO

2.1 Sensoriamento remoto de ambientes aquáticos

O SR é o ramo da ciência que usa a interação da REM com objetos e superfícies buscando extrair informações de forma remota, abrangendo as escalas laboratoriais, de campo, aerotransportado e orbital (JENSEN, 2009). A REM é composta por pacotes com quantidades determinadas de energia, chamados de fótons, possuindo tanto caráter corpuscular quanto ondulatório. Essas partículas de energia possuem momentos lineares e angulares, entretanto, também podem ser associadas às propriedades ondulatórias, como frequência (ν) e comprimento de onda (λ) (MOBLEY, 1994). Buscando quantificar essa energia foram definidas as grandezas radiométricas, que por meio de técnicas de radiometria aliadas às geometrias de propagação e aquisição da REM, puderam ser observadas com precisão.

A radiância (L) e a irradiância (E) são grandezas radiométricas para quantificar a energia contida em um fluxo de fótons da REM. A radiância, em um ponto no campo de luz e numa direção determinada, é definida como o fluxo radiante neste ponto por unidade de ângulo sólido e área, paralelos à direção da propagação dos fótons. A irradiância, se refere ao fluxo radiante por unidade de área em um ponto no campo de luz, integrado para todas as direções de um hemisfério (POZDNYAKOV; GRASSL, 2003).

Com a utilização do sensoriamento remoto para o monitoramento de ambientes aquáticos, inicialmente em águas oceânicas e posteriormente em águas costeiras e interiores, criou-se o conceito de da óptica hidrológica (BUKATA, 2013; BUKATA et al., 2018; MISHRA et al., 2017). A óptica hidrológica, segundo Kirk (2011), é ramo da física que trata dos processos de propagação da luz na água, utilizando como arcabouço físico e matemático a teoria de transferência radiativa (TTR). Os ambientes aquáticos são compostos por uma mistura de componentes orgânicos e inorgânicos, em suspensão ou dissolvidos, que influenciam nos processos de absorção e espalhamento da luz (REM) incidente, conferindo assim a coloração dos rios, lagos e oceanos.

No contexto do SR de ambientes aquáticos, as águas naturais são classificadas em águas do caso 1 e do caso 2, com base nos constituintes presentes nos corpos d'água (GORDON; MOREL, 1983, 1977). As águas do caso 1 são consideradas opticamente menos complexas, geralmente atribuídas as águas oceânicas, onde o fitoplâncton e os derivados de sua degradação (e.g detritos orgânicos) são dominantes na determinação das propriedades ópticas do meio (KIRK, 2011). O caso 2 é atribuído a águas continentais e estuarinas, consideradas mais complexas, onde as propriedades ópticas variam de forma independente com cada constituinte, e não apenas com o fitoplâncton (MISHRA et al., 2017). Mobley (1994) salienta que mesmo que 98% das águas oceânicas e costeiras se enquadrem no caso 1 e a maior parte das águas continentais se enquadrem no caso 2, sua localização não é sinônimo para definir sua classificação.

As propriedades físico-químicas dos COAs, como composição e concentração, determinam suas propriedades ópticas de espalhamento e absorção. Os principais COAs presentes no meio aquático são: a água pura, o CDOM, TSS, os pigmentos fotossintetizantes e as partículas não-algais (NAP).

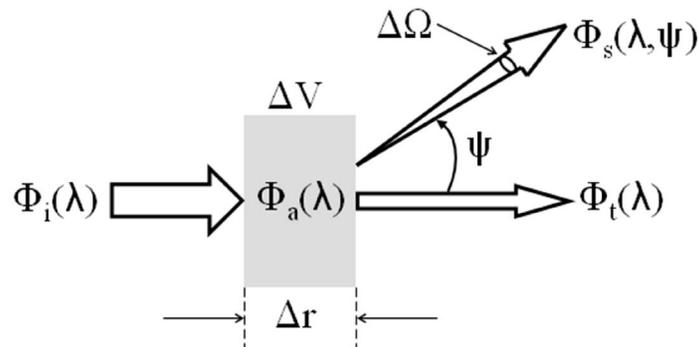
2.2 Propriedades ópticas de ambientes aquáticos

Os ambientes aquáticos naturais são compostos por moléculas de água e uma combinação de constituintes formados por materiais particulados e dissolvidos, em que parte destes são COAs (KIRK, 2011). A interação da REM com a água e seus COAs, por meio dos processos de absorção e espalhamento, determinam as propriedades ópticas essenciais para o estudo de ambientes aquáticos por SR, as quais podem ser divididas em propriedades ópticas inerentes (*Inherent Optical properties* - IOPs) e propriedades ópticas aparentes (*Apparent optical properties* - AOPs) (MOBLEY, 1994; PREISENDORFER, 1961). As IOPs são assim denominadas, porque sua magnitude depende somente da composição e da concentração das substâncias particuladas e dissolvidas presentes na água, além da própria água. Já as AOPs dependem tanto dos COAs e suas concentrações quanto do campo de luz incidente. As

AOPs devem exibir características regulares e estabilidade suficiente para serem úteis descritores das características do corpo de água (DEKKER; BUKATA, 2002; MOBLEY, 1994).

As IOPs são definidas em termos do coeficiente de absorção (α), do coeficiente de espalhamento (b) e da função de espalhamento de volume (VSF) ¹ resultantes da interação da REM ao se propagar na coluna d'água. Estes coeficientes são definidos conceitualmente com a ajuda de uma camada plana e infinitesimalmente fina de água, iluminada por um feixe monocromático colimado perpendicular à camada, onde parte da energia é absorvida, parte espalhada e parte é transmitida (Figura 2.1) (MOBLEY, 1994).

Figura 2.1 - Esquema dos fluxos absorvidos, espalhados e transmitidos.



Fonte: Mobley (1994).

Onde Δ_V e Δ_r são, respectivamente, o volume e a espessura infinitesimal da camada de água, iluminada por um feixe colimado e estreito de luz monocromática de fluxo $\phi_i(\lambda)$. Uma fração desse fluxo é absorvida ($\phi_a(\lambda)$), outra fração é espalhada ($\phi_s(\psi, \lambda)$) e o restante é transmitida para a próxima camada do meio sem alteração na sua direção (KIRK, 2011; MOBLEY, 1994). Segundo Kirk (2011), os coeficientes de absorção (α) e espalhamento (b), juntamente

¹ VSF abreviatura de *volume scattering function*

com a função de espalhamento de volume (VSF - $\beta(\psi, \lambda)$), são as principais IOPs. Dividindo-se a fração absorvida ($\phi_a(\lambda) / \phi_i(\lambda)$) por Δ_r , obtém-se o α e de forma similar, o b é a fração espalhada ($\phi_s(\lambda) / \phi_i(\lambda)$) dividida por Δ_r (Equações 2.1 e 2.2, respectivamente).

$$\alpha = \left(\frac{\Phi_a}{\Phi_i} \right) / \Delta_r \text{ (m}^{-1}\text{)} \quad (2.1)$$

$$b = \left(\frac{\Phi_s}{\Phi_i} \right) / \Delta_r \text{ (m}^{-1}\text{)} \quad (2.2)$$

A informação da distribuição do espalhamento na coluna d'água, que também afeta a penetração da luz, não está contida no coeficiente de espalhamento $b(\lambda)$. O atributo que descreve esta propriedade óptica inerente ao meio é a VSF. A VSF ($\beta(\psi, \lambda)$) determina a fração do fluxo incidente que é espalhado na camada Δ_r dentro de um determinado ângulo sólido $\Delta\Omega$ centrado na direção do ângulo ψ (Equação 2.3). Alternativamente $b(\lambda)$ pode ser obtido por meio da integração da VSF em todas as direções, representado pela Equação 2.4 na decomposição de seus constituintes.

$$\beta(\psi; \lambda) = \left(\frac{\Phi_s(\psi; \lambda)}{\Phi(\lambda)\Delta_r\Delta\Omega} \right) \text{ (m}^{-1}\text{sr}^{-1}\text{)} \quad (2.3)$$

$$b = 2\pi \int_0^\pi \beta(\theta) \sin \theta d\theta = \int_{4\pi} \beta(\theta) d\omega \text{ (m}^{-1}\text{)} \quad (2.4)$$

Onde β é a VSF na direção theta (Θ), Δ_r é a espessura da camada, $d\Theta$ se refere aos ângulos entre 0 e 180° e $d\Omega$ se refere aos ângulos sólidos entre 0 e 4 π sr (esterradianos).

Já as propriedades aparentes (AOPs) devem ser capazes de prover uma robusta e constante descrição dos corpos d'água, levando em conta as propriedades inerentes do meio e a geometria do campo de luz (KIRK, 2011). Estas propriedades devem apresentar pouca influência de variações ambientais para serem úteis na descrição do meio aquático. Grandezas radiométricas como a irradiância descendente (E_d), radiância emergente da água (L_w), e radiância difusa do céu (L_{sky}) são sensíveis a variações ambientais, como a mudança na cobertura de nuvens. Desta forma, não podem ser usadas como descritoras do meio aquático. Entretanto, razões de grandezas radiométricas, como razão de irradiâncias ou de radiância por irradiância, apresentam estabilidade suficiente para serem usadas como AOPs (MOBLEY, 1994).

As principais AOPs definidas e usadas pela óptica hidrológica em aplicações de SR são: Reflectância de sensoriamento remoto ($R_{rs}(\Theta, \phi, \lambda)$), a refletância de irradiância, os coeficientes de atenuação difusos e a razão de irradiâncias (R). A $R_{rs}(\lambda)$ pode ser definida pela razão entre a radiância que deixa a água em direção do ao sensor ($L_w(\lambda)$) e a irradiância incidente no corpo d'água ($E_d(\lambda)$):

$$R_{rs}(\theta, \Phi, \lambda) = \frac{L_w(\theta, \Phi, \lambda)}{E_d(\lambda)} \text{ (sr}^{-1}\text{)} \quad (2.5)$$

Onde $R_{rs}(\lambda)$ é a reflectância de sensoriamento remoto, $L_w(\lambda)$ é a radiância emergente da coluna d'água, na ausência de atmosfera e normalizada para o sol posicionado no zênite e $E_s(\lambda)$ corresponde a irradiância incidente que atinge a superfície da água (MOBLEY, 1999). Θ e ϕ são os ângulos zenital e azimutal da medida. A razão de irradiâncias ou reflectância de irradiância (R) é calculada utilizando E_d e E_u , sendo definida por:

$$R(z, \lambda) = \frac{E_u(z, \lambda)}{E_d(z, \lambda)} \quad (2.6)$$

Os coeficientes de atenuação difusos representam a taxa de decaimento da irradiância com o aumento da profundidade do corpo d'água e é uma importante propriedade relacionada à penetração e disponibilidade de luz em sistemas aquáticos. Os coeficientes de atenuação difusa podem ser calculados para E_d (K_d) e E_u (K_u), sendo definidos por:

$$K_x = - \left(\frac{1}{E_x} * \frac{dE_x(z, \lambda)}{dz} \right) (m^{-1}) \quad (2.7)$$

Onde K_x representa as diferentes funções K (K_d e K_u) em m^{-1} , z é a profundidade e E_x são a diferentes irradiâncias (E_d e E_u).

A ligação entres as IOPs e as AOPs de um meio pode ser feita por meio da equação de transferência radiativa, levando em conta as condições externas como condições de contorno (KIRK, 2011). Estudos mostraram que a reflectância é diretamente proporcional ao retroespalhamento da luz que penetra na coluna d'água e inversamente proporcional ao coeficiente de absorção total (MOREL; GENTILI, 1991; GORDON, 1991), o que permite usar medidas de reflectância obtidas por sensoriamento remoto para obter informações sobre os COAs da água, dado que tanto o retroespalhamento quanto a absorção são funções dos COAs (GORDON et al., 1989). Esta relação é definida como:

$$r_{rs}(\lambda) = \frac{f}{Q} * \left(\frac{b_b(\lambda)}{\alpha_t(\lambda) + b_b(\lambda)} \right) \quad (2.8)$$

Onde $b_b(\lambda)$ é o coeficiente de retroespalhamento total, $\alpha_t(\lambda)$ o coeficiente de absorção total, f/Q é um termo que depende do campo de luz incidente e que

considera o efeito da interface ar-água, da variação da $R_{rs}(\lambda)$ devido a variação angular do campo de luz incidente e o efeito de espalhamento bidirecional (KIRK 1984; GORDON, 1989). O coeficiente de absorção total $\alpha_t(\lambda)$ é a soma de todas as absorções:

$$\alpha_t(\lambda) = \alpha_w(\lambda) + \alpha_{CDOM}(\lambda) + \alpha_{phy}(\lambda) + \alpha_{det}(\lambda) \quad (2.9)$$

Onde $\alpha_w(\lambda)$ correspondem à absorção pela água pura, $\alpha_{CDOM}(\lambda)$ pela matéria orgânica colorida dissolvida, $\alpha_{phy}(\lambda)$ pelo fitoplâncton, $\alpha_{det}(\lambda)$ pelos detritos e λ representa o comprimento de onda.

O coeficiente de espalhamento $b(\lambda)$, por sua vez, é correntemente subdividido em duas frações em função da direção de espalhamento; coeficiente de espalhamento frontal $b_f(\lambda)$; e coeficiente de retroespalhamento $b_b(\lambda)$. O $b_b(\lambda)$ se refere ao espalhamento entre 90 e 180°, em relação a direção de propagação da luz. O retroespalhamento pode ser determinado pela Equação 2.10.

$$b_b(\lambda) = b_{bp}(\lambda) + b_{bw}(\lambda) \quad (2.10)$$

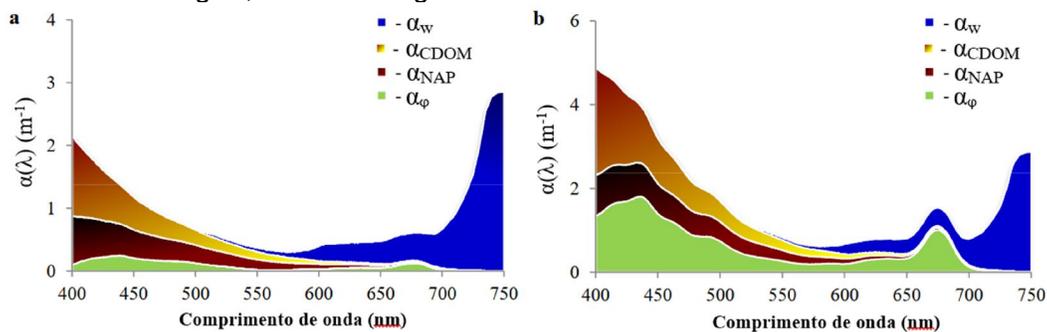
Onde o $b_b(\lambda)$ é o retroespalhamento total, $b_{bp}(\lambda)$ é o retroespalhamento por partículas e $b_{bw}(\lambda)$ é o retroespalhamento da água.

2.3 Componentes Opticamente Ativos

Os constituintes presentes no meio aquático que interagem com a luz (REM), alterando sua composição espectral, sua trajetória e intensidade, são denominados de componentes opticamente ativos (COAs) (KIRK, 2011). Os COAs são os responsáveis pelas IOPs e por parte das AOPs do meio aquático, por meio de sua composição físico-química (KIRK, 2011; MOBLEY, 1994). A resposta espectral das águas naturais é alterada pelos processos de absorção e espalhamento nos COAs, variando também com a concentração de cada

constituente (KIRK, 2011). Os principais COAs são a água pura, a matéria orgânica dissolvida, o fitoplâncton e o material particulado em suspensão (MOBLEY et al., 2017). A seguir, são apresentadas de forma sucinta as IOPs dos principais COAs e sua influência na absorção e espalhamento no meio aquático. A Figura 2.2 apresenta o comportamento espectral de absorção típico dos principais COAs.

Figura 2.2 - Comparação dos coeficientes de absorção do fitoplâncton, partículas não algais, CDOM e a água.



Comparação de a_{phy} , a_{NAP} , a_{CDOM} e a_w para duas estações com concentrações de Chl-a de $4,6 \text{ mg.m}^{-3}$ (a) e $58,1 \text{ mg.m}^{-3}$ (b).

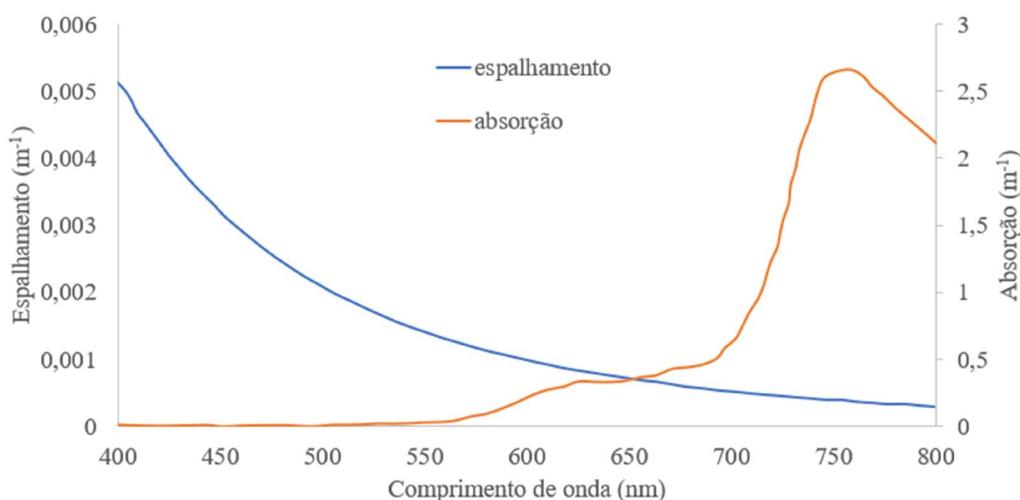
Fonte: Adaptado de Gurlin (2012).

2.3.1 Água pura

A água pura é composta por uma mistura de isótopos de água, com diferentes massas moleculares (POZDNYAKOV; GRASSL, 2003). Ela possui um coeficiente de absorção baixo nas regiões do azul e do verde, apresentando absorção significativa da radiação a partir de 550 nm, e crescente em direção ao infravermelho, podendo encobrir o sinal de outros constituintes, prejudicando os estudos do comportamento espectral de ambientes no final do visível, NIR e parte do infravermelho médio (SWIR) (SZEKIELDA, 1988). De acordo com Kirk (2011), a presença de dois "ombros" no coeficiente de absorção da água pura, aproximadamente entre 610-620 nm e 660-670 nm, podem ser associados aos processos vibracionais das ligações O-H da molécula de água no estado líquido (Figura 2.3).

Em relação ao coeficiente de espalhamento, a água pura possui seu pico no azul, conferindo sua coloração azul em locais com baixas concentrações de particulados e materiais dissolvidos, e reduz exponencialmente ao longo do espectro (MOBLEY, 1994; MOREL; PRIEUR, 1977). Por se tratar de um solvente universal, a água pura não é encontrada em ambientes naturais (MOBLEY, 1994). A Figura 2.3 apresenta os α , b da água pura.

Figura 2.3 – Coeficientes de α e b da água pura.



Fonte: Adaptado de Dekker (1993).

2.3.2 Matéria Orgânica Dissolvida

A matéria orgânica dissolvida - (MOD) é definida como todo material resultante da filtração da água natural em um determinado tamanho de poro, para qual não existe consenso na literatura, variando de 0,2 a 0,7 μm . A MOD é composta por ácidos húmicos e fúlvicos, e suas proporções são determinadas pela origem da matéria, sendo denominada autóctone, quando advinda da decomposição de fitoplâncton e zooplâncton no próprio meio, e alóctone quando proveniente de fontes externas (KIRK, 2011). A parte da MOD que interage com a REM é referida por Mobley (1994) como substância amarela ou matéria orgânica dissolvida colorida - CDOM (do inglês, *Coloured Dissolved Organic Matter*). O CDOM inclui substâncias orgânicas, bem como sais

inorgânicos, sendo definido operacionalmente como o material que passa através de um filtro de tamanho de poro nominal de 0,2 micrômetros (BRICAUD et al., 1981).

Em ambientes interiores a absorção da REM é dominada pelo CDOM, principalmente no azul e parte do verde, em oposição às águas oceânicas em que a absorção é dominada pelo fitoplâncton (MISHRA et al., 2017). Kutser et al. (2005) classificam o CDOM como a parte da MOD que interagem com a REM na região do ultravioleta (UV) e do visível. O CDOM exibe uma feição de absorção na porção ultravioleta do espectro devido à sua fração orgânica, e decai de forma aproximadamente exponencial em direção aos comprimentos maiores (KIRK, 2011) (Figura 2.2).

A alta absorção do CDOM em comprimentos de onda menores, na região do azul, reduz a disponibilidade de radiação nesta região, podendo influenciar na produtividade primária (KUTSER et al., 2005). Em contrapartida essa feição de absorção do CDOM tem o importante papel de proteger a biota da radiação UV-B (LAURION et al., 1998).

2.3.3 Total de Sólidos em Suspensão

Todo o material particulado presente no meio aquático que não passa através de um filtro com poro de 0,45 μm compõe o TSS ou também chamado de *Seston* (DEKKER, 1993). O TSS consiste de matéria orgânica viva (fitoplâncton e outros), matéria orgânica morta e inorgânica, os dois últimos podendo ser agrupados sob o nome de Trípton (MISHRA et al., 2017). A origem da fração inorgânica (TSI) do TSS está associada ao intemperismo de rochas e solos causada pela ação de chuvas e ventos, podendo ser transportados para os corpos hídricos por escoamento superficial (MOBLEY, 1994).

Para propósitos de caracterização óptica, o TSS é fracionado em organismos clorofilados microscópicos (fitoplâncton) e NAP. A NAP é composta de partículas inorgânicas e orgânicas não-algais em suspensão. A fração orgânica da NAP, produtos de degradação do fitoplâncton, é denominada de detrito.

Esta separação é feita devido a grande diferença em termos de interação que cada fração tem com a REM.

O aumento da concentração de TSS acarreta em alterações no espectro de reflectância do corpo d'água, principalmente na região compreendida entre 570 a 700 nm. Essa mudança é caracterizada pelo deslocamento do pico de máxima reflectância e de sua magnitude em direção ao final do espectro visível (vermelho). A partir de 750 nm, devido à alta influência da absorção pela água, os valores de reflectância tendem a se reduzir em direção ao infravermelho médio, independente da concentração de TSS. O TSS apresenta elevada absorção nos menores comprimentos de onda devido a suas frações de Trípton e fitoplâncton, a qual se reduz em direção ao vermelho (Figura 2.2), onde o fitoplâncton se destaca pelo pico em torno de 665 nm (DEKKER, 1993).

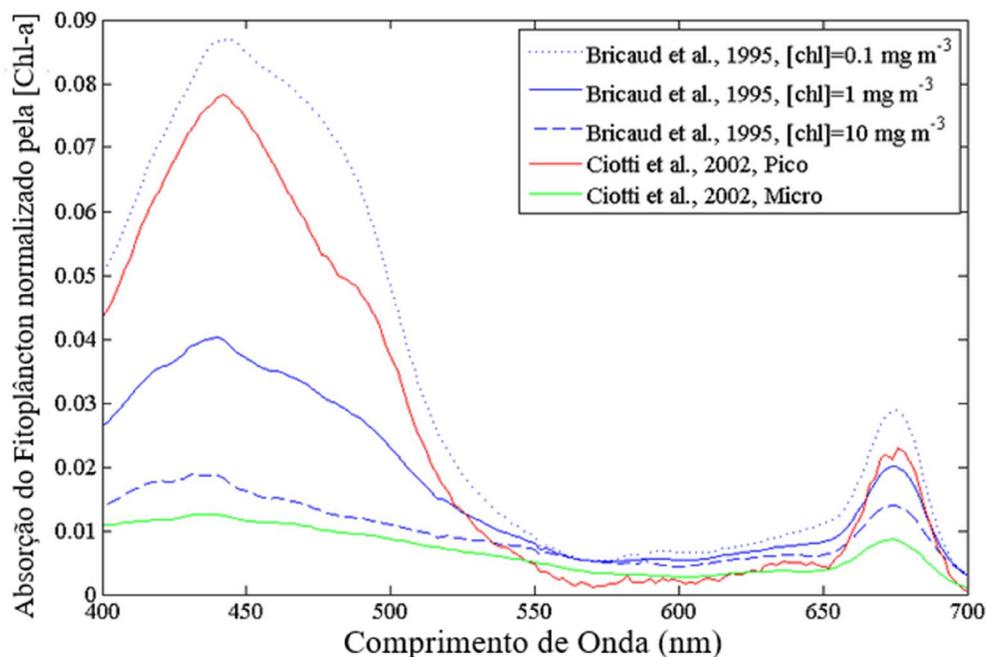
2.3.4 Fitoplâncton

O plâncton é formado por são organismos vivos tais como o fitoplâncton, zooplâncton e bacterioplâncton, os quais vivem em suspensão na coluna d'água de lagos, rios e mares (KIRK, 2011). O fitoplâncton é formado por organismos microscópicos, unicelulares, filamentosos ou coloniais, responsáveis pela parte foto autotrófica do plâncton (ESTEVES, 1998). A presença de diferentes pigmentos no fitoplâncton indica a existência de grupos distintos, caracterizados por cores específicas, ou seja, um comportamento espectral variado conforme sua composição, tamanho e formato (KIRK, 2011). Além da Chl-a que está presente em todos os tipos de algas, outros pigmentos podem interagir com a REM como clorofila-b e c, os carotenoides e ficobiliproteínas em função do grupo taxonômico do organismo presente no corpo d'água. Pigmentos acessórios não fotossintetizantes existentes no fitoplâncton, como os carotenoides e as ficobiliproteínas, também interagem com a REM, apresentando um comportamento espectral característico para cada grupo (KIRK, 2011). A ficocianina é o principal pigmento do grupo das ficobiliproteínas em águas interiores, sendo que sua absorção pode ser

utilizada como *proxy* da presença de cianobactérias (DEKKER, 1993; KIRK, 2011).

Dentre os pigmentos capazes de absorver a REM, a Chl-a destaca-se como o principal componente fitoplanctônico para o SR de ambientes aquáticos, uma vez que está presente em todos os gêneros conhecidos, possuindo dois picos bem definidos de absorção, um na região do azul (440 nm) e outro no vermelho (675 nm) (Figura 2.4). Águas com altas concentrações de Chl-a podem apresentar um comportamento típico de vegetação na região espectral do infravermelho o qual pode ser associado com o aumento da biomassa do fitoplâncton. Usualmente, a Chl-a é utilizada como indicador de bio-produção em ambientes aquáticos, por estar presente em todos os tipos de algas. O pico de absorção da Chl-a pode ser influenciado pela absorção de outros pigmentos e também pelo efeito de empacotamento dentro das células (CIOTTI et al., 2002), em que a absorção deixa de ter uma relação com a concentração de Chl-a (Figura 2.4).

Figura 2.4 – Coeficiente normalizado de absorção da Chl-a no fitoplâncton.



Fonte: Mobley et al. (2017).

Cerca de 1% da energia absorvida pelo fitoplâncton é reemitida na forma de fluorescência, sendo observada na região após o pico de absorção do vermelho entre 681 e 685 nm (KIRK, 2011). Este processo age como mecanismo de proteção, em que parte da energia absorvida é reemitida em forma de energia luminosa. A fluorescência age como um termorregulador para a célula, evitando que a mesma se danifique. Pode-se notar um aumento na magnitude do pico de fluorescência em 685 nm, em águas com maiores concentrações de fitoplâncton (GITELSON et al., 2000).

Estudos em relação ao espalhamento do fitoplâncton ainda são limitados, devido às dificuldades técnicas no desenvolvimento de equipamentos que permitam aferir com precisão o espalhamento. Historicamente, modelos teóricos baseados na teoria de Mie eram utilizados para inferir sobre as propriedades espalhadoras do fitoplâncton (CLAVANO et al., 2007; STRAMSKI, 2010). O retroespalhamento está relacionado com o tamanho e morfologia do fitoplâncton, porém este espalhamento é muito pequeno quando comparado ao de COAs como partículas orgânicas não vivas e inorgânicas (BRICAUD; MOREL, 1986). Porém, seu espalhamento é maior na região do verde (550-570 nm) e infravermelho próximo (próximo à 715 nm), devido ao espalhamento pelas células do fitoplâncton. Em ambientes com a presença de outros COAs, como os sedimentos em suspensão e o CDOM, estas feições podem ser mascaradas (DEKKER, 1993).

2.3.5 Partículas Não Algas

O NAP é composto de partículas inorgânicas suspensas, partículas orgânicas vivas e matéria orgânica detritica (KIRK, 2011). O NAP possui um espectro de absorção que se aproxima de uma exponencial, assim como o CDOM, com valores mais altos no ultravioleta e azul. A inclinação (*slope*) da curva espectral e magnitude da absorção, distintas para o NAP e o CDOM, auxiliam na sua diferenciação. A presença de materiais orgânicos e inorgânicos, de diferentes origens, na composição, do NAP podem influenciar na forma e a magnitude da sua assinatura espectral de absorção.

2.4 Algoritmos bio-ópticos

Os algoritmos bio-ópticos para a estimativa de parâmetros de qualidade da água podem ser divididos em duas abordagens: empírica e analítica. Os algoritmos empíricos são desenvolvidos a partir de relações matemáticas e estatísticas entre medidas radiométricas obtidas *in situ* ou derivadas de sensores orbitais, e medidas limnológicas (concentrações dos COAs) de amostras coletados *in situ*. A abordagem analítica utiliza-se de conceitos da teoria de transferência radiativa e de aproximações da equação de transferência radiativa para relacionar as IOPs medidas *in situ* com medidas radiométricas extraídas de sensores orbitais. Teoricamente, os parâmetros modelados por algoritmos analíticos devem descrever toda a interação entre os COAs e as propriedades ópticas do meio, mas devido à complexidade física, ainda não é possível representá-la completamente de forma matemática. Portanto, algoritmos com uma abordagem híbrida, denominados semi-analíticos, visam auxiliar o entendimento dos processos de interação por meio da combinação de parcelas teóricas e empíricas, tornando estes algoritmos mais viáveis na prática. Segundo Odermatt et al. (2012) estes algoritmos são "semi" analíticos por possuírem algumas premissas baseadas em aproximações estatísticas. As abordagens empírica e semi-analítica, são discutidas nas seções a seguir.

2.4.1 Abordagens empíricas e semi-empíricas

Os algoritmos empíricos são geralmente baseados na relação entre o sinal captado em diversos comprimentos de onda a fim de encontrar a melhor razão ou combinação que se relacione com o parâmetro desejado (LEE, 2006). A validação das relações empíricas entre os dados *in situ* e dos sensores remotos é realizada através de técnicas estatísticas (MATTHEWS, 2011). Dentro desta categoria, existem ainda os algoritmos semi-empíricos, que se utilizam de conhecimento prévio das características espectrais dos parâmetros desejados, para auxiliar a escolha das bandas de maior interesse para desenvolvimento do algoritmo (ODERMATT et al., 2012).

Os algoritmos empíricos e semi-empíricos são utilizados para derivar diversos parâmetros do meio aquático como: turbidez, TSS e pigmentos fitoplantônicos (Chl-a e a ficocianina). A estimativa da Chl-a tem um papel histórico importante em estudos de ambientes aquáticos pela facilidade de obtenção de dados *in situ* e por sua relação com as IOPs. Outros parâmetros tornaram-se passíveis de serem modelados com o avanço da instrumentação disponível (LEE, 2006). Matthews (2011) aponta a relativa simplicidade dos algoritmos empíricos como um dos fatores para sua vasta utilização, porque demandam pequeno tempo computacional e apresentam resultados bem satisfatórios quando parametrizados adequadamente. A utilização de algoritmos empíricos e semi-empíricos esbarra no problema de serem específicos para o conjunto de dados para os quais foram modelados, porém, podem ser rápidos, simples e eficientes. Estes algoritmos podem servir de apoio às estimativas de parâmetros de qualidade da água, quando integrados a um conjunto com técnicas mais sofisticadas, principalmente em sistemas que operam em escalas temporais mais finas (MATTHEWS, 2011).

2.4.2 Abordagens semi-analíticas

As abordagens apresentadas anteriormente focam na relação entre razões de banda e na determinação de coeficientes de regressão, a fim de auxiliar nas estimativas de parâmetros de qualidade da água. Porém, o desenvolvimento de algoritmos que se utilizam de relações matemáticas, com um referencial teórico mais robusto, que possam descrever de forma mais precisa as reais interações entre a REM e os corpos d'água, tem se tornado necessário para a evolução dos estudos de ambientes aquáticos.

Os algoritmos semi-analíticos são baseados na solução de aproximações da equação de transferência radiativa, aliada a otimizações numéricas (CHEN et al., 2014; LEE et al., 2002). Estes algoritmos possuem aplicação em diversos tipos de águas, demandando apenas parametrizações e calibrações locais para um melhor desempenho na representação das propriedades inerentes do meio analisado (LEE et al., 2002). O embasamento teórico e as simulações

numéricas da equação da transferência radiativa, em que se baseiam os algoritmos semi-analíticos descritos na literatura, partem do pressuposto de que a $r_{rs}(\lambda)$ é uma função dos coeficientes de absorção (α) e espalhamento (b), e que esta relação pode ser ajustada em função dos parâmetros de proporcionalidade g_1 e g_2 (GORDON et al., 1988) (Equação 2.11).

$$r_{rs}(\lambda) = \sum_{i=1}^2 g_i \left(\frac{b_b(\lambda)}{a(\lambda) + b_b(\lambda)} \right) \quad (2.11)$$

Onde $r_{rs}(\lambda)$ é a reflectância de sensoriamento remoto de subsuperfície, g_i são parâmetros de proporcionalidade, $b_b(\lambda)$ é o coeficiente de retroespalhamento e $\alpha(\lambda)$ o coeficiente de absorção. Os fatores g_1 e g_2 geralmente variam entre 0,084 a 0,15 sr^{-1} para a radiância à nadir, e dependem de como a parcela da REM retroespalhada se relaciona com o coeficiente de retroespalhamento. Estes fatores dependem da função de espalhamento de volume entre 90° e 180° e da distribuição do campo de luz subaquático, podendo ser matematicamente rearranjado seguindo a Equação 2.12.

$$r_{rs}(\lambda) = g_1 u(\lambda) + g_2 [u(\lambda)]^2 \quad (2.12)$$

$$u(\lambda) = \frac{b_b(\lambda)}{a(\lambda) + b_b(\lambda)} = \frac{-g_1 + \sqrt{g_1^2 + 4g_2 * r_{rs}(\lambda)}}{2g_2} \quad (2.13)$$

Onde $u(\lambda)$ representa as relações entre as IOPs, de tal modo que estes parâmetros contenham a maior parte dos efeitos direcionais da equação da transferência radiativa, adaptada por Lee et al. (2002) a partir de Gordon et al. (1988) e Lee et al. (1999).

A obtenção desses parâmetros de forma precisa (Equação 2.13) é essencial, sendo este o primeiro passo da implementação de grande parte dos algoritmos

semi-analíticos. A conversão da $R_{rs}(\lambda)$ para $r_{rs}(\lambda)$ pode ser realizada por meio da Equação 2.14.

$$r_{rs}(\lambda) = \frac{R_{rs}(\lambda)}{0,52 + 1,7R_{rs}} \quad (2.14)$$

As constantes estabelecidas foram determinadas em Gordon et al. (1988) para águas opticamente profundas, e estão relacionadas com o coeficiente de reflexão da interface ar-água e a razão entre a irradiância ascendente pela radiância ascendente abaixo da superfície da água.

A Equação 2.15 apresenta o cálculo do retroespalhamento por partículas por meio de uma aproximação exponencial, onde $b_{bp}(\lambda_0)$ se refere à magnitude em determinado comprimento de onda, podendo ser obtido previamente por meio de relações empíricas com $R_{rs}(\lambda)$, ou através de métodos para solução de sistemas de equações. O fator η se refere à inclinação da curva, podendo esta pré-selecionada de acordo com a metodologia adotada pelo algoritmo, baseando-se nas características do meio aquático.

$$b_{bp}(\lambda) = b_{bp}(\lambda_0) + \left(\frac{\lambda}{\lambda_0}\right)^{-\eta} \quad (2.15)$$

A Equação 2.16 descreve a parcela referente ao coeficiente de absorção do CDOM e detrito, partindo do pressuposto de que este pode ser simplificado para uma equação exponencial. Desta forma, podemos destacar que tanto η quanto S são selecionados de forma semelhante, podendo utilizar bancos de dados para a obtenção de um valor médio, estabelecer limiares ou por meio de simulações para selecionar o valor mais adequado.

$$\alpha_{dg}(\lambda) = \alpha_{dg}(\lambda_0)e^{S(\lambda-\lambda_0)} \quad (2.16)$$

Onde $\alpha_{dg}(\lambda)$ e $\alpha_{dg}(\lambda_0)$ se referem a magnitude da absorção por detritos e CDOM, espectral e no comprimento de referência, respectivamente. S se refere a inclinação da curva, sendo esta pré-selecionada de acordo com as metodologias adotadas pelos algoritmos semi-analíticos ou, também, podendo ser determinada por relações empíricas.

A Equação 2.17 descreve o coeficiente de absorção do fitoplâncton como uma função que depende unicamente da concentração de Chl-a e do coeficiente de absorção específico do fitoplâncton ($\alpha_{\varphi}^*(\lambda)$). Este é obtido em laboratório por meio da normalização do coeficiente de absorção do fitoplâncton pela concentração de Chl-a e é o parâmetro de entrada que, normalmente, correspondente a um espectro médio para as comunidades fitoplanctônicas da região de estudo (BRICAUD et al., 1995).

$$\alpha_{\varphi}(\lambda) = [CHL] * \alpha_{\varphi}^*(\lambda) \quad (2.17)$$

2.5 Sensores orbitais

2.5.1 Sensor OLI – Landsat 8

O Landsat 8 foi lançado em 11 de fevereiro de 2013 e começou a operar em 30 de maio de 2013. Com tempo de revisita de 16 dias, e com passagem pelo Equador às ~10:11 da manhã, o sensor *Operacional Land Imager* (OLI) a bordo do Landsat 8 possui nove bandas espectrais, sendo oito bandas com resolução espacial de 30 metros e uma banda pancromática de 15 metros (Tabela 2.1). O tamanho aproximado da cena Landsat-8 é de 170 km ao norte-sul por 183 km a leste-oeste. Em comparação com seus antecessores, os sensores *Thematic Mapper* (TM / Landsat 4-5) e *Enhanced Thematic Mapper Plus* (ETM+ / Landsat 7), o OLI possui como vantagem a maior razão sinal-ruído (SNR do inglês, signal-to-noise ratio), relacionada ao maior tempo de integração durante a varredura e maior resolução radiométrica (de 8 para 12 bits). A presença da banda centrada em 443 nm, utilizada para águas costeiras e para a estimativa

de aerossol, é também de grande importância para aplicação de correções atmosféricas e estudos de ambientes aquáticos (JENSEN, 2009).

Tabela 2.1 - Características do sensor OLI – Landsat 8.

Sensor / Bandas	Faixa Espectral (nm)	Resolução Espacial (m)	Resolução radiométrica (bits)	SNR
OLI/B1	435 - 451	30	12	238
OLI/B2	452 - 512	30	12	364
OLI/B3	533 - 590	30	12	302
OLI/B4	636 - 673	30	12	227
OLI/B5	851 - 879	30	12	204
OLI/B6	1566 - 1651	30	12	265
OLI/B7	2107 - 2294	30	12	334
OLI/B8	500 - 680	15	12	148
OLI/B9	1360 - 1380	30	12	160

Fonte: Barsi et al. (2014).

2.5.2 Sensor MSI – Sentinel-2

O sensor MSI (*MultiSpectral Instrument*) a bordo do satélite Sentinel-2A (S2A) entrou em operação em junho/2015, sendo o primeiro da série de dois satélites idênticos que operam com orbitas defasadas de 180 graus. O sensor é do tipo *pushbroom*, com resoluções espaciais de 10 m / 20 m / 60 m, resolução temporal de 10 dias no equador e resolução radiométrica de 12 bits (DRUSCH et al., 2012). O Satélite Sentinel-2B foi lançado em março de 2017 e possibilitou a redução do tempo de revisita para 5 dias devido à defasagem de sua órbita em relação ao S2A. O MSI possui 9 bandas espectrais de interesse, sendo estas no espectro visível, NIR e SWIR (Tabela 2.2). Este sensor se destaca pela presença das bandas no *deep blue* (443 nm) para recuperação de aerossóis, de uma banda para a identificação de *Cirrus* (1375 nm) e três bandas na região correspondente ao chamado vermelho limítrofe (*red-edge*) que auxiliam em estudos aquáticos e da vegetação. Devido ao seu tempo de revisita, este sensor se mostra ainda mais relevante em áreas que apresentam altos índices de cobertura de nuvens, como a região Amazônica. As cenas MSI são disponibilizadas pelo programa Copernicus como produto "Level-1C"

(L1C), projetadas em UTM/WGS84 e com correções radiométricas e geométricas (BAILLARIN et al., 2012).

Tabela 2.2 - Características do sensor MSI – Sentinel-2.

Sensor /Bandas	Faixa Espectral (nm)	Resolução Espacial (m)	Resolução radiométrica (bits)	SNR
MSI/B1	433 - 453	60	12	114
MSI/B2	447,6 - 545,6	10	12	439
MSI/B3	537,5 - 582,5	10	12	102
MSI/B4	645,5 - 683,5	10	12	79
MSI/B5	694,4 - 713,4	20	12	45
MSI/B6	731,2 - 749,2	20	12	45
MSI/B7	768,5 - 796,5	20	12	34
MSI/B8	762,6 - 907,6	10	12	26
MSI/B8	848,3 - 881,3	20	12	20
MSI/B9	932 - 958	60	12	16

Fonte: ESA (2017).

2.5.3 Sensor OLCI – Sentinel-3

O Sensor OLCI (*Ocean and Land Colour Instrument*) a bordo do satélite Sentinel-3, lançado em 16 de fevereiro de 2016, foi projetado para ser sucessor do ENVISAT MERIS. A compatibilidade das bandas dos sensores OLCI e MERIS, principalmente na região do "red-edge", possibilita a continuidade de estudos com dados MERIS, mesmo após ter saído de operação em maio 2012. O OLCI Possui 21 bandas programáveis entre 400 e 1020 nm, com resolução espacial de 300 metros para aplicações costeiras e terrestres e 1,2 km para utilização em oceano aberto (Tabela 2.3). Seu método de varredura é do tipo *push-broom* com cinco módulos de câmera compartilhando o campo de visada, cada câmera tem um campo individual de 14,2° e uma sobreposição de 0,6° com seus vizinhos. Seu tempo de revisita é de 2 dias no equador, com um campo de visada de aproximadamente 1300 km (ESA, 2015).

Tabela 2.3 - Características do sensor OLCI – Sentinel-3.

Sensor /Bandas	Faixa Espectral (nm)	Resolução Espacial (m)	Resolução radiométrica (bits)	SNR
OLCI/B1	400	300	12	2188
OLCI/B2	413	300	12	2061
OLCI /B3	443	300	12	1811
OLCI /B4	490	300	12	1541
OLCI /B5	510	300	12	1488
OLCI /B6	560	300	12	1280
OLCI /B7	620	300	12	997
OLCI /B8	665	300	12	883
OLCI /B9	674	300	12	707
OLCI /B10	682	300	12	745
OLCI /B11	709	300	12	785
OLCI /B12	754	300	12	605
OLCI /B13	761	300	12	232
OLCI /B14	764	300	12	305
OLCI /B15	767	300	12	330
OLCI /B16	779	300	12	812
OLCI /B17	865	300	12	666
OLCI /B18	885	300	12	395
OLCI /B19	900	300	12	308

Fonte: ESA (2017).

2.5.4 Correções atmosféricas

A utilização dos sensores orbitais para a identificação de propriedades ópticas aquáticas tem se mostrado bastante satisfatória. As propriedades ópticas dos COAs no meio aquático apresentam uma robusta relação com a cor superficial da água nas imagens. Porém, uma grande parte da energia detectada pelos sensores são derivados dos efeitos da atmosfera. Esse problema é agravado devido a baixíssima reflectância proveniente dos corpos de água, o que torna a correção atmosférica crucial para este tipo de estudo (MATTHEWS, 2011; WANG, 2010). A qualidade dos dados é diretamente dependente das características dos sensores, da interação entre a atmosfera e a REM e do método de correção atmosférico aplicado (OKIN; GU, 2015). Os modelos físicos de correção atmosférica também se baseiam em equações de transferência radiativa para calcular de forma aproximada os parâmetros físicos da atmosfera local (VERMOTE et al., 1997). Este tipo de modelo utiliza-se de dados independentes à imagem para determinação dos parâmetros

atmosféricos, bem como o seu processo de interação com a REM (ZULLO-JUNIOR, 1994). Os modelos de transferência radiativa mais difundidos são 5S, 6S, LOWTRAN e MODTRAN.

O modelo (6SV) é um consolidado código computacional utilizado para simular os efeitos atmosféricos através de códigos de transferência radiativa, sendo um aprimoramento de seu antecessor (5S) criado pelo *Laboratoire d'Optique* (VERMOTE et al., 1997). Os parâmetros de entrada para estes modelos são: condições do local, modelo atmosférico para os componentes dos gases, modelo de aerossóis, banda espectral de observação, tipo de reflectância do terreno e variação espectral. A transmitância dos gases, a irradiância da superfície e as diferentes contribuições para o sinal do satélite de acordo com a origem da radiância medida são também produzidas por códigos. Este modelo também simula as contribuições para o sinal do satélite, bem como a transmitância dos gases e a irradiância da superfície (VERMOTE et al., 1997).

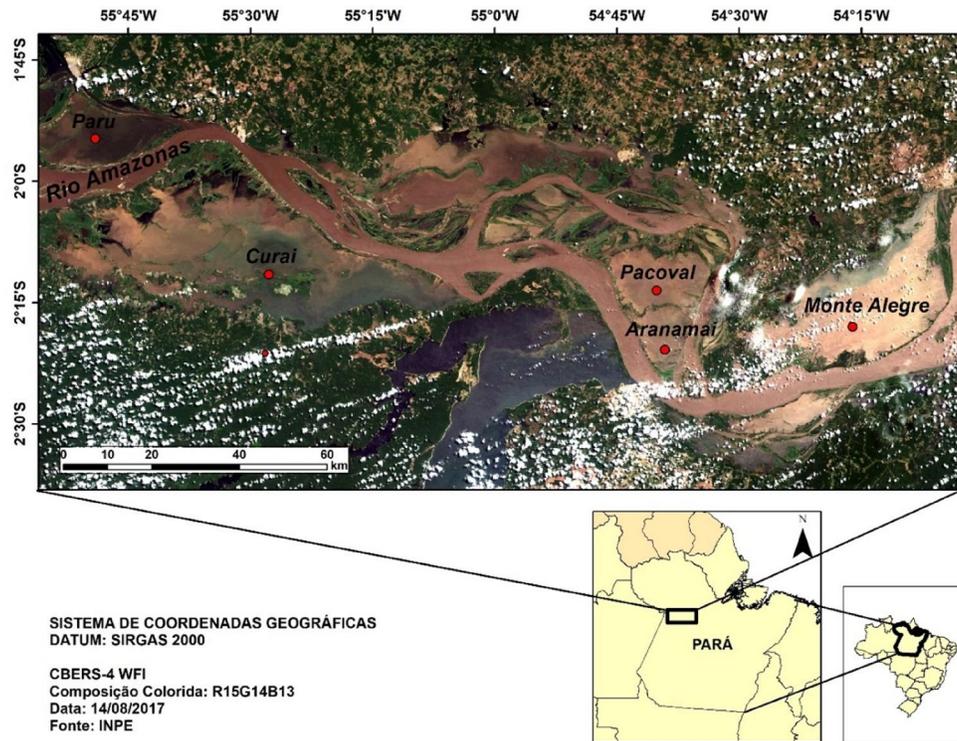
3 METODOLOGIAS DE AQUISIÇÃO E PROCESSAMENTO DE DADOS *IN SITU* E ORBITAIS

3.1 Área de estudo

A área de estudo deste trabalho é composta por 5 lagos (Lago Grande Curuai, Monte Alegre, Paru, Pacoval e Aramaná) localizados na região do Baixo Amazonas, próximo das cidades de Santarém, Óbidos e Monte Alegre, e a cerca de 900 quilômetros da foz do rio Amazonas (Figura 3.1). A precipitação média total anual é de 2447 mm/ano na planície Curuai (ALCANTARA et al., 2007).

Analisando a dinâmica do nível d'água para a estação fluviométrica de Óbidos (dados da Agência Nacional de Águas – ANA) no rio Amazonas próximo aos lagos de estudos, é possível notar que junho é o mês de cota máxima, e a mínima ocorre no mês Novembro (Figura 3.2). A cota tem seu mínimo de 61 cm em novembro de 2015 e máximo de 809 cm em junho de 2015, para todo o período analisado.

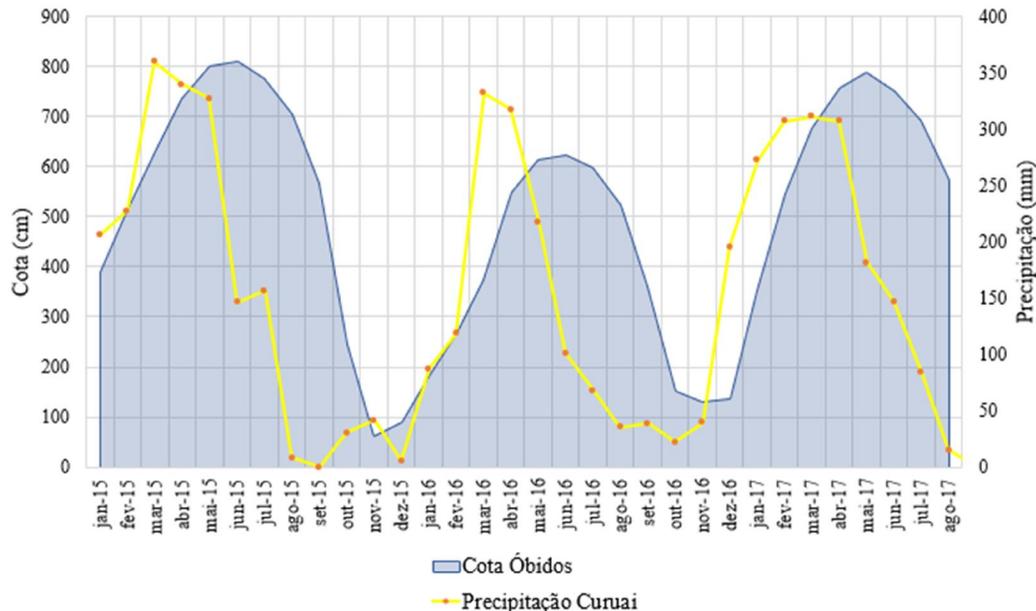
Figura 3.1 - Lagos da área de estudo.



Fonte: Produção do Autor.

O regime hidrológico da região da planície pode ser dividido em quatro estágios diferentes, relacionando os períodos de cheia e seca: época de enchente, caracterizado pelo aumento no nível da água nos meses de Janeiro e Fevereiro; época de cheia, quando as cotas atingem os valores máximos entre os meses de Abril e Junho; época da vazante com a diminuição do nível d'água, nos meses de Agosto, Setembro e Outubro; e águas baixas nos meses de Outubro e Novembro, com pouca variação no nível da água (BARBOSA, 2005). Dados mensais de precipitação foram obtidos para a estação pluviométrica do Lago Grande Curuai, devido a indisponibilidade destes dados na estação de Óbidos.

Figura 3.2 - Cota da estação Óbidos e precipitação da estação Curuai.



Fonte: Produção do Autor.

Os lagos da planície de inundação do Baixo Amazonas são tipicamente grandes, de baixa profundidade e com a presença de vegetação herbácea em suas margens. No período de baixa da água, a área dos lagos é reduzida e comumente utilizada para pecuária bovina e bubalina (BARBARISI, 2010). Neste período, a profundidade da lâmina d'água pode atingir menos de um metro, possibilitando a ressuspensão de sedimentos pelos efeitos do vento na planície, tornando este o período com maior concentração de materiais em suspensão (BARBOSA et al., 2009). A influência dos ventos na mistura dos materiais controla as variações destas concentrações, em conjunto com a profundidade e a direção de propagação. Nos períodos de vazante e cheia estes lagos são ocupados por bancos de macrófitas.

3.2 Materiais

Os dados utilizados neste trabalho são advindos das quatro missões de campo realizadas entre os anos 2015 e 2017 com subsídio do projeto, MAS-BNDES 1022114003005. A primeira missão em junho de 2015, a segunda e terceira em

março e julho de 2016 respectivamente, e a quarta em agosto de 2017. Estas missões representam respectivamente os períodos da cheia, enchente, início da vazante e final da vazante. Ao todo são 94 pontos de amostragem para todos os lagos (Figura 3.1).

3.2.1 Dados coletados *in situ*

3.2.1.1 TriOS

Os dados radiométricos foram coletados entre as 10:00 e 14:00 horas, visando a manutenção da geometria de aquisição em relação à quantidade de luz disponível (MOBLEY, 1999). Em cada estação foram coletadas medidas acima e abaixo da superfície da água, utilizando os radiômetros hiperespectrais RAMSES TriOS (TRIOS, 2015), operando entre 320 e 950 nm, com tempo de integração variável de 4 ms⁻¹ a 8s e resolução espectral de 3,33 nm em 190 canais.

A geometria de aquisição foi determinada seguindo os protocolos descritos por Mobley (1999) e Mueller et al. (2003), com o posicionamento dos sensores e do barco visando evitar reflexões especulares e sombras do próprio barco. Os instrumentos foram acoplados a estruturas fixadas no barco, na proa, para as medidas acima da superfície, e na lateral para o perfil abaixo da superfície. Acima da água foram coletadas as frações L_w a 45° do nadir, L_{sky} a 90° de L_w e a irradiância incidente na superfície da água E_s . Os sensores na parte lateral do barco se referem às medidas dentro da água, com dois sensores de irradiância e um sensor de radiância. Todos os sensores de radiância possuem campo de visada de 7° e os sensores irradiância possuem coleta hemisférica (coletor cosseno). Os três sensores foram fixados em posição vertical, sendo dois destes voltados para baixo (E_u e L_u) e um voltado para cima (E_d). Em cada estação amostral foram realizadas em média 130 medidas, dado que as medidas acima da água foram realizadas concomitantemente com as medidas de perfil na coluna de água. Os dados coletados por meio dos sensores RAMSES TriOS foram utilizados para a determinação da reflectância de sensoriamento remoto ($R_{rs}(\lambda)$).

O pré-processamento dos dados RAMSES TriOS consistiu, primeiro, na interpolação linear dos originais, de ~3,3 nm para 1 nm, visto que os sensores não medem nos mesmos comprimentos de onda, padronizando assim as medidas entre os seis sensores do equipamento. A partir disto, a $R_{rs}(\lambda)$ foi calculada com base na Equação 2.5 apresentada na seção anterior. Porém, segundo Mobley (1999) a radiância medida por um sensor apontado para a água, possui uma fração emergente da coluna d'água $L_w(\lambda)$ e outra advinda da reflexão especular da luz direta do sol (*sunglit*) e com a radiação difusa do céu (*skylint*) que foi refletida pela superfície da água em direção ao sensor ($L_r(\lambda)$) (Equação 3.1). $L_r(\lambda)$ pode ser estimada pela Equação 3.2.

$$L_t(\theta, \Phi, \lambda) = L_w(\theta, \Phi, \lambda) + L_r(\theta, \Phi, \lambda) \quad (3.1)$$

$$L_r(\theta, \Phi, \lambda) = \rho L_s(\theta', \Phi', \lambda) \quad (3.2)$$

Em que $L_r(\theta, \Phi, \lambda)$ corresponde ao *sunglit* e *skylint* que foi refletida em direção ao sensor (θ e Φ), $L_s(\theta, \Phi, \lambda)$ é a radiância espectral difusa do céu e ρ é o fator de proporcionalidade que relaciona a radiância medida quando o sensor observa o céu pela radiância atmosférica refletida, medida quando o sensor está apontado para a superfície da água. Mobley (1999) estimou por meio de simulações o valor de $\rho = 0,028$ quando a velocidade do vento é inferior a 5 ms^{-1} . Assim, utilizando a metodologia atualizada em Mobley (2015), a $R_{rs}(\lambda)$ foi corrigida em função do coeficiente de reflexão especular da água (ρ), determinado pelos dados de vento, latitude, longitude, horário e data para cada ponto (Equação 3.3).

$$R_{rs}(\lambda) = \frac{L_t(\theta, \Phi, \lambda) - \rho L_s(\theta', \Phi', \lambda)}{E_d(\lambda)} \quad (3.3)$$

Após o cálculo da $R_{rs}(\lambda)$ para todo o tempo de amostragem, foi realizada para cada ponto a seleção da curva espectral mais representativa. Esta seleção de espectros visa reduzir ruídos produzidos na aquisição dos dados devido a condições externas do ambiente (ex. ondas e reflexão especular) que não são levados em conta pela correção de Mobley (2015). Para isto, o primeiro passo consiste na remoção dos espectros de $R_{rs}(\lambda)$ considerados *outliers*. No segundo passo, a curva que apresentar menor disparidade em relação à mediana em todo o espectro é selecionada como mais representativa para cada ponto amostral.

3.2.1.2 AC-S

Em relação as propriedades óticas inerentes, os coeficientes de atenuação e absorção foram adquiridos em perfil contínuo na coluna d'água pelo equipamento AC-S, um medidor de absorção e atenuação espectral (do inglês, *Spectral Absorption and Attenuation Meter*), com caminho óptico de 10 cm e resolução de 3,5 nm na região espectral entre 400 e 750 nm. O equipamento é composto por um tubo para medir a atenuação e outro para medir a absorção. O tubo da atenuação é projetado para remover influência da radiação espalhada no sensor, devido a sua parede altamente absorvedora. Já o tubo de absorção possui uma parede lateral espelhada, não absorvendo e redirecionando a radiação para o sensor, com o objetivo de reduzir o efeito do espalhamento. Juntamente com o AC-S, um sensor CTD (do inglês, *Conductivity, Temperature and Depth*), obteve medidas de condutividade, temperatura e pressão do perfil. Foi realizada uma calibração de acordo com a metodologia descrita em Wetlabs, (2009), utilizando água deionizada como a referência, como preparação do AC-S antes de cada campanha de campo.

O procedimento de aquisição dos dados iniciou-se pela profundidade 3 metros, seguido por 10 minutos de estabilização (*warm-up*) e remoção de bolhas/turbulências (*flush*) na mesma profundidade. O processo de perfilamento foi realizado de forma contínua a uma frequência de 1 hertz ou $4s^{-1}$, até próximo à superfície para evitar o ingresso de ar no equipamento.

O processamento dos dados coletados através do AC-S e CTD foram realizados com rotinas desenvolvidas pelo LabISA (<http://www.dpi.inpe.br/labisa/>) por meio da linguagem/software Matlab. Visando a obtenção dos coeficientes de atenuação e absorção de forma precisa, a rotina consiste na manipulação e correção dos dados do AC-S, aferindo a integridade do conjunto de dados. Primeiramente, os dados foram submetidos à interpolação linear a cada 1 nm na faixa de 400 a 750 nm. Foi realizado também a remoção da influência da água pura nas medidas, seguindo o protocolo do Wetlabs (2009). Os ruídos nos dados foram suavizados através de um filtro passa baixa de janela 3x3 e os efeitos da temperatura na absorção e atenuação foram corrigidos. Para a correção do espalhamento no tubo de absorção do AC-S, assumiu-se que a correção proposta em Kirk (1992) é a mais adequada para a área de estudo deste trabalho. Segundo Kirk, (2011) a variação da salinidade pode ser considerada desprezível em águas interiores, portanto esta correção foi desconsiderada.

3.2.2 Dados laboratoriais

O protocolo de coleta do material em campo, acondicionamento, filtração e análise laboratorial foi reproduzido em todas as campanhas. As amostras de água foram coletadas em subsuperfície em frascos de polietileno opacos e vedados contra a influência da radiação solar, e logo após armazenados em caixas de isopor com gelo para minimizar a atividade biológica. As amostras foram armazenadas em baixas temperaturas e no mesmo dia da coleta foram filtradas em um local com pouca luz e climatizado com temperatura estável. No processo de filtração foram utilizados filtros de fibra de vidro Whatman GF-F e GF-C, ambos com 47 mm de diâmetro e porosidade de 0,7 e 1,2 μm , respectivamente, para análise de clorofila, material em suspensão e carbono. Para a análise do CDOM foram utilizados filtros de nylon com 47 mm de diâmetro e porosidade de 0,2 μm .

Os filtros foram mantidos em temperaturas inferiores a 0° Celsius até as análises laboratoriais, realizadas após o fim das campanhas de campo. Os

volumes de água para as análises do CDOM, após a filtração, foram acondicionados refrigerados em frascos plásticos previamente esterilizados com ácido clorídrico (HCl). As análises foram realizadas no Laboratório de Pesquisa Ambiental em Aerossóis, Soluções Aquosas e Tecnologia (Laquatec) do Instituto Nacional de Pesquisas Espaciais (INPE).

O equipamento utilizado para realizar as medidas de absorvância, transmitância e reflectância das amostras filtradas em campo foi espectrofotômetro UV-VIS Shimadzu UV-2600. Este sensor possui uma ótica de duplo feixe que realiza as medidas nas regiões do ultravioleta, visível e infravermelho próximo, de 185 a 900 nm e podendo ser estendido até 1400 nm, possui resolução espectral de 0,1 nm e é equipado com uma lâmpada alógena de deutério, cubetas de quartzo e esfera integradora.

Foi utilizado o método "Transmitância-Reflectância" (T-R) proposto por Tassan e Ferrari (2002) para determinar o espectro de absorção da luz por partículas em suspensão, que incluem o fitoplâncton e os detritos. Por meio da esfera integradora, foi possível realizar as medidas de transmissão e reflexão da luz pelas partículas retidas no filtro. Primeiro, é realizada uma linha de base com os valores do ar (sem filtros), os filtros são umedecidos com 6 gotas de água ultrapura, e as medidas de reflectância e transmitância para cada amostra são realizadas. Para remoção dos efeitos do material que compõem o filtro é utilizado um filtro GF-F novo como referência (branco) umedecido com a mesma quantidade de água. As medidas do branco são realizadas a cada 5 medidas das amostras, visando observar possíveis variações devido a influências externas. Então, é feita a despigmentação dos filtros, utilizando 6 gotas de $\text{Na}_2\text{C}_2\text{O}_4$ (10%), deixando-as agir por 20 minutos. Após a extração dos pigmentos, o $\text{Na}_2\text{C}_2\text{O}_4$ é removido com água deionizada. Para minimizar impactos físicos, o procedimento é realizado lentamente utilizando uma conta gotas. Segundo Tassan e Ferrari (1995), esta técnica se mostrou mais eficiente em algas resistentes sem a perda de material presente no filtro. As mesmas unidades de medidas e equações são utilizadas para o filtro com pigmentos e para o filtro despigmentado. Segundo Tassan e Ferrari (2002), a verificação da eficiência durante o processo de extração pode ser vista na região do

vermelho, facilitando identificar se os pigmentos foram extraídos de forma satisfatória. O processamento dos dados resultantes das medidas no espectrofotômetro (etapas 1 e 2) se dá por meio da aplicação de uma sequência de equações (TASSAN; FERRARI, 2002):

$$\alpha_s = \frac{1 - \rho T + R_f(\rho T - \rho R)}{1 + R_f \rho T \tau} (m^{-1}) \quad (3.4)$$

Onde α_s é o coeficiente de absorção do material em suspensão (fitoplâncton + NAP na primeira etapa, e NAP na segunda etapa), ρT é a transmitância da amostra normalizada pela transmitância do branco, ρS é a reflectância da amostra normalizada pela transmitância do branco, R_f é a reflectância do branco e τ é calculado a partir da transmitância medida utilizando a equação:

$$\tau = 1,15 - 0,17(OD_{TR}(\lambda) - OD_{TR}(750)) \quad (3.5)$$

Onde $OD_{TR}(\lambda)$ é a absorbância estimada a partir do modo transmitância. Por fim, a absorbância é corrigida a partir de um ajuste empírico e o coeficiente de absorção do detrito e do fitoplâncton é estimado:

$$OD_{sus} = 0,423OD_s + 0,479OD_s^2 \quad (3.6)$$

Onde $OD_{sus}(\lambda)$ é a absorbância do material em suspensão, corrigida a partir dos valores medidos na Equação 3.5 e convertidos para valores de absorbância.

$$OD_\phi = OD_{total} - OD_{det} \quad (3.7)$$

Onde $OD_{\phi}(\lambda)$ é a absorvância do fitoplâncton, $OD_{total}(\lambda)$ é a absorvância do material particulado em suspensão corrigido (Equação 3.6) e $OD_{det}(\lambda)$ é a absorvância do detrito. A conversão de absorvância para coeficiente de absorção é feita da seguinte forma:

$$\alpha_p = \frac{2,3030 OD_{sus}(\lambda)}{X} (m^{-1}) \quad (3.8)$$

Onde X é a razão entre o volume filtrado e a área do filtro contendo amostra, em metros, correspondendo ao calor médio obtido das amostras in situ.

Com o espectrofotômetro no modo de absorvância, as medidas de CDOM foram realizadas utilizando a metodologia de Tilstone et al. (2002), e seu coeficiente de absorção foi determinado. A faixa espectral medida foi de 220 a 800 nm com uma largura espectral de 1 nm em uma cubeta de 0,1 m de comprimento. Como referência (branco) para as medições foi utilizada água deionizada em temperatura ambiente. As amostras foram retiradas da refrigeração e aclimatadas à temperatura ambiente para evitar diferenças nas medidas das amostras e da referência devido à temperatura. A leitura foi iniciada com a linha de base do branco, tomando os cuidados de evitar bolhas de ar e sujeiras nas paredes da cubeta. Em cada intervalo de leitura das amostras de diferentes estações, a cubeta era lavada três vezes com água ultrapura e as amostras eram inseridas em seu interior com o mesmo cuidado descrito acima, bem como a limpeza das laterais da cubeta. O fator de correção presente em Tilstone et al. (2002) se refere a subtração do valor do branco de cada amostra e a conversão de absorvância (OD) para coeficiente de absorção $\alpha_{CDOM}(\lambda)$ seguiu a seguinte equação:

$$\alpha_{CDOM} = \frac{2,3030 OD_{med} - OD_{br}}{L} (m^{-1}) \quad (3.9)$$

Onde L é o caminho óptico da cubeta (0,1 m), $OD_{med}(\lambda)$ é a densidade óptica medida de cada amostra e $OD_{br}(\lambda)$.

Devido à possibilidade de algumas partículas espalhadoras atravessarem o filtro e promoverem espalhamento nas amostras, faz-se necessária a aplicação de um fator de correção nas medições realizadas com o espectrofotômetro, retirando assim essa contribuição do espalhamento (BRICAUD et al., 1981). Partindo-se do pressuposto que α_{CDOM} tende a zero nos comprimentos de onda em direção ao infravermelho, o fator de correção é dado pela subtração do valor médio na região entre 750 e 800 nm de todo o espectro. O último passo se refere ao ajuste de curva de decaimento exponencial utilizando a região de 440 nm como referência fixa, obtendo-se assim o coeficiente de decaimento para a curva ajustada em 440 nm, por meio da Equação 2.16.

3.2.3 Dados orbitais

Para este estudo, foram utilizados dados provenientes do sensor OLI-Landsat 8, do sensor MSI-Sentinel-2A, obtidos dos bancos de dados da USGS ("<https://earthexplorer.usgs.gov/>") e da ESA ("<https://scihub.copernicus.eu/>"), respectivamente. A composição dos corpos d'água pode apresentar variações graduais devido aos períodos hidrológicos ou abruptas em resposta a eventos meteorológicos. A comparação dos dados *in situ* com os dados orbitais é de extrema importância para validação das estimativas dos algoritmos aplicados, sendo, portanto, fundamental determinar a defasagem entre aquisição dos dados obtidos em campo e a passagem do satélite. Para os campos de março de 2016 e junho de 2015, não haviam imagens disponíveis sem cobertura de nuvens.

Para a correção atmosférica das imagens dos sensores MSI e OLI, usou-se o método de correção atmosférica 6SV, testado em Martins et al. (2017), e que apresentou os melhores resultados para lagos da região Amazônica (VERMOTE et al., 1997). Para isto, utilizou-se de uma versão modificada do Py6S desenvolvida pelo Laboratório de Instrumentação em Sistemas Aquáticos do INPE (LabISA - <http://www.dpi.inpe.br/labisa>). Os parâmetros obtidos pelo

6SV foram aplicados para obtenção da refletância de superfície, conforme descrito em Martins et al. (2018), a qual foi então dividida por π para se obter a $R_{rs}(\lambda)$.

3.2.3.1 Reamostragem dos dados *in situ* para as bandas espectrais de sensores orbitais.

A reamostragem dos dados espectrais obtidos *in situ* para as características de cada sensor foi baseada na função resposta espectral entre 400 e 900 nm, obtidos em Barsi et al. 2014 para o sensor OLI e Esa, 2017 para os sensores MSI e OLCI. A formulação para a amostragem dos dados pode ser vista por meio da Equação 3.10.

$$D_{rs}^{Sensor}(\lambda_k) = \frac{\int_{\lambda_i}^{\lambda_j} S(\lambda) D_t(\lambda)}{\int_{\lambda_i}^{\lambda_j} S(\lambda)} \quad (3.10)$$

Onde $D(\lambda_k)$ é o dado *in situ* ajustado às bandas dos sensores, λ_i e λ_j são os limites inferiores e superiores de cada banda λ_k e $S(\lambda)$ é a função de resposta da i -ésima banda espectral de cada sensor (MARTINS et al., 2018).

3.3 Estatísticas

A fim de avaliar os resultados obtidos nos capítulos 4 e 5, o desempenho dos algoritmos (empíricos e semi-analítico) foram avaliados por meio dos métodos estatísticos da raiz do erro quadrático médio (RMSE), raiz do erro quadrático médio normalizado (NRMSE), erro percentual médio absoluto (MAPE), bias e o coeficiente de determinação (R^2). Os métodos estatísticos citados, podem ser calculados pelas equações apresentadas a seguir:

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{x_i^{est} - x_i^{med}}{x_i^{med}} \right|}{n} * 100 \quad (5.20)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i^{est} - x_i^{med})^2} \quad (5.21)$$

$$NRMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i^{est} - x_i^{med})^2}}{x_{max}^{med} - x_{min}^{med}} * 100 \quad (5.22)$$

$$Bias = \frac{1}{n} \sum_{i=1}^n (x_i^{est} - x_i^{med}) \quad (5.23)$$

Onde n é o número de amostras e x_i^{est} e x_i^{med} são, respectivamente, os valores estimados e medidos para cada amostra i .

4 ALGORITMOS EMPÍRICOS PARA ESTIMATIVA DE CLOROFILA-A

4.1 Introdução

A utilização de algoritmos empíricos e semi-empíricos possuem grande relevância em estudos para estimativa dos COAs presentes na água, com destaque principal para os algoritmos que se utilizam de razões entre bandas espectrais (DALL'OLMO; GITELSON, 2006). Algoritmos deste tipo são comumente aplicados em estimativas da concentração de Chl-a, devido a sua relação com a produtividade primária, estado trófico do ambiente e outros parâmetros secundários relacionados à qualidade da água. Razões de bandas para derivação da Chl-a tem sido largamente utilizadas em estudos nos mais diferentes tipos de ambientes aquáticos (AMMENBERG et al., 2002; DEKKER, 1993; GITELSON et al., 1985, 1987; KALLIO et al., 2003). Embora existam variações nos comprimentos de onda ótimos para a estimativa de Chl-a, algoritmos aplicados nas regiões espectrais do verde/azul e vermelho/NIR são bem consolidados na literatura para a determinação da concentração de Chl-a (MATTHEWS, 2011; ODERMATT et al., 2012).

Os primeiros algoritmos para estimativa de Chl-a foram desenvolvidos para águas do caso 1, utilizando sensores com características favoráveis à óptica hidrológica, como os sensores CZCS (*Coastal zone color scanner*) e SeaWiFS (*Sea-Viewing Wide Field-of-View Sensor*). Estes sensores possuíam bandas centradas nas regiões de absorção da Chl-a e ângulo de visada variável, reduzindo o efeito de reflexão especular (*glint*) (MATTHEWS, 2011). Esses algoritmos utilizam-se geralmente das bandas espectrais na região do azul, onde ocorre a máxima absorção por Chl-a, e a região do verde, onde a influência da absorção da clorofila é muito baixa (MATTHEWS, 2011). Avaliando o desempenho de algoritmos para estimativa de COAs, Odermatt et al. (2012) puderam concluir que os algoritmos utilizando da razão de bandas azul/verde, nomeados *Ocean Color* (OC2, OC3 e OC4), foram capazes de estimar com precisão os constituintes em águas complexas com concentrações de Chl-a até 10 mg.m^{-3} . Porém, a alta influência do CDOM e de partículas não

algais em suspensão na absorção e espalhamento, principalmente na região do azul/verde, são grandes fontes de incertezas para estes tipos de algoritmos em águas complexas por mascararem as feições da Chl-a no espectro de $R_{rs}(\lambda)$ (DALL'OLMO et al., 2005; GILERSON et al., 2010). Portanto, a utilização da região de máxima absorção por clorofila (443 nm) fica comprometida em águas do caso 2, sendo mais utilizada em águas do caso 1 (BRICAUD et al., 1981).

Buscando evitar os efeitos de outros constituintes nas estimativas de Chl-a, em águas interiores e costeiras, diversos estudos propuseram o uso de razões de bandas na região espectral do vermelho e NIR (DALL'OLMO et al., 2005; DEKKER, 1993; GILERSON et al., 2010; GITELSON, 1992; GITELSON et al., 1985; MISHRA; MISHRA, 2012). Estas razões (vermelho/NIR) se baseiam na utilização do segundo pico de absorção da Chl-a em aproximadamente 675 nm, e o pico de reflectância próximo de 708 nm (baixa influência de Chl-a), considerando uma redução exponencial da absorção do CDOM e dos sólidos em suspensão ao longo do espectro (DEKKER, 1993; GITELSON; KONDRATYEV, 1991). A utilização da razão de bandas em 675 nm juntamente com bandas do NIR (>700 nm) é frequentemente adotada na literatura para a aplicação ao estudo de águas interiores, em uma grande diversidade de ambientes, de estudos laboratoriais à rios, lagos, reservatórios e estuários, com concentrações de 0,1 até 350 mg.m⁻³ e correlações (R^2) acima de 0,80 (MATTHEWS, 2011; ODERMATT et al., 2012). Devido ao deslocamento da banda de absorção da Chl-a em 675 nm em função da variação de sua concentração, a região espectral de mínima absorção por Chl-a e de forte espalhamento pela estrutura celular do fitoplâncton pode ser deslocada em direção ao NIR (~715 nm) (GITELSON, 1992). Outros autores relataram correlações altas entre a Chl-a e a razão utilizando bandas acima de 725 nm mantendo o denominador em 675 nm (OKI; YASUOKA, 2002; PIERSON; STRÖMBECK, 2000; PULLIAINEN et al., 2001).

Algumas variações da razão vermelho/NIR subtraem o sinal da região próximo de 750 e 780 nm, assumindo que a reflectância nesta faixa é inteiramente composta pelos efeitos atmosféricos (MATTHEWS, 2011). Desta maneira,

Dall'olmo et al. (2003) buscaram avaliar a aplicabilidade de um modelo de três bandas desenvolvido para a detecção da concentração de pigmentos em cascas de frutas e nas folhas dos dosséis de milho (GITELSON et al., 2003; MERZLYAK et al., 2003). O algoritmo é semelhante à razão entre 2 bandas, no qual são utilizadas as bandas com alta (λ_1) e baixa (λ_2) influência do pigmento analisado na absorção e que possuam retroespalhamento semelhante, com a adição de uma terceira banda (λ_3) localizada na região com mínimo efeito de absorção por outros componentes (Chl-a, tripton e matéria orgânica). O modelo foi ajustado e validado para águas turbidas produtivas por meio de amostras de campo em águas mesotróficas e hiper-eutrólicas. Comparando-se os resultados modelados com os dados de validação, os autores encontraram correlações de 0,990 ($p=0,86$) (DALL'OLMO et al., 2003). Gitelson et al. (2011) estimaram a concentração de Chl-a utilizando um algoritmo de 3 bandas para o sensor *Hyperspectral Imager for the Coastal Ocean* (HICO), considerando as bandas espectrais do vermelho (684 nm) e infravermelho (700 e 720 nm), em águas costeiras turbidas produtivas do Mar Azov, na Rússia. O algoritmo explicou mais de 85% da variação da concentração de Chl-a e permitiu estimativas de RMSE menores que 10 mg.m^{-3} para concentrações entre 17 e $93,14 \text{ mg.m}^{-3}$.

Avaliando o desempenho de algoritmos empíricos aplicados em imagens do sensor OLI para determinação da concentração da Chl-a, no reservatório de Barra Bonita/SP, Watanabe et al. (2015) obtiveram resultados satisfatórios. O algoritmo de 2 bandas NIR/Verde com ajuste quadrático obteve um ajuste satisfatório ($R^2 = 0,7085$) e os melhores resultados de validação (MAPE = 36,02%, $R^2 = 0,1929$) em comparação com os outros algoritmos testados pelos autores, também ajustados para as bandas simuladas do sensor OLI. Em outro estudo, no mesmo reservatório, Watanabe et al. (2017) estimaram a concentração de Chl-a usando algoritmos de duas e três bandas (GITELSON et al., 2008), o algoritmo NDCI (*Normalized Difference Chlorophyll-a Index*, de Mishra; Mishra, 2012) e o algoritmo *slope model* (MISHRA; MISHRA, 2010). Os resultados obtidos nesse trabalho mostraram que os algoritmos com razão de bandas NIR e vermelho, baseadas no sensor MSI/Sentinel-2A, apresentaram o

melhor desempenho para estimar a Chl-a, possivelmente devido a inserção do pico de reflectância em 705 nm. O algoritmo de 2 bandas não funcionou para o OLI, com resultados ruins na validação ($R^2= 0,07$), com valores de MAPE = 47,1% e NRSME = 46,4% no mapeamento da Chl-a. Entretanto, para o *slope model* obteve-se um R^2 de 0,6 para o OLI e 0,82 para o MSI.

A utilização da combinação de bandas no vermelho e infravermelho mostra-se interessante para estimar com precisão a concentração da Chl-a em águas costeiras e interiores produtivas túrbidas, principalmente com as bandas do sensor MSI no vermelho limítrofe (*red-edge*). Estudos apresentados por Koponen et al. (2002) demonstraram a melhora nas correlações utilizando a adição da terceira banda, porém, isto pode não ser suficiente em águas muito túrbidas, devido a influência remanescente dos materiais particulados (MOBLEY, 1994).

Ainda que utilizem bandas apropriadas para estimar Chl-a, em diversos tipos de ambientes aquáticos, os algoritmos empíricos necessitam ser calibrados para as especificidades de cada área. Portanto, este trabalho objetivou a avaliação da aplicação de algoritmos semi-empíricos de estimativa de Chl-a em lagos túrbidos da planície de inundação do baixo amazonas, em bandas simuladas para os sensores OLI-Landsat-8 e MSI-Sentinel-2. Os algoritmos foram validados utilizando simulações de Monte Carlo (MC). Os algoritmos com melhor desempenho na validação com dados *in situ* foram aplicados às imagens orbitais dos sensores correspondentes. Neste capítulo, a partir deste ponto, os algoritmos semi-empíricos serão apresentados apenas como empíricos, por conveniência.

4.2 Dados e métodos

4.2.1 Dados *in situ*

Neste capítulo, foram utilizados os dados da $R_{rs}(\lambda)$ e as concentrações de Chl-a para as quatro campanhas de campo, seguindo as metodologias apresentadas no Capítulo 3. Estes dados de $R_{rs}(\lambda)$ e Chl-a de foram utilizados para a calibração e validação dos algoritmos empíricos testados neste capítulo. Dentre

as quatro campanhas de campo, foram utilizados 31 pontos amostrais para junho de 2015, 18 para março de 2016, 27 para julho de 2016 e 18 para agosto de 2017. Os dados de $R_{rs}(\lambda)$ foram simulados para as bandas dos sensores OLI e MSI, por meio de suas funções de resposta, conforme apresentado no Capítulo 3.

4.2.2 Algoritmos empíricos

Para identificar os algoritmos com melhor desempenho para estimativa de Chl-a nos lagos da planície de inundação amazônica, foram avaliados vários algoritmos empíricos disponíveis na literatura. Os algoritmos com 2 e 3 bandas (Equações 4.1 e 4.2), desenvolvidos por Gitelson (1992) e Dall'olmo et al. (2003) para vegetação e posteriormente adaptados para Chl-a, foram nomeados neste trabalho como 2B e 3B, respectivamente. Ambos algoritmos utilizam a λ_1 na região de máxima influência da absorção de Chl-a, com a adição da banda λ_2 , de absorção por Chl-a buscando remover os efeitos remanescentes dos COAs. Visando reduzir os efeitos de retroespalhamento e da atmosfera, a banda λ_3 no algoritmo de 3 bandas, deve ser posicionada em uma região de influência apenas da água pura (GITELSON et al., 2008).

$$2B = R_{rs}(\lambda_1)^{-1} * R_{rs}(\lambda_2) \quad (4.1)$$

$$3B = [R_{rs}(\lambda_1)^{-1} - R_{rs}(\lambda_2)^{-1}] * R_{rs}(\lambda_3) \quad (4.2)$$

O algoritmo Slope foi desenvolvido para as bandas do vermelho e verde do sensor MODIS por Mishra e Mishra (2010), relacionando as regiões de máxima (λ_2) e de mínima (λ_1) absorção por Chl-a, conforme:

$$Slope = \frac{R_{rs}(\lambda_2) - R_{rs}(\lambda_1)}{\lambda_2 - \lambda_1} \quad (4.3)$$

O algoritmo NDCI foi desenvolvido para as bandas do sensor MERIS e aplicados em águas túrbidas costeiras e estuarinas. Similar ao índice NDVI, o NDCI utiliza da relação da máxima (λ_1) e mínima (λ_2) absorção por Chl-a (MISHRA; MISHRA, 2012), conforme:

$$NDCI = \frac{R_{rs}(\lambda_2) - R_{rs}(\lambda_1)}{R_{rs}(\lambda_2) + R_{rs}(\lambda_1)} \quad (4.4)$$

A calibração dos algoritmos para estimar Chl-a foi realizada utilizando da técnica de simulação de Monte Carlo, onde 70% do conjunto de dados foi aplicado a regressões lineares e quadráticas, e os 30% restantes foram utilizados para a validação. Após a seleção dos melhores algoritmos para cada sensor testado, esses algoritmos calibrados foram aplicadas às imagens OLI e MSI disponíveis. Para cada ponto amostral foi extraída uma janela de 3x3 píxeis das estimativas geradas pelos algoritmos aplicados às imagens, buscando reduzir as incertezas na recuperação da concentração de Chl-a das imagens. Para avaliar o desempenho dos algoritmos aplicados às imagens, as concentrações de Chl-a obtidas nas mesmas foram comparadas com os dados de campo concomitantes. A Tabela 4.1 apresenta a abreviação para modelos testados em cada sensor e suas combinações de bandas.

Tabela 4.1 - Índices de modelos e bandas testados para os sensores OLI e MSI.

Algoritmos aplicados ao sensor OLI		
Índice	Bandas	Comprimento de Onda (nm)
2B	B3, B4	560, 665
NDCI-G	B3, B4	560, 665
NDCI-N	B4, B5	665, 864
SL-RG	B4, B3	665, 560
Algoritmos aplicados ao sensor MSI		
Índice	Bandas	Comprimento de Onda (nm)
2B-M	B3, B4	665, 705
3B-M	B3, B4, B5	665, 705, 740
NDCI	B4, B5	665, 705
SL-NR	B4, B5	665, 705
SL-RG	B3, B4	560, 665

Em que SL é o algoritmo *slope* (MISHRA; MISHRA, 2010) para as bandas NIR/vermelho (NR) e vermelho/verde (RG). NDCI-G e NDCI-N é o algoritmo NDCI (MISHRA; MISHRA, 2012) para as bandas do verde (G) e NIR (N).

Fonte: Produção do Autor.

4.2.3 Mapas de Chl-a

A composição dos corpos d'água pode apresentar variações graduais devido aos períodos hidrológicos ou abruptas em resposta a eventos meteorológicos. A comparação dos dados *in situ* com os dados orbitais é de extrema importância para validação das estimativas dos algoritmos aplicados. Portanto, a avaliação da janela temporal entre os dados obtidos em campo e a passagem do satélite faz-se necessária. Com uma análise das imagens disponíveis concomitantes com as coletas a campo, foram determinadas as melhores imagens para validação dos algoritmos. Para os campos de junho de 2015, março e julho de 2016 não haviam imagens com qualidade razoável disponíveis, portanto, foram selecionadas as imagens de 10 de agosto de 2017, órbita/ponto 228/062 para o sensor OLI, e 08 de agosto de 2017, órbita/ponto T21MXT para o MSI. Para a correção atmosférica das imagens dos sensores MSI e OLI foi usado o método de correção atmosférica 6SV (VERMOTE et al., 1997), testada por Martins et al. (2017), que apresentou os

melhores resultados para lagos da região Amazônica. Buscando reduzir os efeitos de *glint*, a correção proposta por Shi e Wang, (2009), foi aplicada nas imagens utilizadas, subtraindo os valores das bandas no infravermelho de ondas curtas (SWIR) do restante do espectro, assumindo que nesta região o sinal deveria ser nulo. Para o sensor OLI, foi utilizada a banda B6 em 1609 nm e para o sensor MSI a banda B11 em 1910 nm.

O desempenho dos algoritmos empíricos calibrados foi avaliado através dos métodos estatísticos da raiz do erro quadrático médio (RMSE), raiz do erro quadrático médio normalizado (NRMSE), erro percentual médio absoluto (MAPE) e bias descritos no Capítulo 3.

4.3 Resultados e discussão

4.3.1 Parâmetros de qualidade da água

A estatística descritiva dos pontos amostrais das quatro campanhas de campo está apresentada na Tabela 4.2, com seus valores mínimos, máximos, média, mediana e desvio padrão. Os parâmetros de qualidade da água analisados foram a Chl-a, TSS, TSI, TSO, profundidade Secchi e profundidade. A contribuição dos componentes TSI e TSO para os sólidos totais (TSS) também é apresentada na Tabela 4.2. O ponto amostral Curuai04 da campanha de junho de 2016 foi considerado um *outlier* devido à variação incomum do seu espectro de $R_{rs}(\lambda)$, sendo removido do conjunto de dados, totalizando assim 94 amostras possíveis para a calibração dos algoritmos empíricos.

Tabela 4.2 - Estatísticas descritivas dos parâmetros de qualidade da água medidos in situ.

		Chl-a	TSS	TSI	TSO	TSI/ TSS	TSO/ TSS	Secchi	Prof
Junho de 2015 (n=31)	Mínimo	0,35	5,25	2,00	3,25	0,28	0,17	0,30	3,70
	Máximo	8,59	33,20	27,60	12,75	0,83	0,72	1,10	7,40
	Média	3,28	16,72	10,07	6,67	0,56	0,44	0,60	5,98
	Mediana	2,94	17,38	9,38	5,83	0,55	0,45	0,50	6,30
	σ	1,98	7,27	6,35	2,61	0,16	0,16	22,16	108,24
Março de 2016 (n=18)	Mínimo	0,67	20,50	10,50	10,00	0,51	0,07	0,10	1,45
	Máximo	42,32	235,50	218,50	27,00	0,93	0,49	0,40	4,40
	Média	19,77	74,46	57,85	16,61	0,72	0,28	0,21	2,43
	Mediana	18,31	66,83	44,67	16,34	0,73	0,27	0,18	2,30
	σ	12,78	51,16	49,06	4,82	0,11	0,11	8,08	66,65
Julho de 2016 (n=27)	Mínimo	5,21	17,00	6,86	3,00	0,32	0,06	0,20	2,70
	Máximo	85,05	64,67	56,67	21,25	0,94	0,68	0,56	5,50
	Média	21,55	32,41	21,22	11,19	0,63	0,37	0,37	4,13
	Mediana	11,48	29,86	18,57	10,00	0,60	0,40	0,36	4,20
	σ	21,01	11,68	11,80	5,74	0,17	0,17	9,79	80,72
Agosto de 2017 (n=18)	Mínimo	9,34	7,00	3,38	3,63	0,32	0,22	0,24	2,80
	Máximo	67,85	43,50	33,75	12,13	0,78	0,68	1,15	5,30
	Média	31,11	17,70	11,12	6,59	0,59	0,41	0,60	4,52
	Mediana	31,12	15,30	8,75	6,08	0,58	0,42	0,55	4,70
	σ	17,24	8,52	7,53	2,39	0,14	0,14	25,78	67,17

Onde as unidades são: Chl-a (mg.m^{-3}), TSS, TSI e TSO (mg.L^{-1}), Secchi (m) e Profundidade (m).

Fonte: Produção do Autor.

Em relação à concentração de Chl-a, o conjunto de junho de 2015 se destaca pelos valores baixos em comparação com as demais campanhas, sendo seu máximo de $8,58 \text{ mg.m}^{-3}$, mínimo de $0,35 \text{ mg.m}^{-3}$ e média de $3,28 \text{ mg.m}^{-3}$. Os dois conjuntos de 2016, março e julho, apresentam valores de Chl-a médios similares, com $19,77 \text{ mg.m}^{-3}$ e $21,55 \text{ mg.m}^{-3}$, respectivamente. A campanha de agosto de 2017 obteve a maior média de Chl-a de todo o conjunto, 31 mg.m^{-3} , com valor mínimo de $9,34 \text{ mg.m}^{-3}$ e máximo de $67,85 \text{ mg.m}^{-3}$.

Para o TSS, é possível notar a similaridade das campanhas de junho de 2015 e agosto de 2017 com médias de $16,72$ e $17,70 \text{ mg.L}^{-1}$, respectivamente. Para a campanha de julho de 2016 possui uma média de TSS aproximadamente 2 vezes maior, com $32,41 \text{ mg.L}^{-1}$. A campanha de março de 2016 possui os maiores valores de TSS de todo o conjunto, com valor mínimo de $20,50 \text{ mg.L}^{-1}$,

máximo de 235,50 mg.L⁻¹ e média de 74,46 mg.L⁻¹. Avaliando-se a contribuição das frações orgânicas (TSO) e inorgânicas (TSI) no TSS, nota-se a maior predominância de material inorgânico em todas as campanhas, com a menor contribuição média de TSI/TSS de 56% e a maior de 72%, para junho de 2015 e março de 2016, respectivamente.

Avaliando as estatísticas descritivas das quatro campanhas de campo, foi possível notar a alta influência do TSS na campanha de março de 2016, sendo em média de 2 a 4,5 vezes (74,46 mg.L⁻¹) maior que as outras campanhas. A influência do TSI que compõem o TSS é predominante nesta campanha com valores mínimos de 51%, máximos de 93% e média de 72%. Portanto, em conjunto com as análises de correlação dos modelos empíricos com os dados de Chl-a, optou-se por não utilizar a campanha de março de 2016 para a calibração dos algoritmos empíricos. Os ajustes dos dados modelados com a campanha de março de 2016 podem ser vistos no Apêndice A.

4.3.2 Calibração dos algoritmos com dados *in situ*

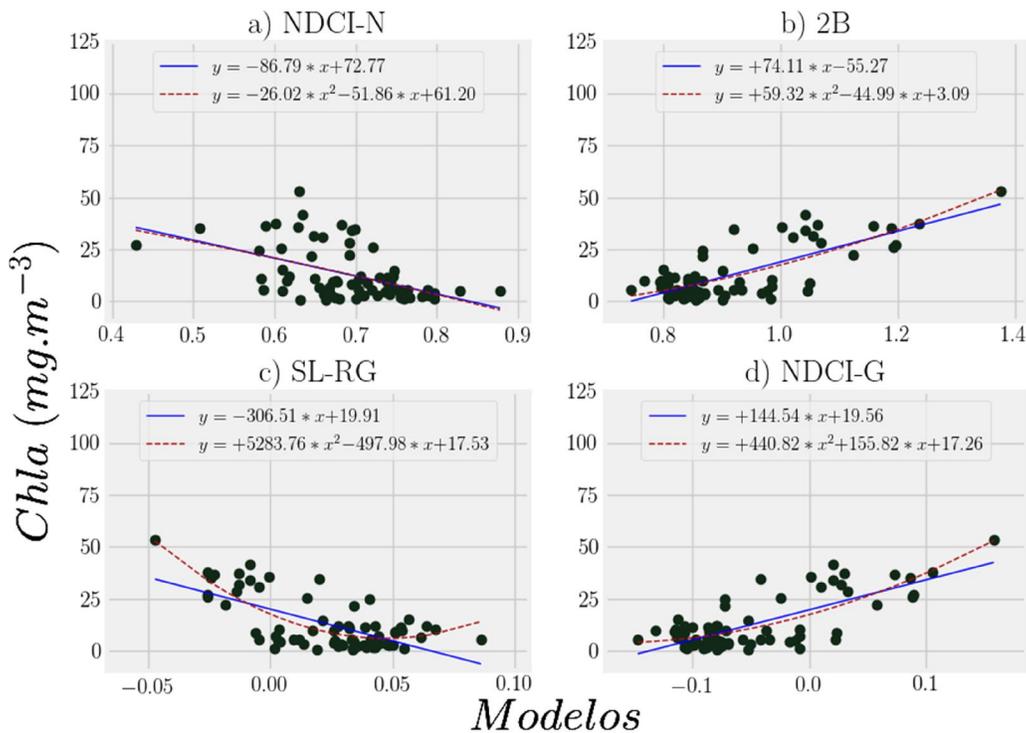
A partir deste ponto, visto a alta concentração de TSI na campanha de março de 2016, para a calibração dos algoritmos empíricos são consideradas apenas campanhas junho de 2015, julho de 2016 e agosto de 2017, nomeadas 2015, 2016 e 2017, respectivamente. Nesta seção, os resultados foram subdivididos por sensor analisado (OLI e MSI), facilitando assim sua descrição. Para a calibração dos algoritmos foram removidos 5 pontos amostrais anormais (*outliers*) em todo o conjunto de dados, sendo os pontos Curuai 04 e 10 de 2017, Curuai 08, 02 e 12 de 2016. Portanto, os algoritmos foram calibrados com conjunto amostral de 71 pontos, sendo 31 em 2015, 24 em 2016 e 16 em 2017.

4.3.2.1 Sensor OLI

Buscando avaliar a correlação dos algoritmos empíricos com a concentração de Chl-a, estes foram aplicados nos dados de $R_{rs}(\lambda)$ simulados para o sensor

OLI. Devido à disponibilidade de bandas, para o sensor OLI, foram testados apenas os algoritmos: 2B (MOSES et al., 2012), NDCI (MISHRA; MISHRA, 2012) e Slope (MISHRA; MISHRA, 2010). A Figura 4.1 exibe os ajustes lineares e quadráticos para cada algoritmo testado. Os algoritmos ajustados para os dados de $R_{rs}(\lambda)$ apresentaram baixa correlação com a concentração de Chl-a, com $R^2=0,26$ para NDCI-N, 0,55 para NDCI-G, 0,56 para o 2B e 0,44 para o SL-RG. A Figura 4.1 apresenta os gráficos de dispersão entre os modelos para o OLI e os dados de Chl-a, seus ajustes lineares e quadráticos e os coeficientes da regressão.

Figura 4.1 - Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmos empíricos aplicados a $R_{rs}(\lambda)$ simulada para o sensor OLI nas campanhas 2015, 2016 e 2017 (n=71).



Fonte: Produção do Autor.

A utilização da banda do NIR (865 nm) no algoritmo NDCI-N apresentou uma baixa correlação ($R^2 = 0,26$). Entretanto, o mesmo algoritmo utilizando a banda do verde (NDCI-G – 561 nm) apresentou uma melhor correlação com a Chl-a

($R^2 = 0,55$) (Tabela 4.3). O algoritmo 2B (Verde/Vermelho) obteve resultados similares com $R^2 = 0,56$ e o algoritmo Slope (SL-RG) obteve uma correlação de $R^2 = 0,44$ com as mesmas bandas.

Para avaliar e validar o desempenho dos algoritmos empíricos ajustados para o sensor OLI, foi realizada uma simulação de MC com 20 mil interações, utilizando amostras de treinamento e teste aleatorizadas, nas proporções 70% e 30%, respectivamente. Os valores modais das estatísticas MAPE, NRMSE e R^2 foram utilizados para avaliar o resultado das estimativas da concentração de Chl-a por cada algoritmo. A Tabela 4.3 apresenta os resultados de validação dos algoritmos testados para os dados das 3 campanhas selecionadas, simulados para sensor OLI.

Tabela 4.3 - Avaliação estatística dos algoritmos aplicados aos dados das campanhas 2015, 2016 e 2017 simulados para o sensor OLI.

Algoritmos ajustados para o sensor OLI (n= 21)					
Algoritmos	Ajuste	MAPE (%)	R^2	NRMSE (%)	Bias (mg.m⁻³)
NDCI-N	Lin	133,13	0,25	29,49	-0,55
NDCI-N	Quad	133,51	0,23	31,58	-0,57
NDCI-G	Lin	107,59	0,58	24,36	0,24
NDCI-G	Quad	138,82	0,59	23,65	0,09
SL-RG	Lin	168,65	0,48	27,13	0,05
SL-RG	Quad	135,91	0,61	23,76	-0,31
2B	Lin	105,94	0,60	23,75	0,21
2B	Quad	111,53	0,58	23,80	-0,04

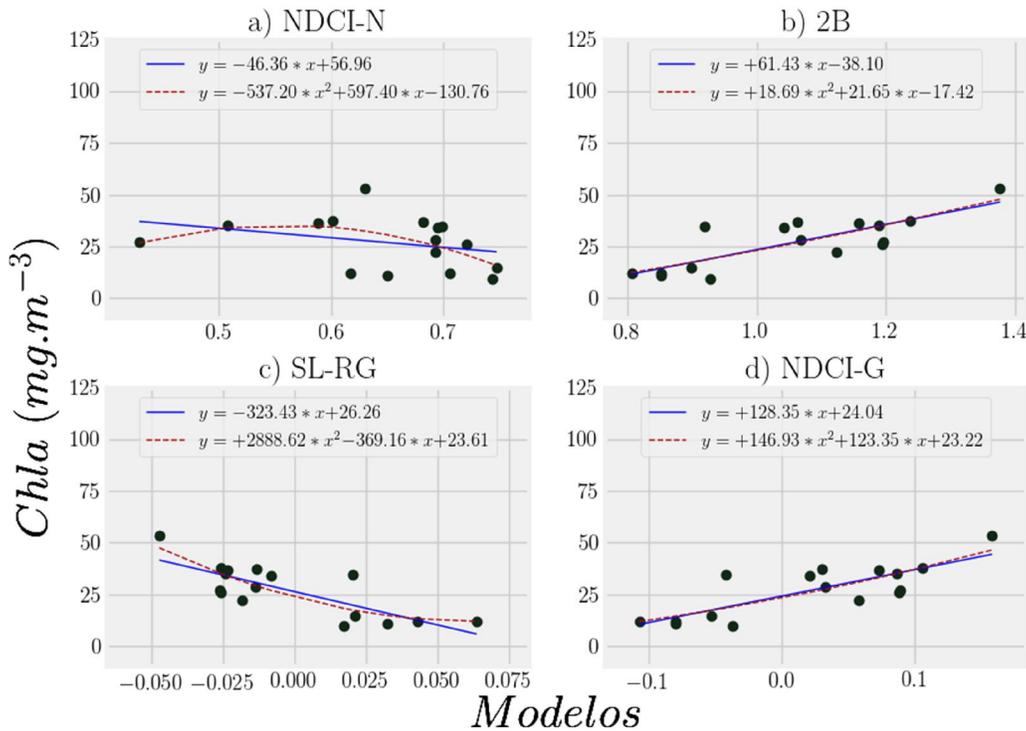
Sendo Lin o ajuste linear e Quad o ajuste quadrático.

Fonte: Produção do autor.

Variações na composição dos sistemas aquáticos amazônicos nas diferentes fases da hidrógrafa apresentam uma condição altamente dinâmica, dificultando a calibração dos algoritmos para a heterogeneidade do conjunto de dados testados para as campanhas de 2015, 2016 e 2017. Portanto, visando uma calibração efetiva dos algoritmos e a compatibilização com a aplicação destes nas imagens orbitais disponíveis, os algoritmos foram ajustados apenas ao conjunto de dados da campanha de 2017. A correlação do conjunto de dados

de 2017, composta por 16 pontos amostrais, com a concentração de Chl-a é apresentado na Figura 4.2.

Figura 4.2 - Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmos empíricos ajustados no conjunto de dados 2017 para o sensor OLI (n=16).



Fonte: Produção do autor.

A correlação dos algoritmos selecionados, ajustados apenas para a campanha de 2017, obtiveram R² de 0,10 para NDCI-N, 0,65 para NDCI-G, 0,63 para SL-RG e 0,65 para o 2B. Com exceção do NDCI-N, os demais algoritmos apresentaram ligeira melhora nas correlações com a Chl-a, quando comparados aos ajustes com as 3 campanhas (2015, 2016 e 2017) realizadas anteriormente, porém, ainda são pouco satisfatórios.

Foi realizada novamente a simulação de MC, com 20 mil interações, com os algoritmos empíricos ajustados apenas para a campanha de 2017. A simulação seguiu o padrão de amostras aleatorizadas de treinamento e teste, nas proporções 70% e 30% dos dados, respectivamente. A Tabela 4.4 apresenta

os resultados das estatísticas MAPE, R^2 , NRMSE e bias para os algoritmos testados, nos ajustes lineares e quadráticos.

Tabela 4.4 - Avaliação estatística dos algoritmos aplicados aos dados simulados OLI para a campanha de 2017.

Algoritmos ajustados para o sensor OLI (n=5)					
Algoritmos	Ajuste	MAPE (%)	R^2	NRMSE (%)	Bias (mg.m^{-3})
NDCI-N	Lin	48,11	0,03	37,08	-2,28
NDCI-N	Quad	54,99	0,03	33,18	-1,01
NDCI-G	Lin	23,59	0,84	18,65	-0,62
NDCI-G	Quad	26,76	0,81	25,87	1,68
SL-RG	Lin	26,32	0,77	20,84	0,33
SL-RG	Quad	7,27	0,82	17,63	-0,37
2B	Lin	24,41	0,86	18,11	-0,70
2B	Quad	26,61	0,81	18,59	1,95

Sendo Lin o ajuste linear e Quad o ajuste quadrático.

Fonte: Produção do autor.

Os resultados da simulação de MC para a campanha de 2017 obtiveram valores modais de MAPE abaixo de 55% para todos os algoritmos, com destaque para o SL-RG (Quadrático) que apresentou MAPE=7,27% e $R^2 = 0,82$. Com exceção do NDCI-N ($R^2 = 0,03$), os demais algoritmos apresentaram valores de R^2 acima de 0,77, com destaque para o algoritmo 2B com $R^2 = 0,86$. Os algoritmos SL-RG e 2B obtiveram valores de NRMSE próximos a 20% em ambos os ajustes. Em relação ao bias, o algoritmo SL-RG (linear e quadrático) obtiveram os resultados mais próximos a zero, enquanto o NDCI-N (linear) e 2B (quadrático) apresentaram os piores resultados. A Tabela 4.5 apresenta os coeficientes selecionados para a aplicação do algoritmo na imagem do sensor OLI, para cada modelo e tipo de ajuste.

Tabela 4.5 - Coeficientes da regressão para o sensor OLI aplicado à campanha 2017.

Coeficientes ajustados para o sensor OLI				
Algoritmos	Ajuste	a	b	c
NDCI-N	Lin	-16,07	36,47	*
NDCI-N	Quad	61,33	-144,71	93,37
NDCI-G	Lin	136,64	23,20	*
NDCI-G	Quad	98,71	143,79	25,20
SL-RG	Lin	-265,07	24,92	*
SL-RG	Quad	2861,08	-350,94	23,25
2B	Lin	61,55	-36,89	*
2B	Quad	2,68	68,04	-49,05

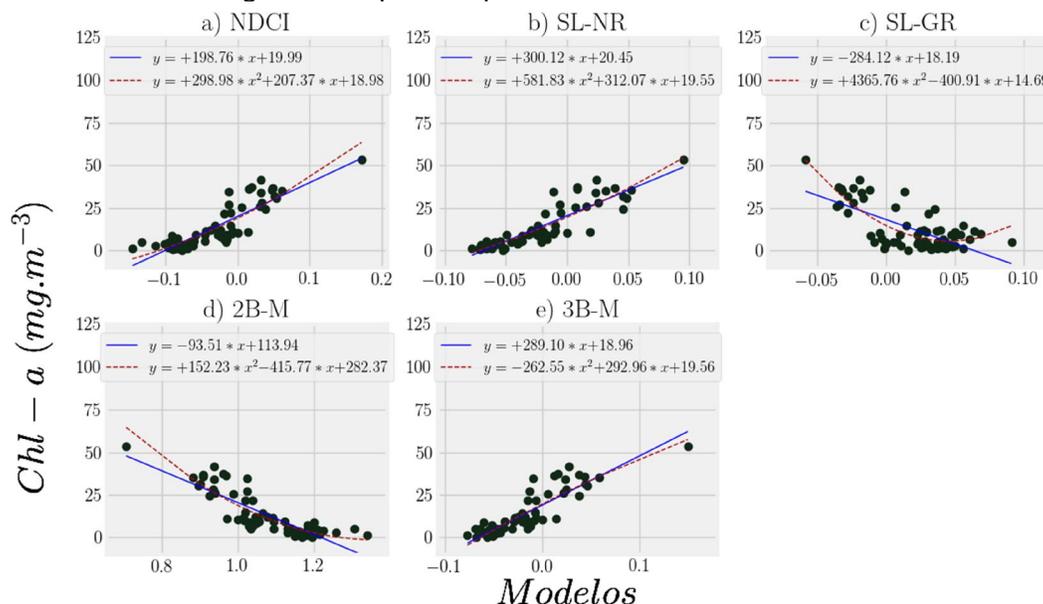
Sendo Lin: $y = ax + b$ e Quad: $ax^2 + bx + c$.

Fonte: Produção do Autor.

4.3.2.2 Sensor MSI

Buscando avaliar a correlação dos algoritmos empíricos para a estimativa de Chl-a, estes foram aplicados nos dados de $R_{rs}(\lambda)$ simulados para o sensor MSI. Para este sensor, foram testados os algoritmos: 2B e 3B (GITELSON et al., 2008), NDCI (MISHRA; MISHRA, 2012) e Slope (MISHRA; MISHRA, 2010). Os algoritmos ajustados para os dados de $R_{rs}(\lambda)$ do sensor MSI apresentaram altas correlações com a concentração de Chl-a, com R^2 de 0,76 para NDCI, 0,80 para SL-NR, 0,48 para o SL-GR, 0,73 para 2B-M, 0,79 para 3B-M. A Figura 4.3 apresenta os gráficos de dispersão entre os modelos para o MSI e os dados de Chl-a, seus ajustes lineares, quadráticos e seus coeficientes da regressão.

Figura 4.3- Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmos empíricos aplicados às bandas simuladas do sensor MSI.



Fonte: Produção do Autor.

O procedimento de simulação Monte Carlo com 20 mil interações foi aplicado para o sensor MSI no conjunto de dados das campanhas 2015, 2016 e 2017 nas proporções de 70% calibração e 30% para validação. Os valores modais das estatísticas MAPE, NRMSE e R² foram utilizados para avaliar as estimativas da concentração de Chl-a pelos algoritmos. A Tabela 4.6 apresenta os resultados de validação dos algoritmos testados para o sensor MSI.

Tabela 4.6 - Avaliação estatística dos algoritmos aplicados aos dados das campanhas 2015, 2016 e 2017 simulados para o sensor MSI.

Algoritmos ajustados para o sensor MSI (n=21)					
Algoritmos	Ajuste	MAPE (%)	R²	NRMSE (%)	Bias (mg.m⁻³)
SL-NR	Lin	60,14	0,83	17,12	-0,20
SL-NR	Quad	45,10	0,83	16,84	-0,14
SL-RG	Lin	159,62	0,53	26,34	0,04
SL-RG	Quad	128,02	0,66	22,69	-0,17
NDCI	Lin	107,71	0,79	18,10	0,15
NDCI	Quad	73,72	0,76	17,47	-0,63
2B-M	Lin	80,93	0,77	19,07	0,18
2B-M	Quad	69,21	0,78	16,67	-0,42
3B-M	Lin	66,59	0,82	29,19	-0,03
3B-M	Quad	71,09	0,79	29,43	-0,25

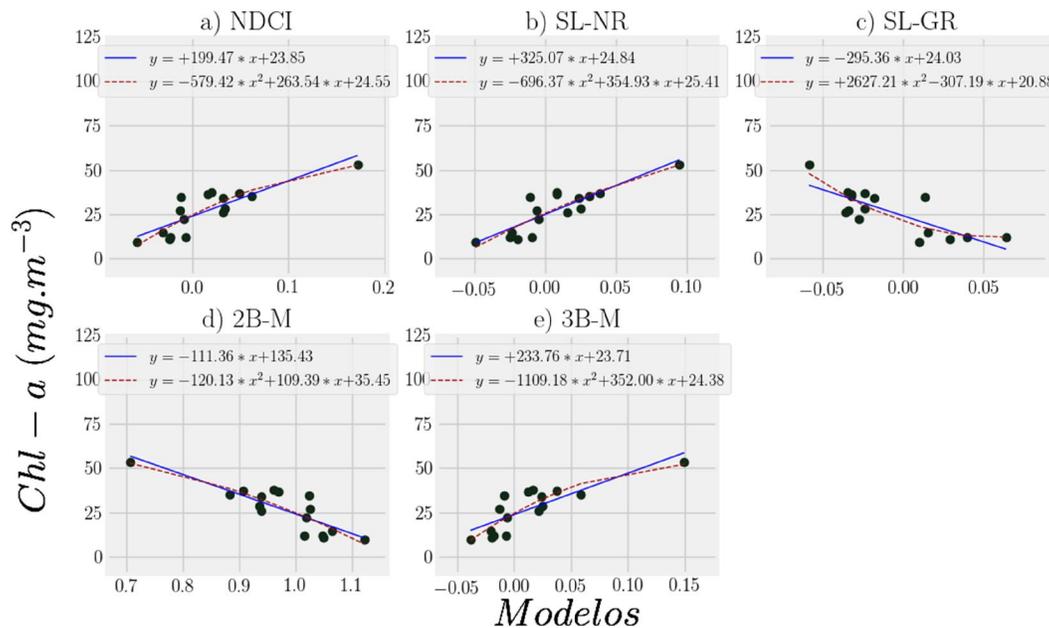
Sendo Lin o ajuste linear e Quad o ajuste quadrático.

Fonte: Produção do Autor.

Os resultados dos algoritmos aplicados às três campanhas de campo (2015, 2016 e 2017) na imagem do sensor MSI não foram satisfatórios, uma vez que apresentaram valores de MAPE acima de 60% para todos os algoritmos, com exceção do SL-NR que obteve o melhor resultado (MAPE = 45,10 e R²=0,83). Todos os algoritmos obtiveram valores de NRMSE abaixo de 30%, com os melhores resultados novamente para o SL-NR. A maioria dos algoritmos tenderam a subestimar as concentrações de Chl-a, e todos obtiveram bias entre -1 e 1. A influência do CDOM na região prejudica as estimativas na concentração de Chl-a pelos algoritmos e pode ser vista na diferença entre as duas combinações do algoritmo Slope testadas.

Buscando novamente compatibilizar a calibração dos algoritmos com a data das imagens disponíveis, apenas a campanha de 2017 foi utilizada para a calibração dos algoritmos nos dados simulados ao sensor MSI. A Figura 4.4 apresenta a dispersão dos seis algoritmos testados em comparação com a concentração de Chl-a.

Figura 4.4 - Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmos empíricos aplicados no conjunto de 2017 para o sensor MSI (n=16).



Fonte: Produção do Autor.

A correlação obtida para os algoritmos aplicados ao MSI, apenas os dados da campanha de 2017, foram de 0,70 para o NDCI, 0,74 para o SL-NR, 0,62 para o SL-GR, 0,72 para o 2B-M, 0,68 para o 3B-M. Os algoritmos aplicados ao sensor MSI para a campanha de 2017 foram submetidos novamente a simulação Monte Carlo com 20 mil interações, utilizando amostras aleatorizadas de treinamento e teste, nas proporções 70% e 30% dos dados, respectivamente. A Tabela 4.7 apresenta os resultados das estatísticas MAPE, R², NRMSE e bias para os algoritmos testados, nos ajustes lineares e quadráticos.

Tabela 4.7 - Avaliação estatística dos algoritmos aplicados aos dados simulados MSI para a campanha de 2017.

Algoritmos ajustados para o sensor MSI (n=5)					
Algoritmos	Ajuste	MAPE (%)	R2	NRMSE (%)	Bias (mg.m⁻³)
SL-NR	Lin	27,53	0,83	16,74	-0,17
SL-NR	Quad	31,35	0,78	16,82	0,97
SL-RG	Lin	26,51	0,77	20,66	0,80
SL-RG	Quad	22,95	0,82	25,67	-0,37
NDCI	Lin	29,80	0,83	19,12	-0,77
NDCI	Quad	26,43	0,76	19,19	3,18
2B-M	Lin	27,58	0,85	16,66	-0,20
2B-M	Quad	26,40	0,77	18,84	1,74
3B-M	Lin	29,49	0,80	38,09	-1,09
3B-M	Quad	26,20	0,76	35,82	-0,46

Sendo Lin o ajuste linear e Quad o ajuste quadrático.

Fonte: Produção do Autor.

Nota-se, primeiramente, a relevante melhora no desempenho dos algoritmos quando aplicados às bandas do sensor MSI, em comparação às do sensor OLI. Todos os algoritmos apresentaram valores de MAPE abaixo de 32%. Os melhores desempenhos foram obtidos pelo algoritmo Slope, tanto com as bandas do vermelho e NIR (MAPE ~29%), quanto para as bandas do verde e vermelho (MAPE~24%). Os valores de R² variaram de 0,76 (NDCI quadrático) até 0,85 (2B-M linear). Os coeficientes da regressão foram selecionados baseados nos valores modais do MAPE, recuperados da simulação de MC para a interação mais representativa. A Tabela 4.8 apresenta os coeficientes selecionados para a aplicação na imagem do sensor MSI, para cada modelo e tipo de ajuste.

Tabela 4.8 - Coeficientes da regressão para o sensor MSI aplicado à campanha 2017.

Coeficientes ajustados para o sensor MSI (n= 16)				
Algoritmos	Ajuste	a	b	c
SL-NR	Lin	316,18	25,37	*
SL-NR	Quad	-217,21	317,46	24,67
SL-RG	Lin	-265,07	24,92	*
SL-RG	Quad	3291,94	-316,38	17,73
NDCI	Lin	263,23	23,63	*
NDCI	Quad	-822,11	246,99	24,37
2B-M	Lin	-117,55	143,00	*
2B-M	Quad	-181,31	219,08	-12,07
3B-M	Lin	299,36	22,20	*
3B-M	Quad	-1350,72	382,77	25,79

Sendo Lin o ajuste linear e Quad o ajuste quadrático.

Fonte: Produção do Autor.

4.3.3 Avaliação dos algoritmos em imagens orbitais

Os coeficientes derivados das iterações da simulação MC, definidos para cada algoritmo e sensor, foram utilizados na espacialização das concentrações usando a imagem orbital disponível para cada sensor. As equações foram aplicadas sobre os valores $R_{rs}(\lambda)$ das imagens, com correções atmosféricas e remoção de *glint*, recortadas para a máscara de água gerada pelo software Fmask (ZHU et al., 2015). Todo o processamento de espacialização dos algoritmos foi realizado em ambiente Python, e a geração dos mapas no software ArcGis.

4.3.3.1 Sensor OLI

Os dados de concentração de Chl-a, coletados em campo, foram utilizados para a comparação dos resultados dos algoritmos espacializados nas imagens, com a utilização da média de uma janela de 3x3 *píxeis* ao redor da localização do ponto amostral. A Tabela 4.9 apresenta os resultados dos algoritmos aplicados à imagem do sensor OLI, avaliados por meio dos dados *in situ* nas estatísticas MAPE, R^2 , NRSME e bias.

Tabela 4.9 - Estatísticas dos algoritmos aplicados na imagem do sensor OLI comparados aos dados de Chl-a *in situ* (n=16).

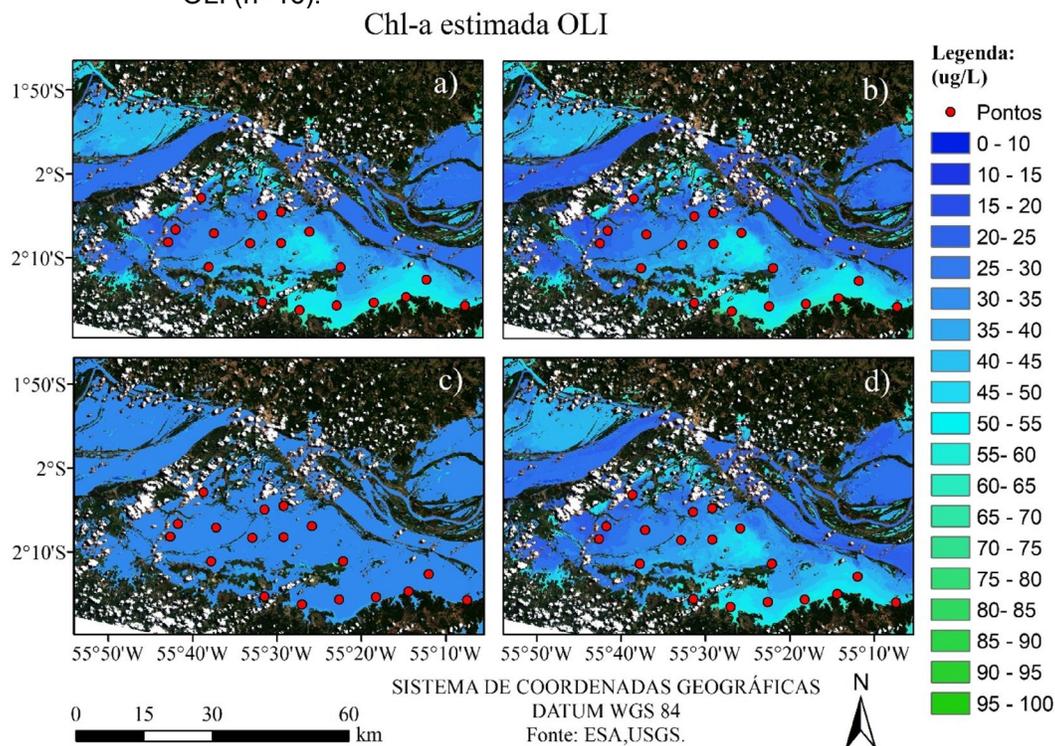
Algoritmos ajustados para o sensor OLI					
Algoritmos	Ajuste	MAPE (%)	R ²	NRMSE (%)	Bias (mg.m ⁻³)
NDCI-N	Lin	57,73	0,08	0,29	2,95
NDCI-N	Quad	69,85	0,08	0,28	-4,04
NDCI-G	Lin	58,30	0,30	0,25	-4,67
NDCI-G	Quad	366,29	0,29	1,33	-76,80
SL-RG	Lin	3,44E+11	0,03	2,29E+09	-1,1E+11
SL-RG	Quad	3,44E+11	0,03	2,29E+09	-1,1E+11
2B	Lin	65,17	0,28	0,27	-6,78
2B	Quad	60,71	0,28	0,27	-6,55

Sendo Lin o ajuste linear e Quad o ajuste quadrático.

Fonte: Produção do Autor.

O algoritmo NDCI o produziu os melhores resultados de MAPE, com 57,73% para a razão com o NIR (NDCI-N) e 58,30% com a razão do Verde (NDCI-G), porém o NDCI-N apresentou um R² próximo a zero, enquanto o NDCI-G obteve R² = 0,30. O algoritmo SL-RG apresentou resultados inexpressivos. Os dois ajustes para o algoritmo 2B apresentaram MAPE acima de 60% e R² = 0,28. Nenhum dos algoritmos avaliados apresentaram bons resultados para a espacialização da concentração de Chl-a na imagem do sensor OLI. A Figura 4.5 apresenta os quatro algoritmos com os menores valores de MAPE para o sensor OLI, sendo: a) 2B (linear), b) 2B (quadrático), c) NDCI-N (linear) e d) NDCI-G (linear).

Figura 4.5 – Algoritmos calibrados com dados *in situ* e especializados para o sensor OLI (n=16).



sendo: a) 2B (linear), b) 2B (quadrático), c) NDCI-N (linear) e d) NDCI-G (linear).

Fonte: Produção do Autor.

4.3.3.2 Sensor MSI

A Tabela 4.10 apresenta os resultados dos algoritmos aplicados à imagem do sensor MSI, avaliados por meio dos dados de campo nas estatísticas MAPE, R^2 , NRSME e bias. Todos os algoritmos aplicados na imagem do sensor MSI apresentaram resultados insatisfatórios, com valores de R^2 abaixo de 0,40. Em relação aos valores de MAPE, os algoritmos NDCI e 2B-M obtiveram os melhores desempenhos. Com exceção dos algoritmos SL-RG (Quadrático), os demais algoritmos superestimaram os resultados, com valores de bias acima de 10,00.

Tabela 4.10 - Estatísticas dos algoritmos aplicados na imagem do sensor MSI.

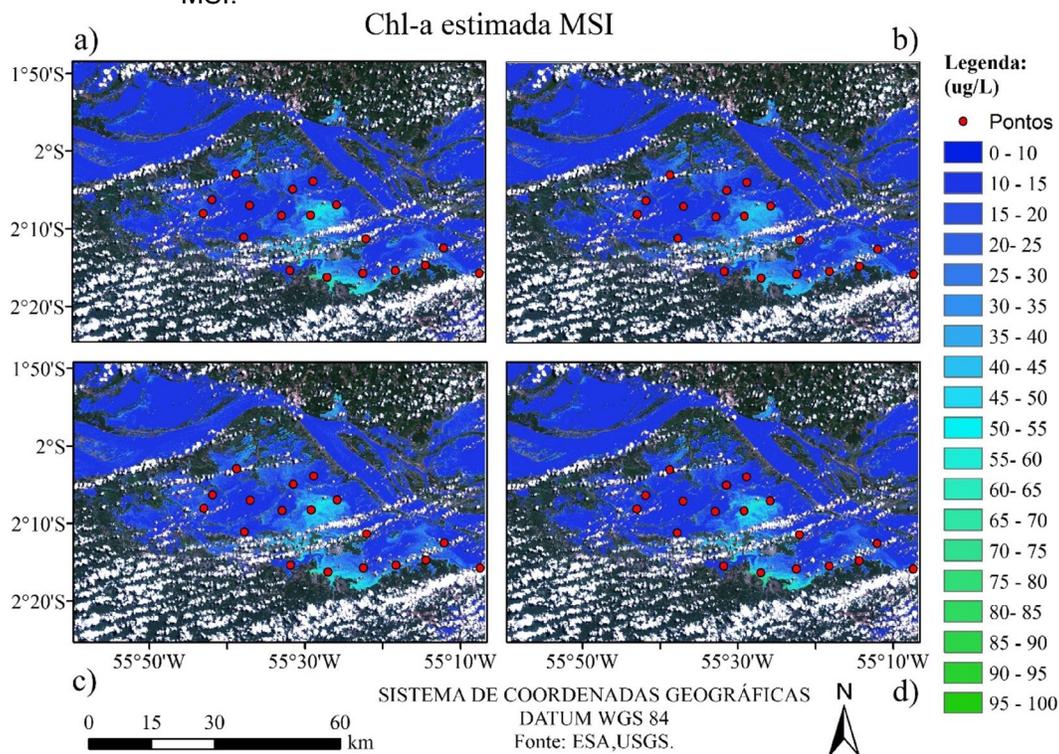
Algoritmos ajustados para o sensor MSI					
Algoritmos	Ajuste	MAPE	R²	NRMSE	Bias (mg.m⁻³)
SL-NR	Lin	177,42	0,32	0,72	30,98
SL-NR	Quad	202,55	0,35	0,79	36,01
SL-RG	Lin	73,95	0,39	0,35	11,12
SL-RG	Quad	109,20	5,44E-07	0,54	-6,01
NDCI	Lin	57,23	0,23	0,39	16,94
NDCI	Quad	63,85	0,22	0,42	18,98
2B-M	Lin	51,01	0,23	0,37	15,11
2B-M	Quad	73,67	0,22	0,45	20,25
3B-M	Lin	58,63	0,22	0,40	17,29
3B-M	Quad	76,24	0,22	0,45	20,20

Sendo Lin o ajuste linear e Quad o ajuste quadrático.

Fonte: Produção do Autor.

O algoritmo Slope utilizando as bandas do NIR e vermelho apresentaram os resultados menos satisfatórios de MAPE, com valores acima de 150%, seguido SL-RG (quadrático) que obteve MAPE=109,20%. Os algoritmos com os melhores desempenhos (NDCI, 2B-M e 3B-M) obtiveram resultados de NRMSE abaixo de 45%. A adição da terceira banda não foi capaz de melhorar o desempenho do algoritmo de 3 bandas, com resultados ligeiramente inferiores. A Figura 4.6 apresenta os quatro algoritmos com os menores valores de MAPE para o sensor MSI, sendo a) NDCI (linear), b) NDCI (quadrático), c) 2B-M (linear), d) 3B-M (linear).

Figura 4.6 – Algoritmos calibrados com dados *in situ* especializados para o sensor MSI.



sendo a) NDCI (linear), b) NDCI (quadrático), c) 2B-M (linear), d) 3B-M (linear).

Fonte: Produção do Autor.

4.4 Conclusão

Os algoritmos empíricos para a estimativa de Chl-a calibrados para o conjunto de dados da planície de inundação do baixo amazonas não foram capazes de estimar com precisão a concentração de Chl-a. Os melhores resultados obtidos pra a calibração dos algoritmos empíricos, neste trabalho, foram utilizando o pico de reflectância próximo 705 nm e o segundo pico de máxima absorção da Chl-a em 665 nm. Ainda que com resultados pouco satisfatórios, as bandas na região do vermelho limítrofe (*red-edge*), presentes no sensor MSI, mostraram potencial para a aplicação nas estimativas de Chl-a, quando comparado com o sensor OLI.

As altas concentrações de materiais particulados, principalmente materiais inorgânicos, mascararam as feições da absorção nas baixas concentrações de

Chl-a medidas em campo, dificultando a calibração dos algoritmos. A alta dinâmica sazonal devido ao pulso de inundação da planície amazônica apresentou características distintas entre as campanhas de campo, influenciando na calibração dos algoritmos.

Foi possível notar a alta correlação dos dados da campanha de 2017 com a Chl-a, apresentando bons resultados para simulação MC. Porém, estes resultados não foram observados nas imagens de satélite, podendo ser atribuído a lacuna temporal entre as coletas de campo e a aquisição da imagem.

A alta cobertura de nuvens na região da área de estudo apresenta outro fator agravante para a possível utilização dos algoritmos empíricos em produtos de estimativa de Chl-a, de forma regionalizada. A dinâmica da floração (*bloom*) de algas pode ser visto na comparação entre as imagens dos dois sensores utilizados, em que na data de aquisição do sensor OLI (08/08) o *bloom* está presente em toda a região oeste e sul do Lago Grande Curuai, e na imagem do sensor MSI (10/08) se encontram na região central e pouco na borda sul do lago.

5 ALGORITMO QAA PARA DETERMINAÇÃO DAS IOPS DOS PRINCIPAIS LAGOS DA PLANÍCIE DE INUNDAÇÃO DO BAIXO AMAZONAS

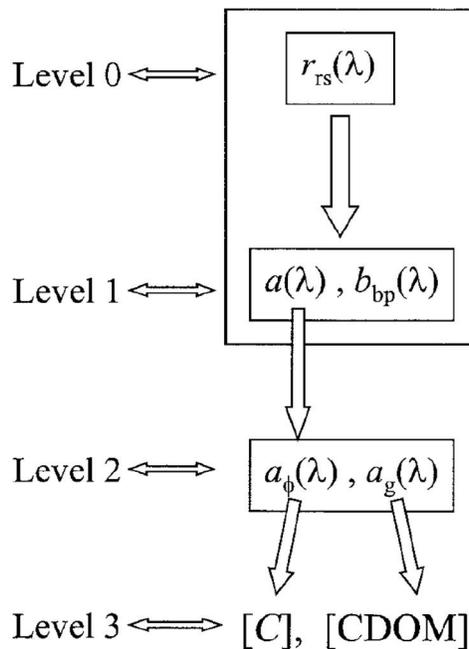
5.1 Introdução

Conforme apresentado no capítulo anterior, os algoritmos empíricos e semi-empíricos possibilitam determinar os parâmetros de qualidade da água por meio de relações estatísticas entre AOPs, $R_{rs}(\lambda)$ e a R, com as concentrações dos COAs. Porém, nesta abordagem, as IOPs dos constituintes não são consideradas durante o ajuste das relações, tornando estes aplicáveis somente para o ambiente para o qual foi ajustado e em condições similares de composição das massas de água (LEE et al., 2002; MOSES et al., 2012; ODERMATT et al., 2012). Buscando dar maior abrangência temporal, diversos autores propuseram abordagens voltadas para resolução analítica da relação entre as AOPs e as IOPs, utilizando-se como arcabouço aproximações da equação de transferência radiativa e otimizações numéricas (DEKKER; BUKATA, 2002; LEE et al., 2002; ODERMATT et al., 2012). Vale ressaltar que estes algoritmos não são puramente analíticos e necessitam, em muitos casos, de suposições e ajustes empíricos para sua utilização (DEKKER; BUKATA, 2002; ODERMATT et al., 2012). Estes algoritmos apresentam uma maior flexibilidade temporal e espacial, porém para se obter um bom desempenho, necessitam geralmente, de serem parametrizados para as características do meio (LEE et al., 2002). Neste contexto, o *quasi-analytical algorithm* (QAA) é um algoritmo inverso baseado na relação entre a $R_{rs}(\lambda)$, uma AOP, e os coeficientes de absorção (α_t) e retroespalhamento ($b_b(\lambda)$) que são propriedades inerentes (IOPs).

O QAA desenvolvido por Lee et al. (2002) é um algoritmo semi-analítico de modelagem inversa em três níveis, desenvolvido para estimativa de IOPs de corpos d'água a partir da refletância de sensoriamento remoto (Figura 5.1). No primeiro nível, a $R_{rs}(\lambda)$ é convertida analiticamente para $r_{rs}(\lambda)$. No segundo nível, os coeficientes de absorção total $\alpha_t(\lambda)$ e de retroespalhamento $b_b(\lambda)$ são

derivados e no terceiro nível, o coeficiente de absorção total é decomposto espectralmente nas contribuições dos pigmentos fitoplanctônicos ($\alpha_{\phi}(\lambda)$) e do CDOM mais detritos ($\alpha_{\text{CDM}}(\lambda)$). O algoritmo baseia-se na relação da $r_{rs}(\lambda)$ com as IOPs da água derivadas da equação de transferência radiativa. Atualizações do QAA foram publicadas por Lee et al. (2007) e Lee et al.(2009) e validados para águas oceânicas e costeiras. Atualmente, o algoritmo está em sua sexta versão (QAA_{v6}), uma modificação do QAA_{v5} para águas em que a $R_{rs}(670) > 0,0015 \text{ sr}^{-1}$ (LEE, 2014).

Figura 5.1 - Fluxograma esquemático conceitual do QAA.



Fonte: Lee et al. (2002).

Devido a sua formalização teórica consistente, o QAA tem sido utilizado por diversos autores, desde águas em mar aberto, águas costeiras e em águas interiores eutrofizadas e túrbidas (LE et al., 2013; LEE et al., 2007; MISHRA et al., 2014; WATERS et al., 2014; YANG et al., 2013). Mais recentemente foram desenvolvidas versões para as águas interiores brasileiras, com características ópticas diversas (JORGE, 2018; OGASHAWARA et al., 2016; RODRIGUES et

al., 2018; WATANABE et al., 2016). Ainda que com resultados satisfatórios em determinados ambientes de águas interiores, a parametrização e calibração do QAA ainda carece de mais estudos (LE et al., 2009).

O algoritmo original do QAA foi desenvolvido por (LEE et al., 2002) para a derivação da absorção e retroespalhamento em águas de mar aberto e regiões costeiras. O algoritmo se baseia na associação de relações empíricas e analíticas para derivar as IOPs através de aproximações da equação de transferência radiativa. Desta forma, o QAA se baseia em um comprimento de onda de referência λ_0 onde a absorção total (α_t) pode ser assumida como proveniente apenas da água (α_w), para assim estimar os próximos passos. Em sua primeira versão, o comprimento de onda de referência λ_0 foi determinado por Lee et al. (2002) como sendo 555 nm, o qual apresentou um desempenho satisfatório em águas pouco produtivas do caso 1. Entretanto, ao se tratar de águas interiores, muito túrbidas e eutrofizadas, a contribuição do material em suspensão ainda é expressiva nessa região, fazendo com que λ_0 necessite ser deslocado para comprimentos de onda mais longos. Lee et al. (2002) demonstraram que para ambientes oceânicos altamente absorvedores, em que $\alpha_t(440)$ é maior que $0,3 \text{ m}^{-1}$, a performance do algoritmo melhora com a mudança de λ_0 para 640 nm. Diversos autores descrevem a melhora no desempenho do algoritmo com o deslocamento do λ_0 , como em 708 nm (MISHRA et al., 2013; WATERS et al., 2014), 710 nm (LE et al., 2009) e 754 nm (YANG et al., 2013).

A ampla variedade de composição e concentração dos COAs que compõem as águas interiores tornam estes ambientes complexos e com características bio-ópticas distintas, dificultando a adequada parametrização do QAA. Vários autores reportaram, após parametrização adequada, um bom desempenho do QAA em águas interiores, como exemplo um estudo realizado no Lago Taihu por Le, et al. (2009), um corpo de água eutrófico e altamente turvo, para o qual, utilizou-se o comprimento de onda a 710 nm como referência. Mishra et al. (2013, 2014) e Mishra et al. (2014) utilizaram λ_0 em 708nm, para águas altamente produtivas com uma variação de Chl-a de 59,40 até 1376,60 mg.m^{-3} e de TSS de 69,80 a 401,20 mg.L^{-1} . Yang et al. (2013) utilizaram, em três lagos

asiáticos turvos com uma variação de Chl-a de 9,79 a 153,92 mg.m⁻³ e TSS de 4,81 a 61,00 mg.L⁻¹, o λ_0 em 754 nm para evitar a interferência da alta turbidez na absorção total. Li et al. (2013, 2015) desenvolveram duas versões do QAA para águas interiores, a primeira, parametrizado para um ambiente com uma variação de Chl-a de 1,85 a 285,8 mg.m⁻³ e TSS de 1,51 a 211,91 mg.L⁻¹, e a segunda versão para um ambiente com uma variação de Chl-a de 2,93 até 285,8 mg.m⁻³ e TSS de 2,34 a 123,79 mg.L⁻¹. Em ambas as versões, utilizou-se λ_0 em 709 nm.

Watanabe et al. (2016) parametrizou e calibrou o QAA para o reservatório de Barra Bonita no estado de São Paulo, durante um período em que a Chl-a variou de 17,7 a 797,8 mg.m⁻³ e o TSS de 3,6 a 44 mg.L⁻¹. A versão, a qual denominaram de QAA_{BBHR} apresentou resultados satisfatórios na estimativa de $\alpha(\lambda)$, $\alpha_{\text{CDM}}(\lambda)$ e $\alpha_{\phi}(\lambda)$. O ajuste fino e a recalibração dos passos empíricos dos QAA melhoraram consideravelmente a predição das IOPs. O uso de λ_0 em 709 nm e a calibração aumentaram a precisão da estimativa de $\alpha(\lambda_0)$ e, conseqüentemente de $\alpha_{\text{CDM}}(\lambda)$ e $\alpha_{\phi}(\lambda)$. O QAA_{BBHR} foi bem-sucedido ao isolar a interferência de outros COAs nas bandas de absorção de fitoplâncton, podendo ser usado com sucesso para recuperar a concentração de Chl-a.

Estudando lagos da reserva de desenvolvimento sustentável Mamirauá (RDMSM), Jorge (2018) parametrizou o algoritmo QAA, obtendo erros (NRSME) abaixo de 10% para as estimativas da absorção total nos comprimentos de onda de importância para Chl-a (670 e 708 nm). Com um NRMSE da absorção por fitoplâncton ($\alpha_{\phi}(\lambda)$) de até 60%, o QAA subestimou os valores em relação aos dados medidos em laboratório.

Como pôde ser visto, a utilização do QAA em águas interiores necessita de desenvolvimento e um maior respaldo de literatura, ainda mais para ambientes com grande influência de CDOM e material particulado como às planícies de inundação amazônicas. Portanto, este capítulo visou a parametrização e calibração do algoritmo QAA para às águas túrbidas dos lagos amazônicos. Assim, primeiramente, foram testadas versões do algoritmo QAA parametrizadas por diversos autores da literatura, aplicando-os nos lagos

selecionados. As bandas do sensor OLCI-Sentinel-3 foram simuladas a partir de dados radiométricos coletados em 3 campanhas de campo entre 2015 e 2017. Devido à complexidade do ambiente de estudo, a parametrização de uma versão do QAA ajustada para às águas dos lagos de estudo se fez necessária. Portanto, os objetivos específicos deste capítulo foram: i) testar e avaliar as principais versões do QAA presentes na literatura, parametrizadas para águas oceânicas e interiores; ii) parametrizar uma versão do QAA para as propriedades bio-ópticas dos lagos da planície de inundação amazônica; iii) avaliar a aplicação das IOPs do QAA parametrizado em algoritmos empíricos para a estimativa de Chl-a.

A versão do QAA parametrizada foi nomeada QAA_{LGC} , atribuído ao nome do Lago Grande Curuai, sendo este o principal lago presente na área de estudo. A parametrização e calibração do QAA_{LGC} , segundo objetivo específico deste capítulo, foi realizada com base na estrutura do QAA_{v5} . Os seguintes passos foram realizados para atingir esse objetivo: a) identificar o comprimento de onda de referência λ_0 em que $\alpha_t(\lambda)$ é dominado por $\alpha_w(\lambda)$; b) selecionar as bandas a serem utilizadas nas equações empíricas (χ e η) relativas à influência dos COAs na absorção e no espalhamento; e c) calibrar os coeficientes ζ e ξ associados com $\alpha_\phi(\lambda)$ e $\alpha_{CDOM}(\lambda)$, respectivamente.

5.2 Dados e métodos

As metodologias de aquisição e correção dos dados, *in situ* e laboratoriais, utilizados neste capítulo são as mesmas descritas no Capítulo 3 desta dissertação. Dentre todo o conjunto de dados das quatro campanhas apresentadas no Capítulo 3, foram descartados da calibração do QAA_{LGC} pontos amostrais com informações incompletas, como a falta das IOPs ou AOPs. Assim, Para a campanha de junho de 2015 foram selecionados 30 pontos, em julho de 2016 foram 06 pontos, agosto de 2017 foram 22 pontos. A campanha realizada em março de 2016 não foi utilizada para a calibração por não conter dados de $\alpha_t(\lambda)$ medidos. Portanto, para a calibração do QAA_{LGC} foi

utilizado um total de 58 pontos amostrais e para a etapa de validação foram utilizados 18 pontos da campanha independente de março de 2016.

Para o desenvolvimento do QAA, este trabalho relacionou medidas radiométricas *in situ* ($R_{rs}(\lambda)$) e dados de α (α_t , α_ϕ e α_{CDM}) determinados em laboratório e *in situ*. Para tanto, foram adotadas as premissas de que a magnitude da $R_{rs}(\lambda)$ varia exclusivamente em função dos COAs presentes no meio e que é possível estimar as IOPs a partir dos espectros da $R_{rs}(\lambda)$, conhecendo os coeficientes de absorção e espalhamento de cada COA. Assim sendo, a $R_{rs}(\lambda)$ foi utilizada como entrada no algoritmo QAA. Para determinar $\alpha_{CDM}(\lambda)$, as medidas obtidas em laboratório de $\alpha_{CDOM}(\lambda)$ e $\alpha_{det}(\lambda)$ foram somadas. Para a determinação da absorção total em campo $\alpha_t(\lambda)$, os dados do AC-S foram acrescidos da contribuição da água pura $\alpha_w(\lambda)$, determinado por Pope e Fry (1997). Os dados de $\alpha_t(\lambda)$, $\alpha_{CDOM}(\lambda)$ e $\alpha_\phi(\lambda)$ de campo foram utilizados para comparação com os valores estimados pelo algoritmo a cada passo. Os dados utilizados neste capítulo foram discriminados, a partir deste ponto, pelos anos de sua coleta, sendo 2015 (junho de 2015), 2016 (julho de 2016), 2017 (agosto de 2017), e para todo o conjunto utilizou-se a sigla LGC.

Os dados foram simulados para as bandas do sensor OLCI, por serem apropriadas para o estudo de ambientes aquáticos, principalmente, pelas feições de absorção da Chl-a nas bandas em 443 nm (B03) e próximo a 665, 674, 681 nm (B08, B09 e B10), e pelo pico de retroespalhamento próximo de 709 nm (B11), associado à concentração de Chl-a. Outro fator importante na escolha do sensor OLCI é sua compatibilidade de bandas com o sensor MERIS (fora de operação), possibilitando sua comparação com trabalhos anteriores publicados.

5.2.1 Algoritmos QAA

Neste trabalho, foram testadas seis versões do QAA propostas por diferentes autores, sendo estas QAA_{v5} (LEE et al., 2009), QAA_{v6} (LEE, 2014), QAA_{M14} (MISHRA et al., 2014), QAA_{BBHR} (WATANABE et al., 2016), QAA_{RDSM} (JORGE, 2018), QAA_{Turbid} (YANG et al., 2013). Dentre estas versões, duas foram

propostos para águas oceânicas (v5 e v6) e quatro para águas interiores (M14, BBHR, RDSM e Turbid). A descrição metodológica do QAA nesta seção segue os passos do QAA_{v5}, pois foi a versão de referência utilizada pelos autores, cujas versões foram testadas neste trabalho, bem como para o QAA_{v6}. As principais modificações realizadas nos passos do QAA em cada versão também são apresentadas. Por simplificação, o QAA foi dividido em duas etapas, a primeira etapa consiste na determinação do $\alpha_t(\lambda)$ e $b_b(\lambda)$ (Passos 0 a 6 - Tabela 5.1) e a segunda na decomposição de $\alpha_t(\lambda)$ nas contribuições $\alpha_\varphi(\lambda)$ e $\alpha_{CDM}(\lambda)$ (Passos 7 a 10 -Tabela 5.1).

Tabela 5.1- Etapas originais do QAA_{v5}.

Passos	Propriedade	Formulação	Método
Passo 0	r_{rs}	$\frac{R_{rs}}{(0,52 + 1,7 R_{rs})}$	Semi-analítico
Passo 1	$u(\lambda) = \frac{b_b(\lambda)}{a(\lambda) + b_b(\lambda)}$	$= -0,089 + \frac{\sqrt{0,089^2 + 4 * 0,125 r_{rs}}}{2 * 0,125}$ $= a_w(\lambda_0) + 10^{-1,146-1,366x-0,469x^2}$	Semi-analítico
Passo 2	$a(\lambda_0)$	$x = \log\left(\frac{r_{rs}(443) + r_{rs}(490)}{r_{rs}(\lambda_0) + 5 \frac{r_{rs}(667)}{r_{rs}(490)} r_{rs}(667)}\right)$	Empírico
Passo 3	$b_{bp}(\lambda_0)$	$= \frac{u(\lambda_0) + a(\lambda_0)}{1 - u(\lambda_0)} - b_{bw}(\lambda_0)$	Analítico
Passo 4	η	$= 2,0 \left(1 - 1,2 \exp\left(-0,9 \frac{r_{rs}(443)}{r_{rs}(\lambda_0)}\right)\right)$	Empírico
Passo 5	$b_{bp}(\lambda)$	$= b_{bp}(\lambda_0) \left(\frac{\lambda_0}{\lambda}\right)^\eta$	Semi-analítico
Passo 6	$a(\lambda)$	$= \frac{(1 - u(\lambda)) + b_{bw}(\lambda) + b_{bp}(\lambda)}{u(\lambda)}$	Analítico
Passo 7	$\zeta = a_\varphi(411)/a_\varphi(443)$	$= 0,74 + \frac{0,2}{0,8 + r_{rs}(443)/r_{rs}(\lambda_0)}$ $e^{S(443-411)}$	Empírico
Passo 8	$\xi = a_{dg}(411)/a_{dg}(443)$	$s = 0,015 + \frac{0,002}{0,6 + r_{rs}(443)/r_{rs}(\lambda_0)}$	Semi-analítico
Passo 9	$a_{dg}(443)$	$= \frac{(a(411) - \zeta a(443)) - (a_w(411) - \zeta a_w(443))}{\xi - \zeta}$	Analítico
Passo 10	$\alpha_\varphi(\lambda)$	$a(\lambda) - a_w(\lambda) - a_{dg}(443) e^{S(\lambda-443)}$	Analítico

Fonte: Adaptado de Lee et al. (2009)

5.2.1.1 Parte 1 - Derivação de α_t

No passo 0 (Tabela 5.1), o QAA deriva analiticamente a $r_{rs}(\lambda)$ a partir da $R_{rs}(\lambda)$ por meio dos fatores estabelecidos na Equação 2.13. No passo 1, a razão entre $b_b(\lambda)$ pela soma $b_b(\lambda)$ e $\alpha(\lambda)$ para cada λ é algebricamente calculada seguindo os modelos de Gordon et al. (1988) e Lee et al. (1999). O passo 2 é uma das partes mais importantes do QAA, quando a absorção no λ_0 é calculada, a partir do pressuposto de que a absorção neste comprimento de onda é dominada por α_w . O comprimento de onda de referência λ_0 foi apontado por diversos estudos como uma das principais fontes de erros na estimativa de $\alpha_t(\lambda_0)$ (LEE et al., 2002, 2009), que se propagam para os passos restantes. A transição do uso do QAA em águas oceânicas para o uso em águas interiores pode ser visto pelo deslocamento do λ_0 (Tabela 5.2) para comprimentos de onda mais longos visando identificar comprimento de onda em que as absorções pelos outros constituintes (CDOM e TSS) tornam-se desprezíveis. A discrepância na escolha do λ_0 entre os autores deve-se a necessidade de seleção precisa do comprimento de onda no qual a absorção da água é dominante, o que varia com a composição e a concentração de COAs em cada ambiente.

Tabela 5.2 - Comprimentos de onda de referência.

Versão	λ_0 (nm)
QAA _{v5}	550,555,560
QAA _{v6}	670
QAA _{BBHR}	709
QAA _{M14}	708
QAA _{RDSM}	708
QAA _{Turbid}	754

Fonte: Produção do autor.

Além da seleção do λ_0 , a primeira parametrização de grande importância para o desempenho do QAA está no passo dois, tanto na definição das bandas de influência dos COAs do parâmetro χ , quanto na calibração dos coeficientes h_0 , h_1 e h_2 para a determinação do $\alpha_t(\lambda_0)$. Estes coeficientes são determinados por padrão no QAA_{v5} como sendo: $h_0=-1,1459$, $h_1=-1,3658$ e $h_2=-0,469$. A seguir, são apresentadas as equações parametrizadas para as versões testadas neste trabalho.

QAA_{v5}:

$$\chi = \log \left(\frac{(r_{rs}(443) + r_{rs}(490))}{r_{rs}(\lambda_0) + 5 \frac{r_{rs}(670)}{r_{rs}(490)} r_{rs}(670)} \right); \quad (5.1)$$

$$\alpha_t(\lambda_0) = \alpha_w(\lambda_0) + 10^{-1,1459-1,3658\chi-0,469\chi^2}$$

QAA_{v6}:

$$\alpha_t(670) = \alpha_w(670) + 0,39 \left(\frac{R_{rs}(670)}{R_{rs}(443) + R_{rs}(490)} \right)^{1,14} \quad (5.2)$$

QAA_{RDSM} – LE (Lagos escuros):

$$\chi = \log \left(r_{rs}(443) + \frac{r_{rs}(620)}{r_{rs}(\lambda_0) + 0,5 \frac{r_{rs}(620)}{r_{rs}(555)} r_{rs}(620)} \right); \quad (5.3)$$

$$\alpha_t(\lambda_0) = \alpha_w(\lambda_0) + 10^{-0,8672-0,3082\chi+4,1447\chi^2}$$

QAA_{RDSM} - LC (Lagos claros):

$$\chi = \log \left(r_{rs}(443) + \frac{r_{rs}(665)}{r_{rs}(\lambda_0) + 0,5 \frac{r_{rs}(620)}{r_{rs}(555)} r_{rs}(620)} \right); \quad (5.4)$$

$$\alpha_t(\lambda_0) = \alpha_w(\lambda_0) + 10^{-66,828-111,5816\chi-45,9832\chi^2}$$

QAA_{BBHR}:

$$\chi = \log \left(\frac{r_{rs}(443) + r_{rs}(665)}{r_{rs}(\lambda_0) + 5 \frac{r_{rs}(620)}{r_{rs}(443)} r_{rs}(620)} \right); \quad (5.5)$$

$$\alpha_t(\lambda_0) = \alpha_w(\lambda_0) + 10^{-0,7702-0,0999\chi-0,0566\chi^2}$$

QAA_{M14}:

$$\chi = \log \frac{(r_{rs}(443) + r_{rs}(620))}{r_{rs}(\lambda_0) + 0,005 \frac{r_{rs}(620)}{r_{rs}(443)} r_{rs}(620)}; \quad (5.6)$$

$$\alpha_t(\lambda_0) = \alpha_w(\lambda_0) + 10^{-0,7153-2,054\chi-1,047\chi^2}$$

Os próximos passos do QAA (passo 3 a 5 – Tabela 5.1) buscam modelar o retroespalhamento espectral, utilizando as Equações 2.12 e 2.14, consolidadas por Gordon e Morel (1983) e Smith e Baker (1981), relacionando $b_b(\lambda)$ com suas frações referentes a água $b_{bw}(\lambda)$ e particulados $b_{bp}(\lambda)$. Portanto, partindo-se do valor de $\alpha(\lambda_0)$ derivado no passo dois e do retroespalhamento da água em λ_0 determinado por Zhang et al. (2007) pode-se calcular o $b_{bp}(\lambda_0)$ por meio da Equação 2.12. Os algoritmos QAA_{BBHR}, QAA_{RDSM} e QAA_{M14} utilizam da estruturação proposta para o QAA_{v5} nos passos 3 a 5. O passo três do QAA_{v6} utiliza da mesma formulação da versão 5, porém, com λ_0 em 670 nm, expressa por:

$$b_{bp}(\lambda_0) = b_{bp}(670) = \frac{u(\lambda_0) * \alpha(\lambda_0)}{1 - u(\lambda_0)} - b_{bw}(670) \quad (5.7)$$

Assumindo que $b_{bp}(\lambda)$ tem um decaimento exponencial com o comprimento de onda, o passo quatro propõe um ajuste empírico do fator potência de η por meio da razão entre as bandas 443 e 555 nm (MERIS - 560 nm). Apresentando uma abordagem alternativa, Yang et al. (2013) (QAA_{Turbid}) propuseram um modelo semi-analítico baseado nas bandas de 750 e 780 nm do MERIS para a estimativa do η dado por:

$$\eta = -372,99 \log \left[\frac{u(750)}{u(780)} \right]^2 + 37,286 \log \left(\frac{u(750)}{u(780)} \right) + 0,84 \quad (5.8)$$

A estimativa de η torna, então, possível determinar $b_{bp}(\lambda)$ espectral no passo cinco. Por fim, retornando novamente às propriedades analíticas da Equação 2.12, no passo seis utiliza-se o $b_{bp}(\lambda)$ derivado anteriormente para obter $\alpha_t(\lambda)$ espectral, encerrando a primeira etapa do QAA.

5.2.1.2 Parte 2 – Derivação de α_{CDM} e α_ϕ

Na segunda etapa, $\alpha_t(\lambda)$ espectral, derivado na primeira etapa, é decomposto nas frações absorção por fitoplâncton ($\alpha_\phi(\lambda)$) e por CDM + detritos ($\alpha_{CDM}(\lambda)$). No passo sete, o parâmetro ζ é estimado de forma empírica, relacionando duas regiões espectrais (λ_1 e λ_2) que possuam influência da absorção pelo fitoplâncton. Dentre os modelos testados, QAA_{v5} e QAA_{v6} utilizam a razão de bandas de 443/560 nm e QAA_{BBHR}(λ) utiliza a razão 665/709 nm. Os modelos QAA_{Turbid}, QAA_{M14} e QAA_{RDSM} não estimam o parâmetro ζ . Segundo (YANG et al., 2013) as relações empíricas determinadas no QAA_{v5} apresentam muita incerteza em águas túrbidas, e portanto inviabiliza a estimativa de $\alpha_\phi(\lambda)$. O parâmetro ξ é derivado de forma semi-analítica no passo oito, em função da absorção pela matéria orgânica, pois, o valor da potência S é determinado através da razão entre a $r_{rs}(\lambda)$ dos comprimentos de onda considerados representativos.

No passo nove, os parâmetros ζ e ξ são utilizados para derivar $\alpha_{dg}(\lambda)$ no comprimento de onda selecionado (Equação 5.9), podendo assim ser propagado para todo o espectro utilizando as propriedades do passo oito do QAA (Tabela 5.1). O coeficiente ζ está relacionado com a concentração de Chl-*a* e a absorção dos pigmentos, enquanto o ξ está relacionado com a absorção por CDM, ambos são estimados utilizando aproximações empíricas (LEE et al., 2002).

$$\alpha_{dg}(443) = \frac{(\alpha(411) - \zeta\alpha(443)) - (\alpha_w(443))}{\xi - \zeta} \quad (5.9)$$

Buscando uma abordagem alternativa, representativa às características das águas altamente túrbidas dos lagos amazônicos, Jorge (2018) propôs uma modificação na estimativa de $\alpha_{dg}(443)$. O autor parte da premissa que $\alpha_t(443)$ possui alta influência de $\alpha_{dg}(443)$, e, portanto, assume que $\alpha_{dg}(443) = \alpha_t(443)$ (Equação 5.10). Mantendo o parâmetro S, QAA_{RDMS} é calibrado com as bandas em 665 e 709 nm conforme a equação a seguir:

$$S = 0,01 + \left(\frac{0,006}{0,6 + \frac{r_{rs}(665)}{r_{rs}(709)}} \right) \quad (5.10)$$

$$\alpha_{dg}(\lambda) = \alpha_t(443) \exp(-S(\lambda - 443))$$

Por fim, o $\alpha_\phi(\lambda)$ é derivado algebricamente, removendo $\alpha_w(\lambda)$ e $\alpha_{dg}(\lambda)$ de $\alpha_t(\lambda)$ derivado na primeira parte do QAA (Equação 5.11). Podemos notar que a estimativa de $\alpha_\phi(\lambda)$ é feita de forma semelhante a abordagens laboratoriais, estimando $\alpha_t(\lambda)$ e $\alpha_{dg}(\lambda)$ e obtendo $\alpha_\phi(\lambda)$ de forma algébrica. Assim, não é necessário pressupor uma assinatura para a comunidade fitoplanctônica (coeficiente de absorção específico do fitoplâncton) e, para estudos voltados à compreensão destas comunidades, o QAA pode gerar resultados mais precisos.

$$\alpha_\phi(\lambda) = \alpha_t(\lambda) - \alpha_w(\lambda) - \alpha_{dg}(\lambda) \quad (m^{-1}) \quad (5.11)$$

Devido às incertezas associadas aos parâmetros ξ e ζ , o QAA_{Turbid} não propõe uma metodologia para determinação do $\alpha_\phi(\lambda)$ e $\alpha_{CDM}(\lambda)$, por isto, foram utilizados os parâmetros propostos no QAA_{v5} , possibilitando assim a

comparação dos resultados no passo 2 com os outros QAAs. O desempenho dos algoritmos da literatura foi utilizado como base para a parametrização do QAA_{LGC} para a área de estudo deste trabalho, e seus resultados foram comparados.

5.2.2 Parametrização do QAA_{LGC}

As diferentes versões do QAA apontam para a importância das características de cada ambiente para a parametrização precisa do QAA. Águas turbidas com grande influência de CDOM, como os lagos do baixo Amazonas, são dependentes das condições ambientais do entorno e podem ter suas características altamente influenciadas pela geologia, pedologia e hidrologia da região. Portanto, é esperado a ineficiência dos algoritmos da literatura parametrizados para outros ambientes, sendo necessário o ajuste dos mesmos para cada ambiente (LEE, 2014; LEE et al., 2009; MISHRA et al., 2014).

Desta forma, neste trabalho, a versão do QAA_{LGC} foi parametrizada para as condições bio-ópticas dos lagos da planície de inundação do baixo Amazonas. A reparametrização para o QAA_{LGC} foi realizada com a estrutura original do QAA_{v5} (LEE et al., 2009), com a parametrização e calibração de suas etapas empíricas. As relações semi-analíticas dos passos zero e um, para determinar a $r_{rs}(\lambda)$ e u , foram utilizadas conforme a versão original QAA_{v5}, mantendo também os fatores g_0 e g_1 .

Para a seleção do (λ_0) , foram realizados testes com as parametrizações da literatura nos comprimentos de onda de 560, 670, 709 e 754 nm. Com a alta influência do CDOM e dos materiais particulados nos comprimentos de onda menores, para águas interiores, o deslocamento do λ_0 para 709 e 754 nm pode auxiliar em estimativas mais precisas, minimizando os erros na derivação de $\alpha_t(\lambda)$ pela influência dos COAs (LEE et al., 2009; MISHRA et al., 2013, 2014). Na parametrização de χ , os parâmetros h_0 , h_1 e h_2 foram utilizados conforme o QAA_{v5} original e as bandas do sensor OLCI foram testadas na conformação da Equação 5.12.

$$\chi = \log \frac{(r_{rs}(\lambda_1) + r_{rs}(\lambda_2))}{r_{rs}(\lambda_0) + x \frac{r_{rs}(\lambda_3)}{r_{rs}(\lambda_4)} r_{rs}(\lambda_3)} \quad (5.12)$$

Onde $r_{rs}(\lambda_n)$ é a reflectância de sensoriamento remoto em subsuperfície nos n comprimentos de onda de referência e λ_1 , λ_2 , λ_3 e λ_4 são os comprimentos de onda relacionados com os constituintes presentes na água. O passo seguinte, foi a determinação das bandas e coeficientes da relação empírica η , que descreve a inclinação do decaimento do retroespalhamento por partículas ($b_{bp}(\lambda)$), diretamente relacionado com a derivação do $\alpha_t(\lambda)$ no QAA. Para isto, foi mantida a estrutura da equação do passo quatro do QAA_{v5}, variando os coeficientes a (1,3 a 2,0), b (0,5 a 1,5) e c (0,1 a 0,9), juntamente com as bandas λ_0 e λ_1 (Equação 5.13), conforme testado por outros autores (JORGE, 2018; RODRIGUES, 2017; WATANABE et al., 2016). A modificação da razão de bandas de $443/\lambda_0$ para as bandas de $655/709$ proposto por Rodrigues (2017) também foi testada neste passo.

$$\eta = a \left(b \exp \left(-c \frac{r_{rs}(\lambda_0)}{r_{rs}(\lambda_1)} \right) \right) \quad (5.13)$$

Como passo final da primeira etapa do QAA, a curva espectral de $\alpha_t(\lambda)$ foi derivada analiticamente seguindo o passo seis, e suas frações $\alpha_\phi(\lambda)$ e $\alpha_{CDM}(\lambda)$ foram decompostas por meio dos coeficientes ξ e ζ na segunda parte do QAA. Na versão 5, o QAA utiliza os comprimentos de onda de 443 e 411 nm para a derivar ξ e ζ , neste trabalho as bandas das equações 5.14 e 5.15 foram ajustadas para o sensor OLCI, em 443 e 413 nm.

$$\zeta = \frac{\alpha_\phi(413)}{\alpha_\phi(443)} = a + \frac{b}{c + r_{rs}(\lambda_1)/r_{rs}(\lambda_2)} \quad (5.14)$$

$$S = a + \frac{b}{c + r_{rs}(\lambda_1)/r_{rs}(\lambda_2)} \quad (5.15)$$

$$\xi = \frac{\alpha_{CDM}(413)}{\alpha_{CDM}(443)} = e^{S(443-413)}$$

O $\alpha_{CDM}(443)$ foi derivado analiticamente no Passo 9 (Figura 5.1), removendo a influência de $\alpha_{\varphi}(\lambda)$ e $\alpha_w(\lambda)$ de $\alpha_t(\lambda)$. Utilizando o *slope* espectral S parametrizado no passo anterior com $\alpha_{CDM}(443)$, foi possível determinar $\alpha_{CDM}(\lambda)$ para todo o espectro e, por fim $\alpha_{\varphi}(\lambda)$, foi matematicamente extraído de $\alpha_t(\lambda)$, conforme proposto por Lee et al. (2009) no passo 10 do QAA.

Levando em consideração as características dos lagos da planície de inundação amazônica e a complexidade da interação de seus constituintes, Jorge (2018) propôs uma nova abordagem para a separação de $\alpha_{CDM}(\lambda)$ e $\alpha_{\varphi}(\lambda)$ na parametrização do QAA_{RDSM}. Segundo o autor, em sua área de estudo, a influência de $\alpha_{CDM}(\lambda)$ nos comprimentos de onda iniciais (400, 413 e 443 nm) é dominante em $\alpha_t(\lambda)$, o que permite assumir que $\alpha_{CDM}(443) = \alpha_t(443)$. Assim, $\alpha_{CDM}(\lambda)$ é diretamente derivado da Equação 2.16, modificada em função de $\alpha_t(\lambda)$ e utilizando o fator S (Equação 5.16). A partir da determinação de $\alpha_{CDM}(\lambda)$, $\alpha_{\varphi}(\lambda)$ é matematicamente determinado como na versão apresentada por Lee et al. (2009).

$$S = 0,01 + \frac{0,006}{0,6 + r_{rs}(665)/r_{rs}(709)} \quad (5.16)$$

$$\alpha_{dg}(\lambda) = \alpha_t(443)e^{S(\lambda-443)}$$

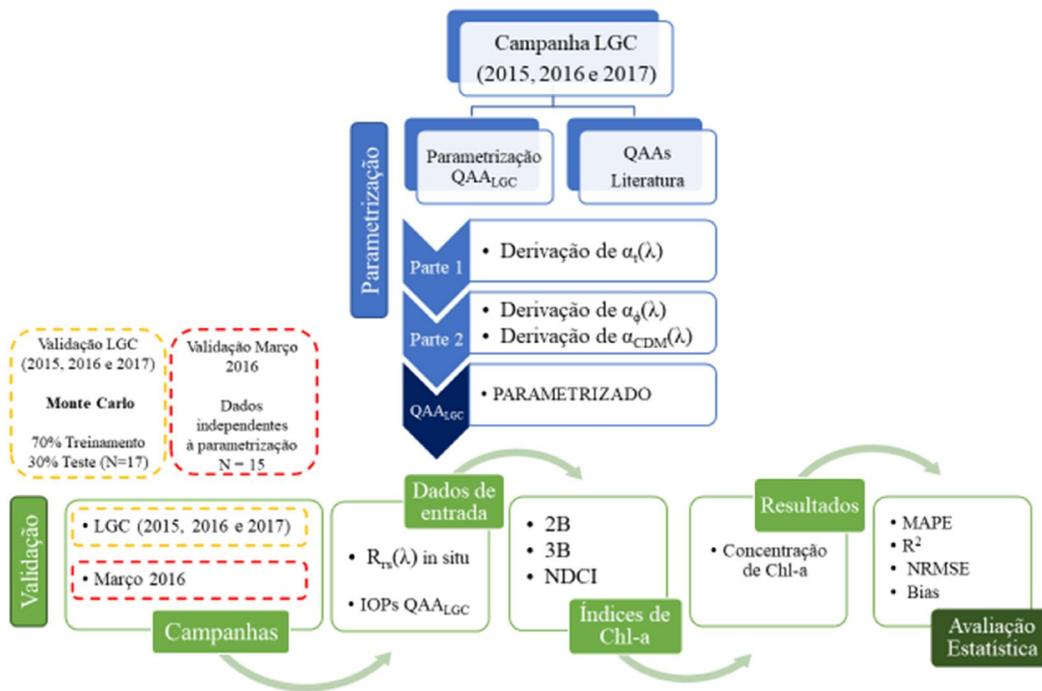
Com esta modificação Jorge (2018) supriu, de certa forma, a incerteza na estimativa de ζ em um ambiente em que os dados apresentam pouca relação com a absorção por pigmentos e pela concentração de Chl-a. A modificação apresentada por Jorge (2018) na parametrização do QAA_{RDSM} foi testada neste

trabalho como alternativa ao QAA original, buscando assim reduzir as premissas empíricas na estimativa de ζ , com um aporte teórico robusto.

5.2.3 Validação

Buscando avaliar o desempenho do QAA_{LGC} parametrizado neste trabalho, foram propostas duas abordagens de validação descritas no fluxograma a seguir (Figura 5.2). Na parte central do fluxograma (tons de azul), são apresentados os passos da parametrização do QAA descritos anteriormente e divididos conforme a secção 5.2.1. Na parte inferior, em tons de verde, são apresentados os passos da validação utilizando os dados de campo e os produtos (IOPs) do QAA_{LGC} . Em amarelo, a descrição da validação utilizando a simulação MC com os dados das campanhas de 2015, 2016 e 2017, com amostras pseudoaleatórias na proporção 70/30 para calibração e validação, respectivamente. Em vermelho, a descrição da validação utilizando a campanha de março de 2016, não utilizada na calibração do QAA_{LGC} .

Figura 5.2 - Fluxograma de Parametrização (azul) e validação (verde) do QAA_{LGC} .



Fonte: Produção do Autor.

A seguir são apresentados os algoritmos empíricos e seus respectivos índices adaptados para as IOPs, bem como os métodos estatísticos utilizados para a avaliação do seu desempenho.

5.2.3.1 Índices de clorofila-a adaptados às IOPs

A partir das IOPs estimadas com o QAA_{LGC} , foram parametrizados modelos bióticos empíricos para a estimativa da concentração de Chl-a. Devido ao pico de absorção do fitoplâncton em 443 nm, algoritmos utilizando as razões de banda azul/verde são eficazes para estimativa de Chl-a em águas oceânicas (CARDER et al., 1999; MATTHEWS, 2011). Porém, para águas interiores altamente túrbidas, com grande influência de sedimentos e CDOM nos comprimentos de onda inferiores, esta região fica comprometida. Utilizando o segundo pico de absorção devido ao fitoplâncton, em aproximadamente 665 nm, algoritmos bióticos de razão vermelho/NIR se mostram eficazes devido à baixa influência de CDOM e detritos (GITELSON et al., 2008; ODERMATT et al., 2012). Para águas muito túrbidas, onde ainda exista influência do material particulado na região do NIR, Le et al. (2013) propõe a utilização de algoritmos com bandas acima de 750 nm.

Foram testados neste trabalho índices para estimativa da concentração de Chl-a, utilizando-se da razão Vermelho/NIR baseados nos algoritmo de 2 e 3 bandas (GITELSON et al., 2008) e no modelo NDCI (MISHRA; MISHRA, 2012). Estes índices foram matematicamente decompostos por Le et al. (2013) em função das IOPs ($\alpha_{\varphi}(\lambda)$ e $\alpha_w(\lambda)$). Assim, estimativas da concentração de Chl-a utilizando as IOPs obtidas pelo QAA_{LGC} puderam ser comparadas aos índices originais utilizando dados de $R_{rs}(\lambda)$. Como proposto em Watanabe et al. (2016), foram selecionadas as bandas em 665, 709 e 754 nm para a aplicação nos índices utilizando $\alpha_{\varphi}(\lambda)$, $\alpha_{CDM}(\lambda)$ e $\alpha_w(\lambda)$. As Equações 5.17, 5.18 e 5.19 apresentam os índices testados e suas respectivas derivações.

$$2B = R_{rs}(709) / R_{rs}(665); \quad (5.17)$$

$$\psi_1 = (\alpha_\varphi(665) + \alpha_w(665) / \alpha_w(709))$$

$$3B = [R_{rs}^{-1}(665) + R_{rs}^{-1}(709)] * R_{rs}(754);$$

$$\psi_2 = \frac{[\alpha_\varphi(665) + \alpha_w(665) - \alpha_\varphi(709) - \alpha_w(709)]}{\alpha_w(754)} \quad (5.18)$$

$$NDCI = \frac{R_{rs}(709) - R_{rs}(665)}{R_{rs}(709) + R_{rs}(665)}; \quad (5.19)$$

$$\psi_3 = \frac{\alpha_w(665) + \alpha_\varphi(665) - \alpha_w(709)}{\alpha_w(665) + \alpha_{CDM}(665) + \alpha_\varphi(665) + \alpha_w(709) + \alpha_{CDM}(709)}$$

O desempenho dos QAAs testados e também do QAA_{LGC} parametrizado foram avaliados através dos métodos estatísticos da raiz do erro quadrático médio (RMSE), raiz do erro quadrático médio normalizado (NRMSE), erro percentual médio absoluto (MAPE) e bias conforme descrito no Capítulo 3.

5.3 Resultados e discussão

5.3.1 Parâmetros de qualidade da água

Os dados *in situ* utilizados neste capítulo apresentaram uma média de concentração de clorofila de 14,51 mg.m⁻³ (Tabela 5.3) com a amplitude de 0,35 mg.m⁻³ (Curuai 01 - 2015) para 85,05 mg.m⁻³ (Curuai 02 - 2016). A campanha de 2015 apresentou as concentrações mais baixas, com variação de 0,35 a 8,59 mg.m⁻³ com uma média 4,47 vezes menor que a média de todos os dados (3,25 mg.m⁻³). Na campanha de 2016, os valores tiveram uma variação maior, de 5,25 até 85,05 mg.m⁻³, com valor médio de 30 mg.m⁻³. Em 2017, a média de concentração é 25,65 mg.m⁻³ e a amplitude de 2,82 a 67,85 mg.m⁻³. As concentrações mínimas de Chl-a na campanha de 2016 foram semelhantes às do máximo em 2015. A campanhas de 2016 e 2017 apresentaram médias e medianas similares para a Chl-a.

Tabela 5.3 - Estatísticas descritivas dos parâmetros de qualidade da água medidos in situ.

		Chl-a	TSS	TSI	TSO	TSO / TSS	TSI / TSS	Secchi	Prof
2015 (n=30)	Mínimo	0,35	5,25	2,00	3,25	0,17	0,28	0,30	3,70
	Média	3,25	16,46	9,81	6,68	0,45	0,55	0,60	6,04
	Máximo	8,59	33,20	27,60	12,75	0,72	0,83	1,10	7,70
	Mediana	2,94	17,38	9,13	5,83	0,45	0,55	0,50	6,60
	σ	2,00	7,07	6,16	2,62	0,16	0,16	0,22	1,13
2016 (n=06)	Mínimo	5,25	18,75	11,25	7,50	0,30	0,41	0,28	4,50
	Média	30,01	33,98	19,02	14,96	0,44	0,56	0,34	4,85
	Máximo	85,05	45,00	31,33	21,25	0,59	0,70	0,38	5,50
	Mediana	23,59	36,15	17,79	15,13	0,42	0,58	0,35	4,65
	σ	29,36	9,92	7,28	5,26	0,10	0,10	0,04	0,44
2017 (n=22)	Mínimo	2,82	7,00	3,38	3,63	0,14	0,32	0,20	3,00
	Média	25,65	27,72	20,60	7,13	0,34	0,66	0,49	4,11
	Máximo	67,85	81,00	70,00	12,13	0,68	0,86	1,15	5,30
	Mediana	21,12	22,40	13,91	6,50	0,29	0,71	0,42	4,40
	σ	18,39	19,12	17,92	2,44	0,17	0,17	0,26	0,82

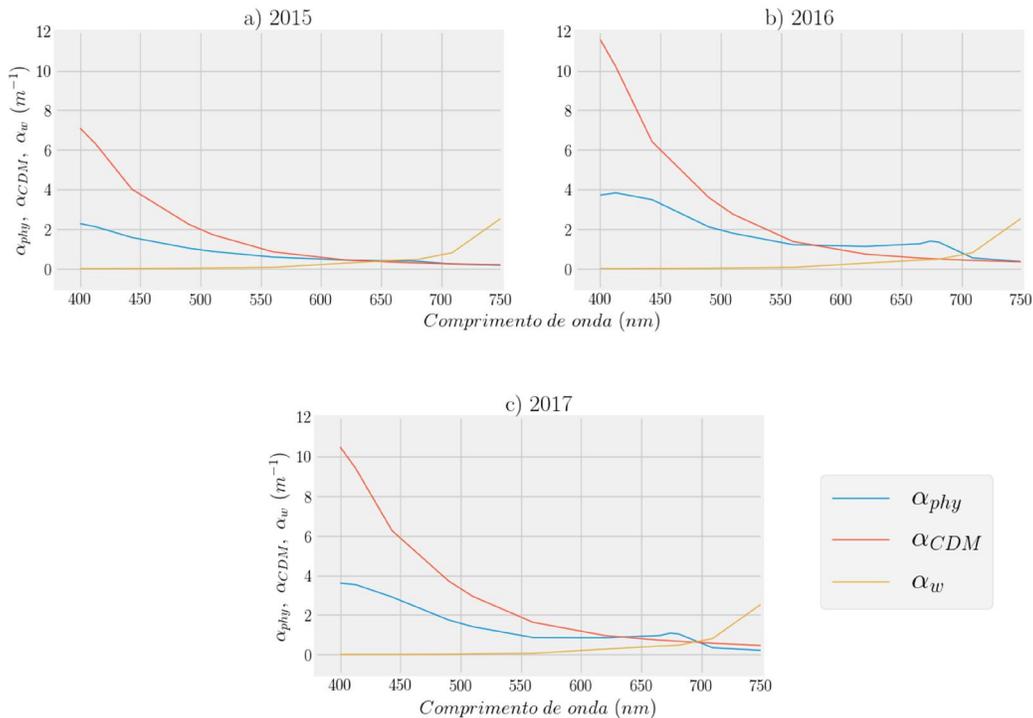
(Chl-a - mg.m⁻³); concentração de sólidos totais em suspensão (TSS - mg.L⁻¹); concentração de sólidos orgânicos em suspensão (TSO - mg.L⁻¹), concentração de sólidos inorgânicos em suspensão (TSI - mg.L⁻¹); Profundidade Secchi (m); Profundidade (m).

Fonte: Produção do Autor.

As concentrações médias dos totais de sólidos em suspensão foram de 16,46, 33,98 e 27,72 mg.L⁻¹ para 2015, 2016 e 2017, respectivamente. As campanhas de 2015 e 2016 apresentaram desvios padrão similares, 7,07 (2015) e 9,92 mg.L⁻¹ (2016), porém com médias de 16,46 (2015) e 33,98 (2016) mg.L⁻¹, respectivamente. Comparando-se a razão das frações orgânicas (TSO) e inorgânicas (TSI) dos sólidos por seu total (TSS) verifica-se a predominância do TSI com médias entre 55% e 66% em todas as campanhas e valores máximos de 83% em 2015, 70% em 2016 e 86% em 2017. Em todo o conjunto de dados, a profundidade de Secchi representou em média 10,5% da profundidade total do corpo d'água, atingindo o máximo de penetração no ponto Curuai 16 de 2017 com 23%.

A Figura 5.3 apresenta os valores médios de absorção por fitoplâncton ($\alpha_{phy}(\lambda)$) e CDOM com detritos ($\alpha_{CDM}(\lambda)$) em comparação com a absorção da água pura de Pope e Fry (1997) para as campanhas: a) 2015, b) 2016 e c) 2017. Nota-se que, em todas as campanhas, a influência de $\alpha_{phy}(\lambda)$ e $\alpha_{CDM}(\lambda)$ entre 400 e aproximadamente 680 nm, as quais determinam, a magnitude e o formato do espectro de absorção nesta região. Na campanha de 2015, a influência da água foi predominante a partir de aproximadamente 680 nm e nas demais campanhas após 700 nm. É possível constatar, também, uma maior influência do $\alpha_{CDM}(\lambda)$ até 550 nm em relação ao $\alpha_{phy}(\lambda)$. Apenas nas campanhas de 2016 e 2017 foi possível visualizar a feição de absorção do fitoplâncton próximo a 675 nm, sendo principalmente relacionados com a Chl-a.

Figura 5.3 - Coeficientes $\alpha_{phy}(\lambda)$, $\alpha_{CDM}(\lambda)$, e $\alpha_w(\lambda)$ obtidos em laboratório e simulados para as bandas do sensor OLCI para as campanhas a) 2015, b) 2016 e c) 2017.



Fonte: Produção do autor.

A Tabela 5.4 mostra os resultados exploratórios para os dados de absorção medidos em laboratório e simulados para as bandas do sensor OLCI. Os dados de $\alpha_{\phi}(443)$, $\alpha_{\phi}(665)$ e $\alpha_{\phi}(674)$ se referem aos picos de absorção do fitoplâncton (443, 665 e 674 nm). A influência do CDOM com detritos também foi analisada a partir dos valores de $\alpha_{\text{CDM}}(413)$ e $\alpha_{\text{CDM}}(443)$. Em relação ao $\alpha_{\phi}(443)$, as campanhas 2016 e 2017 apresentaram valores similares, de 1,36 a 6,30 m^{-1} em 2016 e 1,11 a 8,33 em 2017, porém, a campanha de 2015 apresentou média 2 vezes menor, com seu máximo sendo menor que as médias das outras campanhas. O padrão se repetiu em $\alpha_{\phi}(443)$, porém, com a média de 2015 de 2 a 3 vezes menor que as outras campanhas. Os valores de $\alpha_{\text{CDM}}(443)$ foram 2,25 vezes maiores que $\alpha_{\phi}(443)$ para todas as campanhas, com a maior diferença para a campanha de 2015 (2,55) e a menor para 2016 (1,84).

Tabela 5.4 - Estatística descritiva das IOPs (α_{ϕ} e α_{CDM}) medidas em laboratório.

	$\alpha_{\phi}(443)$	$\alpha_{\phi}(665)$	$\alpha_{\phi}(674)$	$\alpha_{\text{CDM}}(413)$	$\alpha_{\text{CDM}}(413)$	$\alpha_{\phi}(443) / \alpha_{\text{CDM}}(443)$	
2015 (n=30)	Mínimo	0,75	0,12	0,12	3,53	2,40	0,23
	Média	1,57	0,38	0,39	6,30	4,01	0,40
	Máximo	2,81	0,59	0,58	8,87	5,61	0,55
	Mediana	1,54	0,38	0,39	6,33	3,98	0,38
	σ	0,47	0,12	0,12	1,54	0,96	0,09
2016 (n=06)	Mínimo	1,36	0,45	0,46	7,60	4,69	0,29
	Média	3,48	1,25	1,39	10,19	6,41	0,53
	Máximo	6,30	2,48	2,90	12,53	7,94	0,88
	Mediana	3,61	1,24	1,33	10,33	6,53	0,51
	σ	1,73	0,70	0,85	1,73	1,16	0,23
2017 (n=22)	Mínimo	1,11	0,37	0,43	3,51	2,26	0,28
	Média	2,91	0,96	1,08	9,39	6,26	0,47
	Máximo	8,33	1,67	1,77	16,33	10,89	1,25
	Mediana	2,56	0,87	1,06	8,97	6,05	0,44
	σ	1,55	0,34	0,38	3,05	2,07	0,20

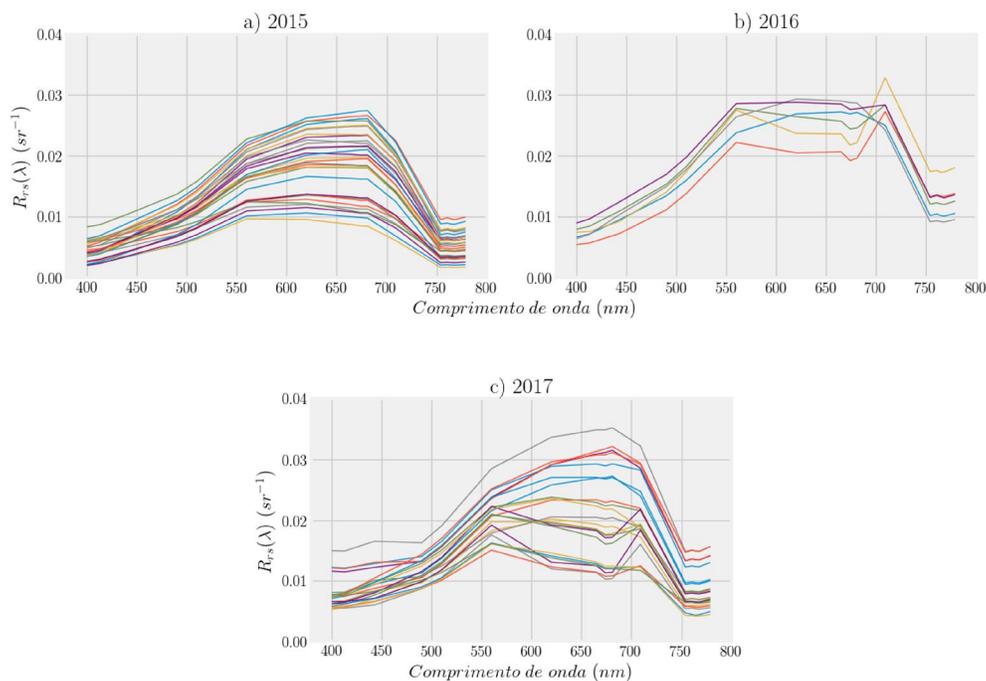
α_{ϕ} em 443, 665 e 674 nm (m^{-1}); α_{CDM} em 413 e 443 nm (m^{-1}); e a razão $\alpha_{\phi}(443) / \alpha_{\text{CDM}}(443)$.

Fonte: Produção do autor.

5.3.2 Caracterização biótica

As principais características espectrais encontradas nos dados de $R_{rs}(\lambda)$ para comprimentos de onda iniciais (<550 nm), nas três campanhas de campo, estão relacionadas com a absorção por CDOM e matéria particulada (Figura 5.4). Na região espectral do azul, todo o conjunto de dados utilizado não apresentou características da absorção relacionada com os pigmentos do fitoplâncton, mantendo-se constante até ~570 nm. Na região espectral entre 550 e 650 nm, é possível observar variações na magnitude das curvas espectrais com a manutenção da forma, podendo ser associado a variação da concentração do material particulado. Na campanha de 2015, devido à baixa concentração de Chl-a, suas feições não são detectáveis em nenhuma das curvas espectrais. Para as campanhas de 2016 e 2017, é possível identificar o vale na $R_{rs}(\lambda)$ em aproximadamente 675 nm, devido à forte absorção dos pigmentos do fitoplâncton. A influência do material particulado pôde também ser observada ao longo de todo o espectro, nas três campanhas, corroborando com Doxaran et al. (2002) que reportou aumento da $R_{rs}(\lambda)$ entre 550 e 850 nm, com o aumento da concentração TSS. A partir de ~710 nm todas as curvas espectrais da $R_{rs}(\lambda)$ apresentaram drástica redução devido a crescente influência da absorção da água.

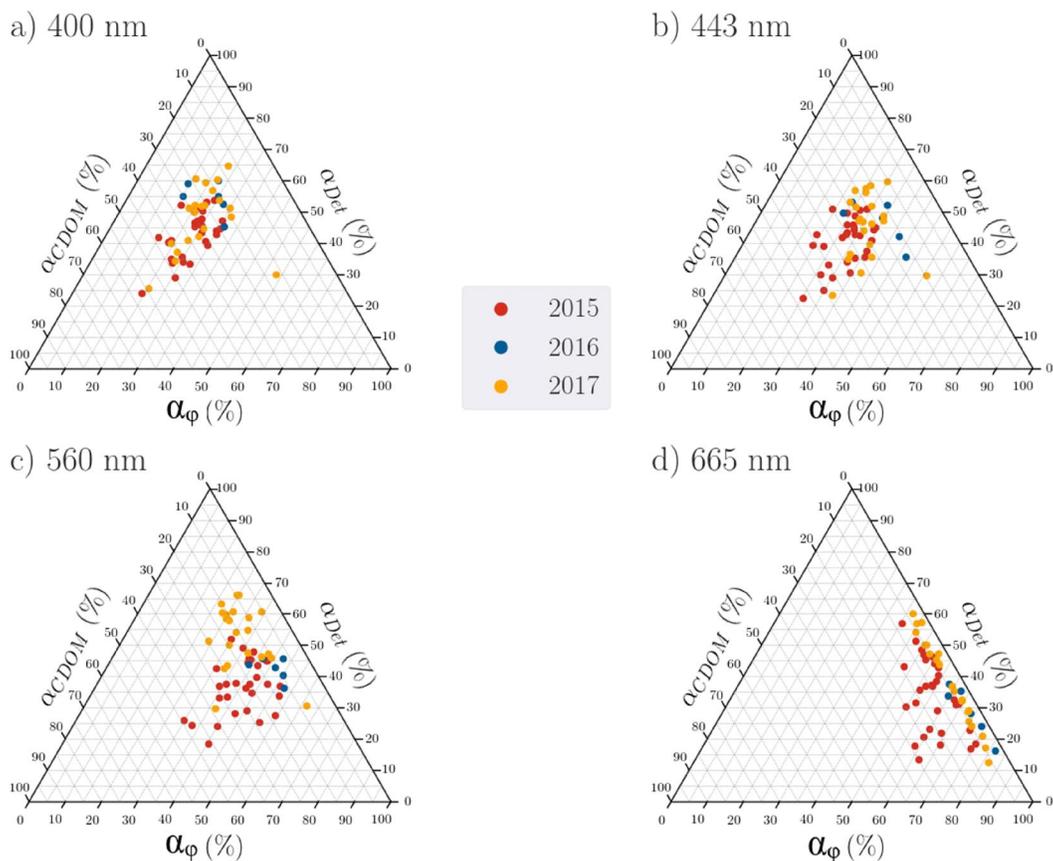
Figura 5.4 - Espectro da $R_{rs}(\lambda)$ simulados para as bandas do sensor OLCI para as campanhas a) 2015 (n=30), b) 2016 (n=06) e c) 2017 (n = 22).



Fonte: Produção do Autor.

A contribuição relativa dos principais COAs (fitoplâncton, CDOM e detritos), desconsiderando a absorção da água, pode ser observada na Figura 5.5. As bandas em 400, 443, 560 e 665 nm foram selecionadas devido a sua boa correlação com material particulado, CDOM e fitoplâncton. Na região de 400 nm é possível observar a dominância do CDOM e detritos, com valores α_{ϕ} de abaixo de 30% em todas as amostras. Para 443 nm a contribuição de α_{ϕ} é mais expressiva, com valores variando de 30% a 55%. Nas regiões de 560 e 665 nm, a influência do CDOM na absorção é fortemente reduzida, porém, a contribuição do detrito ainda se mostra expressiva. Como esperado, a influência da absorção por fitoplâncton em 665 nm é dominante, mas se mostra muito variável, com mínimo em 40% e máximo em 85%.

Figura 5.5 - Gráfico ternário comparando as frações α_ϕ , α_{CDOM} e α_{Det} nos comprimentos de onda a) 400 nm, b) 443 nm, c) 560 nm e d) 665 nm.



Fonte: Produção do Autor.

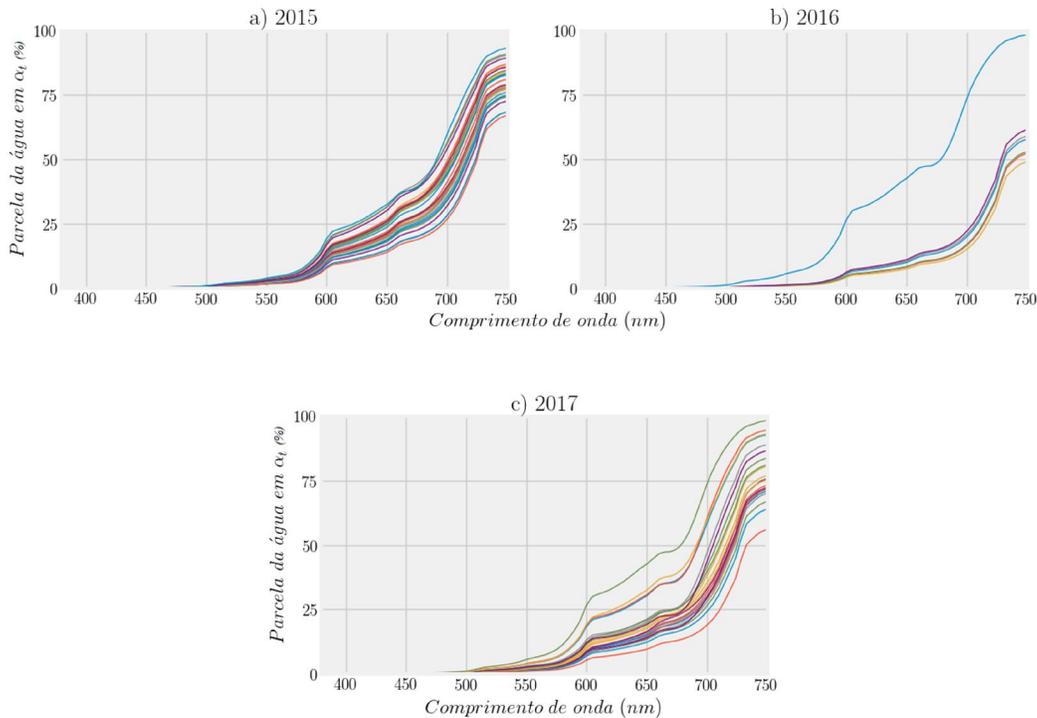
5.3.3 Etapa 1 – Estimativa de $\alpha_t(\lambda)$

A Figura 5.6 apresenta uma análise da contribuição da absorção da água ($\alpha_w(\lambda)$) em relação a $\alpha_t(\lambda)$, utilizando aos dados hiperespectrais coletados com o equipamento AC-S, com a adição da água determinada por Pope e Fry (1997). Nota-se a baixa contribuição de $\alpha_w(\lambda)$ até 600 nm, com valores menores que 10%, violando, nesta região, a premissa inicial adotada por Lee (2009) em relação ao valor de λ_0 para viabilizar a utilização do QAA_{v5} .

Em sua versão mais recente, o QAA utiliza da banda em 670 nm, região onde a contribuição é em média aproximadamente 25% para todas as campanhas. Para 709 nm esta relação se aproxima de 45% em todas as campanhas, porém, na campanha de 2016, esse valor fica em torno de 26%, podendo

acarretar baixo desempenho no QAA, ao se utilizar o λ_0 nesta região. Na região do infravermelho, próximo de 750 nm, a relação média fica em 75%, com baixa novamente para a campanha de 2016 entorno de 55%.

Figura 5.6 - Contribuição da água na absorção total nas campanhas: a) 2015, b) 2016 e c) 2017.



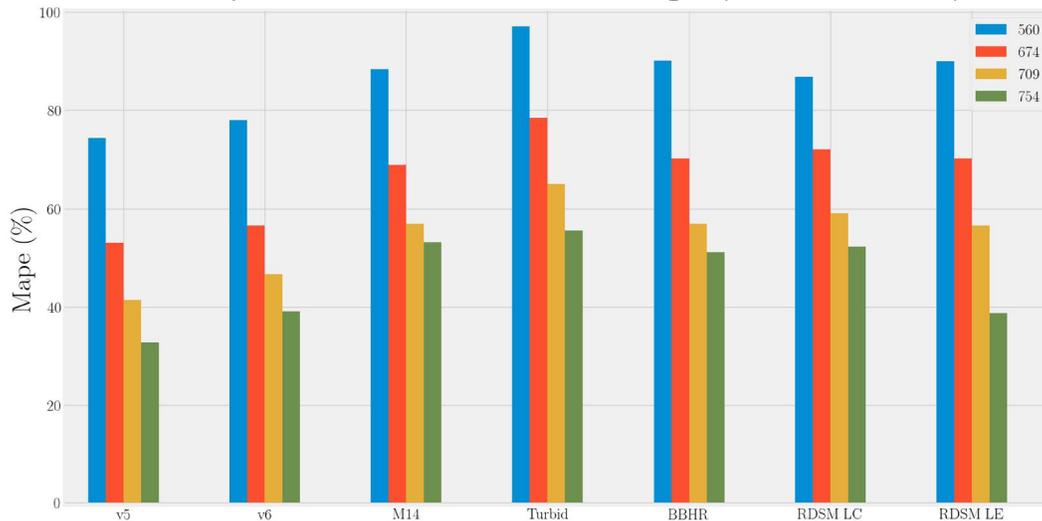
Fonte: Produção do Autor.

O primeiro passo para o desenvolvimento de uma versão do QAA parametrizada para os lagos da planície amazônica foi testar as versões do algoritmo disponíveis na literatura em suas proposições originais. Estes algoritmos foram adaptados para ambientes totalmente distintos, abrangendo um amplo espectro de águas. A aplicação destes algoritmos nos dados LGC podem auxiliar no entendimento e parametrização do QAA, porém, com a alta influência do CDOM e materiais particulados no espectro, as premissas do QAA em isolar uma região do espectro em que os efeitos da água pura são majoritários, podem ficar comprometidas. Para avaliar o potencial impacto da seleção do comprimento de onda de referência (λ_0) na estimativa de $\alpha_t(\lambda)$, os

modelos da literatura foram testados apenas alterando λ_0 para as bandas de 560, 670, 709 e 754 nm, sem nenhuma outra modificação em sua estrutura. A Figura 5.7 apresenta o resultado de MAPE médio de $\alpha_t(\lambda)$ estimado para cada modelo nos λ_0 selecionados, comparados com os dados do AC-S + água (POPE; FRY, 1997).

Os modelos QAA_{BBHR} , QAA_{M14} , QAA_{RDSM} (ambos os lagos) apresentaram resultados similares, com valores de MAPE de aproximadamente 100% para $\lambda_0(560)$ em todo o espectro. Com $\lambda_0(670)$ a variação de MAPE foi de aproximadamente 80% até 60% no decorrer do espectro e para $\lambda_0(709)$ o MAPE variou de ~65% a ~45%. Os melhores resultados de MAPE foram obtidos para $\lambda_0(754)$ variando de 33% a 57%. O modelo QAA_{v5} apresentou um desempenho entorno de 20% melhor que os outros nas bandas de 560, 670 e 709, seguindo o mesmo padrão dos outros modelos. Para a banda de 754 nm, o QAA_{v5} obteve resultados de MAPE em torno de 30% em comprimentos de onda até 560 nm, os quais aumentaram até atingir 709 nm, quando atingiu 38%.

Figura 5.7 - MAPE médio de $\alpha_t(\lambda)$ estimado para cada modelo nos λ_0 selecionados, comparados com os dados do AC-S + água (POPE; FRY, 1997).



Fonte: Produção do Autor.

De acordo com a literatura, o deslocamento do λ_0 para os comprimentos de onda maiores beneficiaram o desempenho dos algoritmos, devido a influência do CDOM e dos materiais particulados no início do espectro. Portanto, levando em consideração os resultados dos modelos da literatura e a análise exploratória dos dados, optou-se pela banda de 754 nm como o comprimento de onda de referência para a parametrização do QAA_{LGC} , seguindo a tendência dos autores Yang et al. (2013).

A base do QAA_{LGC} seguiu as etapas e a estruturação do QAA_{V5} , porém, com a reparametrização das relações empíricas. Após a parametrização, as bandas da equação η foram selecionadas para as características do ambiente de estudo. Devido à baixa influência da Chl-a na absorção total (Figura 5.3), as bandas selecionadas buscaram suprir a influência remanescente dos materiais em suspensão, sendo estas 400, 413, 674 e 490 nm compreendidas pelas bandas B01, B02, B09 e B04 do sensor OLCI, respectivamente. Modificações nos coeficientes h_0 , h_1 e h_2 foram testadas juntamente com as alterações nas bandas, porém, os valores propostos por Lee (2009) para o QAA_{V5} apresentaram os melhores resultados. A Equação 5.24 apresenta a formulação definida para o QAA_{LGC} .

$$\chi = \log \left(\frac{(r_{rs}(400) + r_{rs}(413))}{r_{rs}(754) + 5 \frac{r_{rs}(674)}{r_{rs}(490)} r_{rs}(674)} \right); \quad (5.24)$$

$$\alpha_t(754) = \alpha_w(754) + 10^{-1,1459 - 1,3658\chi - 0,46927\chi^2}$$

A estimativa de $\alpha_t(\lambda)$ nos passos seguintes do QAA está analiticamente relacionada com $b_b(\lambda)$. Considerando-se o $b_{bw}(\lambda)$ como invariável, assumiu-se neste trabalho que ele poderia ser representado pela curva espectral determinada por Zhang et al. (2007). A dependência espectral de $b_{bp}(\lambda)$ é determinada pela Equação 2.15, assumindo-se um fator espectral de potência (η) para seu decaimento espectral. Além da seleção do λ_0 , a determinação

precisa deste fator é apontada como de grande influência para as estimativas de $\alpha_t(\lambda)$ (LEE et al., 2002; RODRIGUES, 2017; YANG et al., 2013). Em suas versões originais, o QAA (LEE, 2006, 2014; LEE et al., 2002, 2009) propõem uma razão empírica utilizando a $R_{rs}(\lambda)$ entre as bandas de 443 e 560 nm. Segundo Carder et al. (1999) as variações na $R_{rs}(\lambda)$ nestas bandas é altamente determinado pelas absorções do fitoplâncton e CDOM. Para este trabalho foram testados variações nos coeficientes e bandas propostas no QAA_{v5} . O modelo semi-analítico utilizando as bandas de 750 e 780 nm proposto por Yang et al. (2013) também foi avaliado para estimativa de η . Em relação aos coeficientes (a, b e c), os melhores resultados foram obtidos mantendo os valores originais do QAA_{v5} , utilizando a razão das bandas em 665 e 754 nm como proposto em Rodrigues (2017) (Equação 5.25).

$$\eta = 2 \left(1 - 1,2 \exp \left(-0,9 \frac{r_{rs}(665)}{r_{rs}(754)} \right) \right) \quad (5.25)$$

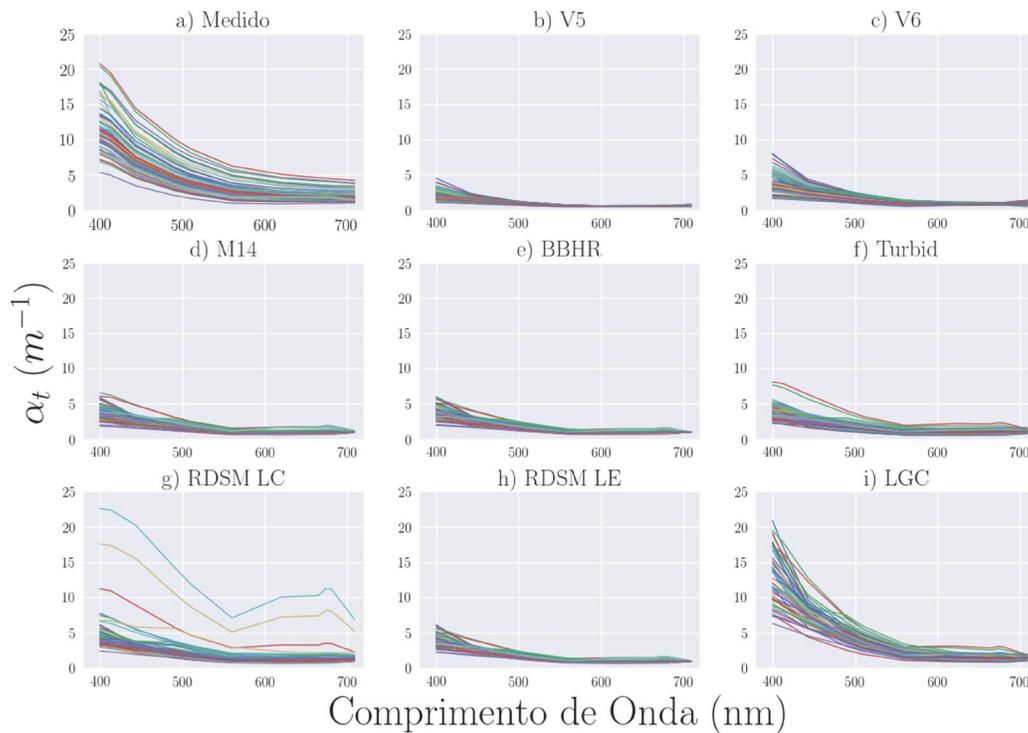
Os valores de η obtidos pelo QAA_{LGC} variaram de 1,28 a 1,98 com média de 1,79. Tipicamente os valores podem variar de 0 a 2,2, com valores maiores associados ao retroespalhamento por partículas pequenas e , tipicamente, à águas oligotróficas (GORDON; MOREL, 1983; LEE et al., 2002; SATHYENDRANATH et al., 2001). Com o $b_b(\lambda)$ estimado utiliza-se das propriedades da Equação 2.12 (GORDON et al., 1988) para determinar analiticamente $\alpha_t(\lambda)$ espectral, seguindo o passo original de Lee (2009).

A Figura 5.8 apresenta os valores de $\alpha_t(\lambda)$ espectral determinado: a) medido pelo AC-S, b) QAA_{v5} (LEE et al., 2009), , c) QAA_{v6} (LEE, 2014), d) QAA_{M14} (MISHRA et al., 2014), e) QAA_{BBHR} (WATANABE et al., 2016), f) QAA_{Turbid} (YANG et al., 2013), g) $QAA_{RDSM-LC}$ (JORGE, 2018), h) $QAA_{RDSM-LE}$ (JORGE, 2018) e i) QAA_{LGC} . Todas as versões do QAA testadas apresentaram baixíssimos valores de $\alpha_t(\lambda)$, subestimando os resultados em todo o espectro. Mesmo propostos para águas interiores, os modelos QAA_{M14} , QAA_{Turbid} e QAA_{BBHR} são compreendidos por águas com características bio-ópticas

distintas da área de estudo deste trabalho, sendo hipereutróficas com altas concentrações de fitoplâncton. Parametrizado para águas de lagos amazônicos, o QAA_{RDSM} apresentou ligeira melhora nos resultados, porém ainda subestimando os valores de $\alpha_t(\lambda)$ em todas as regiões do espectro. Como esperado, a versão parametrizada para as características da área de estudo QAA_{LGC} apresentou os melhores resultados para a estimativa de $\alpha_t(\lambda)$.

A parametrização de χ e η são considerada por Lee et al. (2002) como de baixa influência na estimativa de $\alpha_t(\lambda)$, porém, foram essenciais para aprimorar os resultados estimados pelo QAA_{LGC} .

Figura 5.8 - Espectro $\alpha_t(\lambda)$ determinado para cada modelo testado e a versão parametriza QAA_{LGC} .



a) medido pelo AC-S, b) QAA_{V5} (LEE et al., 2009), , c) QAA_{V6} (LEE, 2014), d) QAA_{M14} (MISHRA et al., 2014), e) QAA_{BBHR} (WATANABE et al., 2016), f) QAA_{Turbid} (YANG et al., 2013), g) $QAA_{RDSM-LC}$ (JORGE, 2018), h) $QAA_{RDSM-LE}$ (JORGE, 2018) e i) QAA_{LGC} .

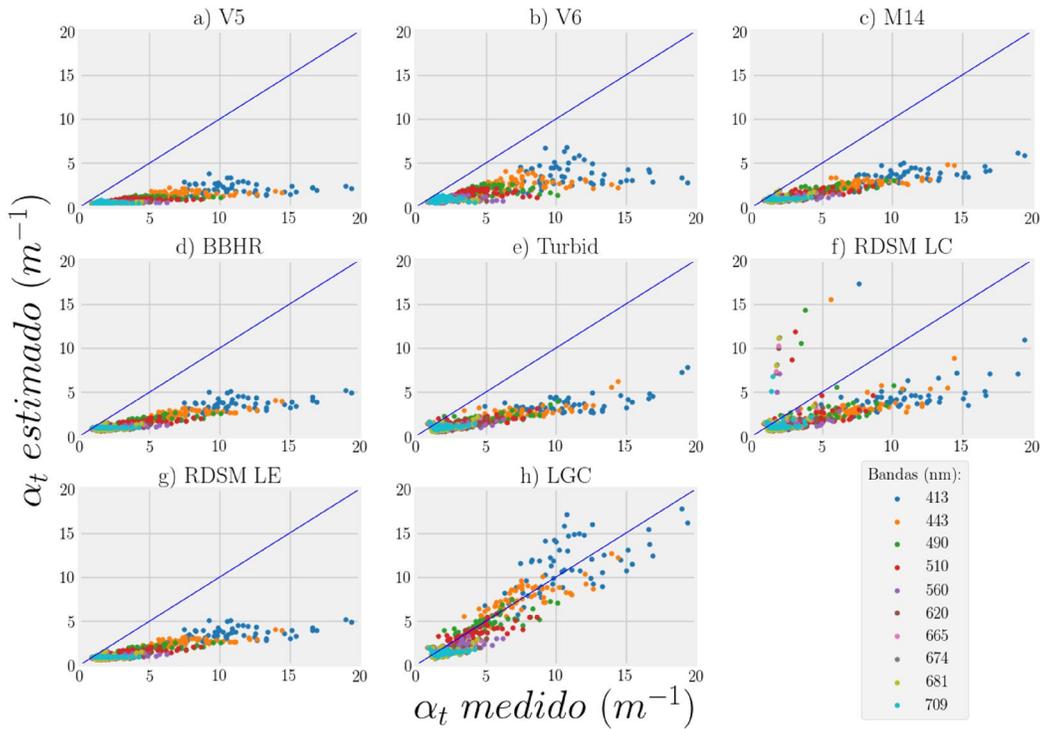
Fonte: Produção do Autor.

O QAA_{V5} apresentou os piores resultados de bias, com valor de $-9,44 \text{ m}^{-1}$ em 400 nm e crescendo para $-1,40 \text{ m}^{-1}$ em 709 nm. As outras versões testadas

apresentaram resultados muito similares, com bias de aproximadamente $-8,0 \text{ m}^{-1}$ no início do espectro e aumentando para cerca de $-1,0 \text{ m}^{-1}$ em 709 nm. A versão parametrizada QAA_{LGC} apresentou os melhores resultados de bias, variando de $-0,697 \text{ m}^{-1}$ em 560 nm e $1,099 \text{ m}^{-1}$ em 400 nm, e com média de $-0,223 \text{ m}^{-1}$. O QAA_{LGC} obteve bias positivo nas bandas de 400, 413 e 443 nm, e negativo no restante das bandas.

A Figura 5.9 apresenta a dispersão dos resultados de $\alpha_t(\lambda)$ estimados por cada algoritmo testado em comparação aos dados medidos, para 10 bandas do sensor OLCI (413, 443, 490, 510, 560, 620, 665, 674, 681 e 709 nm). Todos os algoritmos da literatura testados apresentaram o mesmo padrão, subestimando fortemente os valores de $\alpha_t(\lambda)$ em todas as bandas. O modelo QAA_{RDSM} para LC superestimou forte mente os valores de $\alpha_t(\lambda)$, nas estações Curuai09 e Curuai10, de 2017. As estimativas do QAA_{LGC} se mostraram próximas da linha 1:1, com uma maior dispersão das estimativas nos comprimentos e onda iniciais (413 e 443 nm) e se tornando mais linear ao longo do espectro. Ambas as versões do QAA desenvolvidas para águas oceânicas (QAA_{v5} e QAA_{v6}) apresentaram resultados ruins de R^2 com valores próximos a zero.

Figura 5.9 - Dispersão de $\alpha_t(\lambda)$ estimados em relação aos dados de campo.



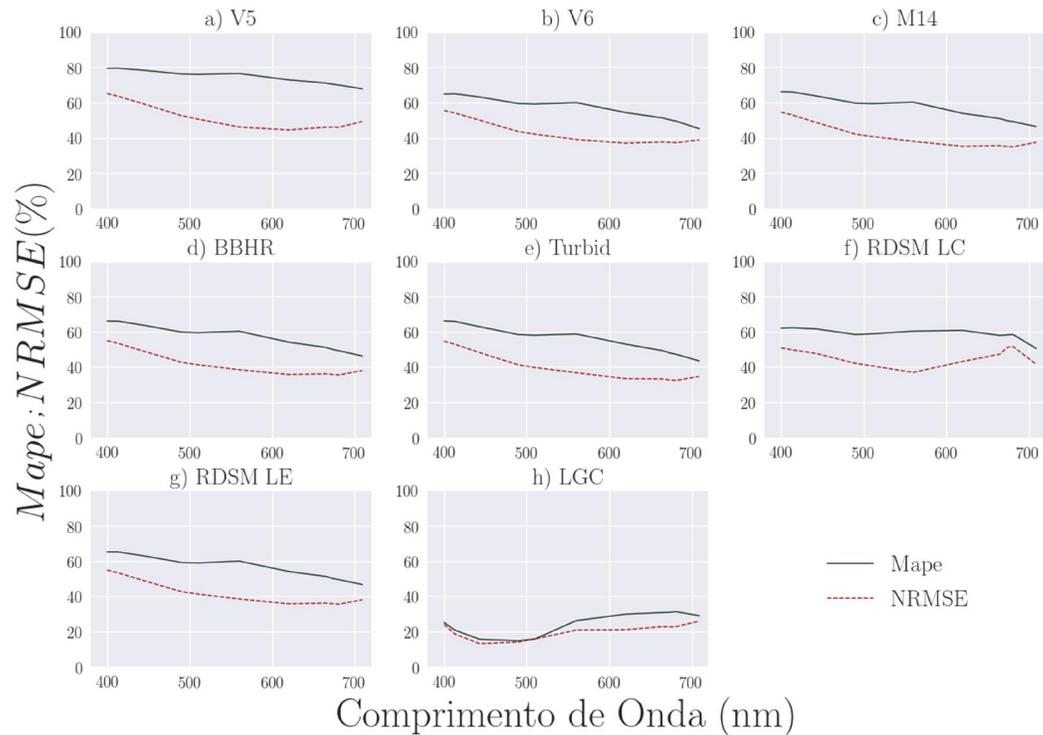
Fonte: Produção do Autor.

A Figura 5.10 apresenta os resultados espectrais de MAPE e NRMSE dos valores de $\alpha_t(\lambda)$ estimados em relação aos valores reais medidos. Todos os modelos testados obtiveram valores de MAPE acima de 45% para todo o espectro, com um padrão de decrescimento semelhante ao longo do espectro. Os piores resultados foram obtidos para o QAA_{V5} , com MAPE variando de 79,42% em 400 nm até 67,81% em 709 nm e uma média de 74,40%. Os modelos QAA_{V6} , QAA_{M14} , QAA_{BBHR} , QAA_{Turbid} e $QAA_{RDSM-LE}$ se assemelham na forma da curva espectral, com MAPE acima de ~60% até 490 nm, um platô entre 490 e 560 nm (MAPE~60%) e por fim uma redução linear até 709 nm. Com exceção do QAA_{V5} com MAPE médio de 74,37%, os outros modelos da literatura obtiveram valores médios entre 55% e 59%. A parametrização do QAA_{LGC} obteve valores de MAPE de 1,5 a 3 vezes menor que os modelos da literatura, com mínimo de 14,78% (490 nm), máximo de 31,28% (681nm) e média de 24,54%. O QAA_{LGC} obteve um melhor desempenho na faixa espectral entre 413 e 560 nm (16,73%) e pior entre 560 e 709 nm (29,66%). Os

resultados inferiores nas bandas de 620 (29,83%), 665 (30,77%), 674 nm (30,93%) podem indicar problemas para águas dominadas por cianobactérias e altamente produtivas, porém, não representam um grande problemas para águas oligotróficas (RODRIGUES, 2017).

Em relação ao NRSME, com exceção do $QAA_{RDSM-LC}$, todo os outros modelos da literatura obtiveram resultados muito semelhantes, variando de aproximadamente 55% para 400 nm até ~36% em 709 nm. O QAA_{V5} obteve o mesmo padrão, porém com um aumento de 10% em relação aos outros modelos. $QAA_{RDSM-LE}$ obteve seus menores valores de NRMSE entre 560 e 790 nm (~35% até ~39%). No QAA_{LGC} a média de NRMSE foi de 20,13%, com os menores valores entre 413 e 510 nm (<18%). Os piores resultados foram para as bandas de 400 e 709 nm com 23,93% e 25,89%, respectivamente.

Figura 5.10 - Resultados de MAPE e NRMSE para $\alpha_t(\lambda)$ estimado em relação aos dados de campo.



Fonte: Produção do Autor.

5.3.4 Etapa 2 – Separação de $\alpha_{\text{CDM}}(\lambda)$ e $\alpha_{\phi}(\lambda)$

A decomposição do $\alpha_t(\lambda)$ nas absorções dos componentes $\alpha_{\text{CDM}}(\lambda)$ e $\alpha_{\phi}(\lambda)$ depende diretamente de uma boa estimativa de $\alpha_t(\lambda)$, juntamente com uma precisa modelagem da influência do fitoplâncton e do CDM, com parametrização e calibração dos fatores ζ e ξ (LEE et al., 2002; MISHRA et al., 2014). Segundo Lee et al. (2002), o fator ζ deve estar associado à concentração de Chl-a ou absorção de pigmentos, e pode ser estimado para águas do Caso 1 pela razão de bandas da $R_{rs}(\lambda)$ no verde/azul (443/560 nm). Devido à presença de CDOM e materiais em suspensão, orgânicos e inorgânicos, nas águas interiores a estimativa de ζ ainda é pouco explorada (CARDER et al., 1999; YANG et al., 2013). Levando em consideração estes condicionantes, a parametrização do ζ do QAA_{LGC} foi determinada pela razão de banda em 665 e 764 nm (Equação 5.26).

$$\zeta = 0,5 + \frac{0,1}{0,15 + r_{rs}(665)/r_{rs}(764)} \quad (5.26)$$

O parâmetro ξ é definido pela razão entre $\alpha_{\text{CDM}}(413) / \alpha_{\text{CDM}}(443)$ juntamente com o fator S, que está relacionado com pigmentos, detritos e material orgânico (LEE et al., 2002). Utilizando como base a equação proposta por (LEE et al., 2009) para a modelagem de S, modificações nos coeficientes e bandas foram testados, e sua formulação final é apresentada na Equação 5.27. Para determinar os parâmetros ζ e ξ definidos, a parametrização seguiu os passos originais do QAA_{v5}. Para determinar $\alpha_{\text{CDM}}(443)$, $\alpha_{\text{CDM}}(\lambda)$ e por fim extrair $\alpha_{\phi}(\lambda)$ matematicamente, foram mantidos as proposições do QAA_{v5} nos passos subsequentes à determinação de ζ e ξ .

$$S = 0,009 + \frac{0,003}{0,15 + r_{rs}(754)/r_{rs}(674)} \quad (5.27)$$

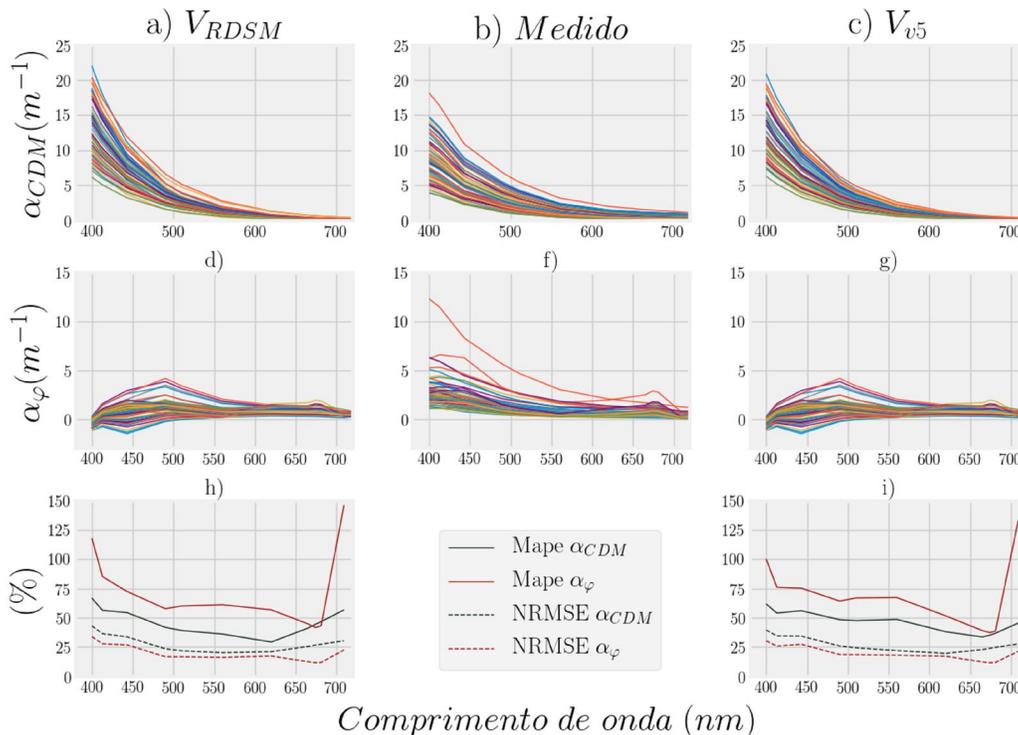
$$\xi = \frac{\alpha_{CDM}(413)}{\alpha_{CDM}(443)} = e^{S(443-413)}$$

Buscando avaliar a modificação proposta por Jorge (2018) no QAA_{RDSM} para a determinação do $\alpha_{CDM}(\lambda)$, os resultados obtidos para $\alpha_t(\lambda)$ derivado pelo QAA_{LGC} foram aplicados na parametrização proposta para o QAA_{RDSM} . Seguindo as premissas do autor, apenas o fator S foi parametrizado e utilizado para determinar o decaimento da absorção por CDM diretamente de $\alpha_t(\lambda)$ (Equação 5.28).

$$S = 0,01 + \frac{0,003}{0,2 + r_{rs}(754)/r_{rs}(510)} \quad (5.28)$$

A seguir são apresentados os resultados (Figura 5.11) comparativos entre a parametrização seguindo a versão original do QAA (V_{v5}) e a versão proposta para o QAA_{RDSM} (V_{RDSM}). As duas formulações apresentaram resultados similares para a derivação do $\alpha_{CDM}(\lambda)$ e $\alpha_\phi(\lambda)$ com valores médios de MAPE e NRMSE levemente menores para V_{RDSM} .

Figura 5.11 – Frações $\alpha_{CDM}(\lambda)$ e $\alpha_{\varphi}(\lambda)$ estimadas pelas parametrizações a) V_{RDSM} , b) dados laboratoriais medidos e c) V_{v5} .



Fonte: Produção do Autor.

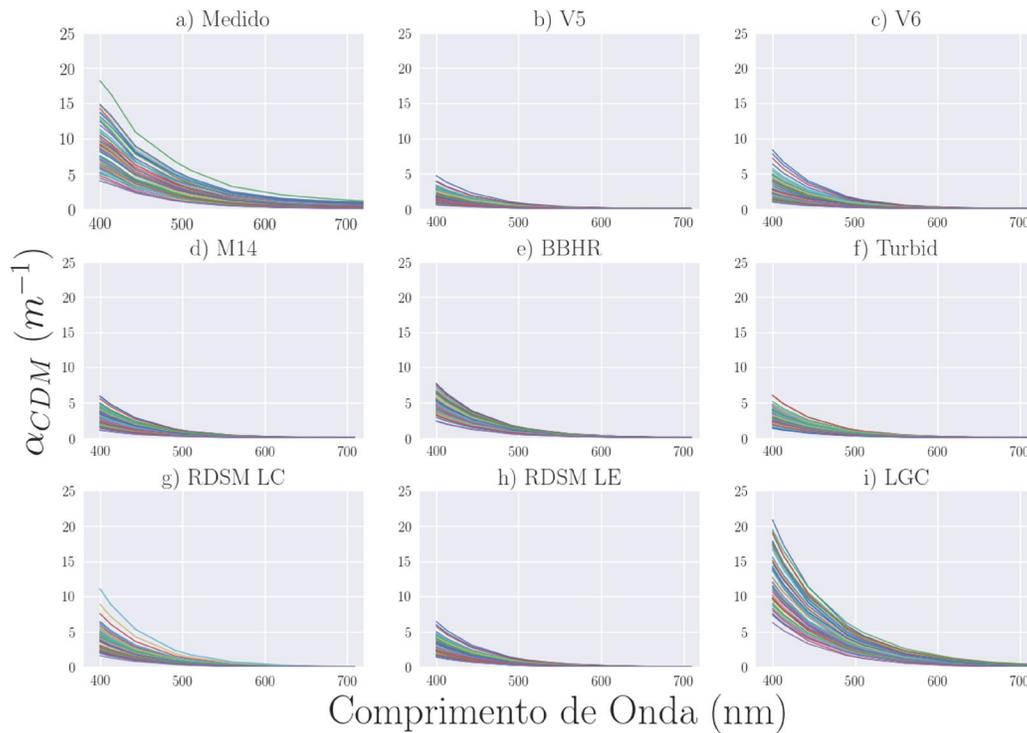
Avaliando os resultados de V_{RDSM} e V_{v5} e buscando um embasamento teórico mais preciso para a parametrização do QAA_{LGC} , a versão V_{RDSM} (QAA_{RDSM}) foi assimilada na versão final do QAA_{LGC} . Portanto, deste ponto em diante a parametrização de $\alpha_{CDM}(\lambda)$ e $\alpha_{\varphi}(\lambda)$ seguindo o QAA_{v5} foi descartada.

5.3.4.1 Estimativa de $\alpha_{CDM}(\lambda)$

A Figura 5.12 apresenta os valores de $\alpha_{CDM}(\lambda)$ espectral determinado: a) medido em laboratório, b) QAA_{v5} (LEE et al., 2009), c) QAA_{v6} (LEE, 2014), d) QAA_{M14} (MISHRA et al., 2014), e) QAA_{BBHR} (WATANABE et al., 2016), f) QAA_{Turbid} (YANG et al., 2013), g) $QAA_{RDSM-LC}$ (JORGE, 2018), h) $QAA_{RDSM-LE}$ (JORGE, 2018) e i) QAA_{LGC} . Nenhuma das versões testadas foram capazes de estimar $\alpha_{CDM}(\lambda)$ com precisão, subestimando as estimativas em todo o espectro. O QAA_{v6} apresentou resultados ligeiramente melhores que o QAA_{v5} ,

porém, estas versões desenvolvidas para águas oceânicas não obtiveram desempenho satisfatório. As absorções estimadas foram menores que $7,5 \text{ m}^{-1}$ em 400 nm para todos os modelos da literatura, enquanto os valores reais variam entre 3,9 a $18,15 \text{ m}^{-1}$ nesta mesma banda. Os valores de bias dos modelos testados variam de aproximadamente $-7,0$ até $-4,0 \text{ m}^{-1}$ em 400 nm, e decaem ao longo do espectro ainda negativos. A parametrização do QAA_{LGC} se mostrou efetiva para a determinação do $\alpha_{CDM}(\lambda)$, entretanto, o algoritmo tendeu a superestimar as bandas iniciais de 400, 413 e 490 nm com valores de bias de 3,95, 2,79 e $1,89 \text{ m}^{-1}$, respectivamente. A partir de 620 até 709 nm, o QAA_{LGC} passa a subestimar os valores, com bias próximo de $-0,2 \text{ m}^{-1}$. A superestimação do fator S pelos modelos da literatura pode ser apontado como a principal fonte de erros na estimativa de $\alpha_{CDM}(\lambda)$. Estudos mostraram que S pode variar de 0,01 a 0,02, portanto, a maioria dos modelos adota o valor médio de $S=0,015$ (BABIN et al., 2003). Os modelos aplicados ao conjunto de dados LGC obtiveram valores variando de 0,0159 (QAA_{BBHR}) e 0,0169 (QAA_{v5}), coincidindo com o melhor e pior desempenho, respectivamente. Em relação ao QAA_{LGC} , os valores foram em média de 0,014, com máximo de 0,0164 e mínimo de 0,0125. Os modelos testados subestimaram os valores $\alpha_{CDM}(\lambda)$, porém, não acarretaram em valores negativos como observados em modelos da literatura avaliados em outros estudos (MISHRA et al., 2014; WATANABE et al., 2016).

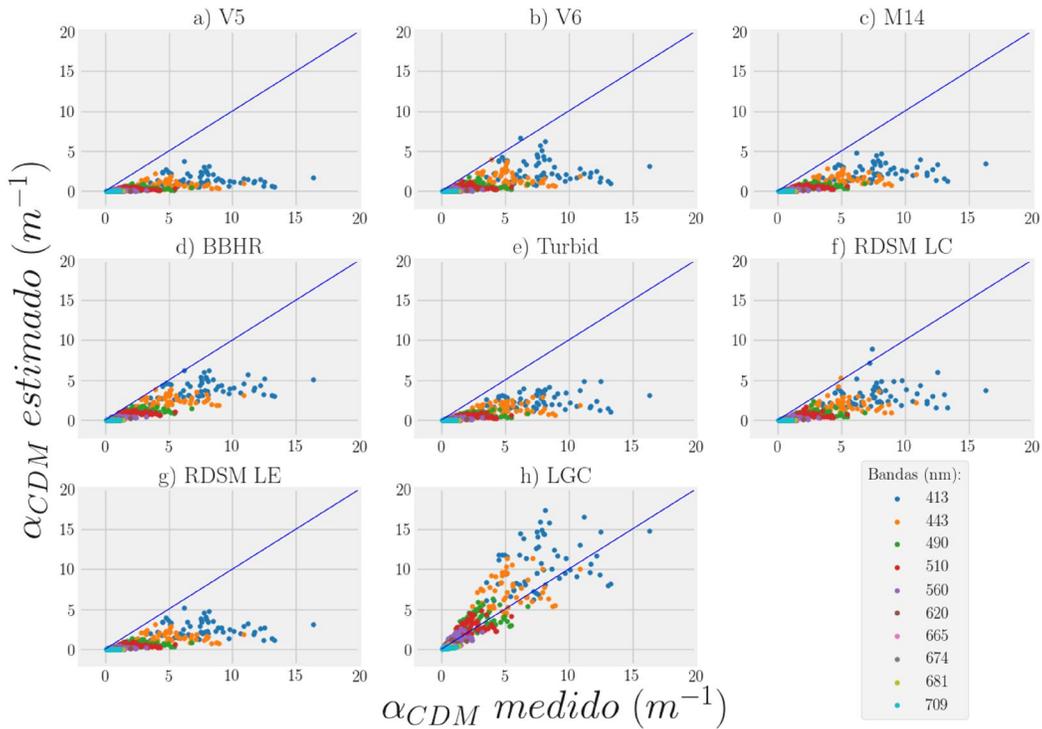
Figura 5.12 - Espectro $\alpha_{CDM}(\lambda)$ determinado para cada modelo testado e a versão parametriza QAA_{LGC}.



Fonte: Produção do Autor.

A Figura 5.13 apresenta a dispersão dos resultados de $\alpha_{CDM}(\lambda)$ estimados por cada algoritmo testado em comparação aos dados medidos, para 10 bandas do sensor OLCI (413, 443, 490, 510, 560, 620, 665, 674, 681 e 709 nm). Os modelos da literatura apresentaram resultados de R^2 próximos de zero em todas as bandas, por sua vez o QAA_{LGC} apresentou uma variação de 0,07 em 400 nm até 0,26 em 754 nm. As bandas e os coeficientes calibrados para o fator S no QAA_{LGC} melhoraram as estimativas de $\alpha_{CDM}(\lambda)$, mesmo sem a utilização do fator ξ , para a remoção da influência do fitoplâncton.

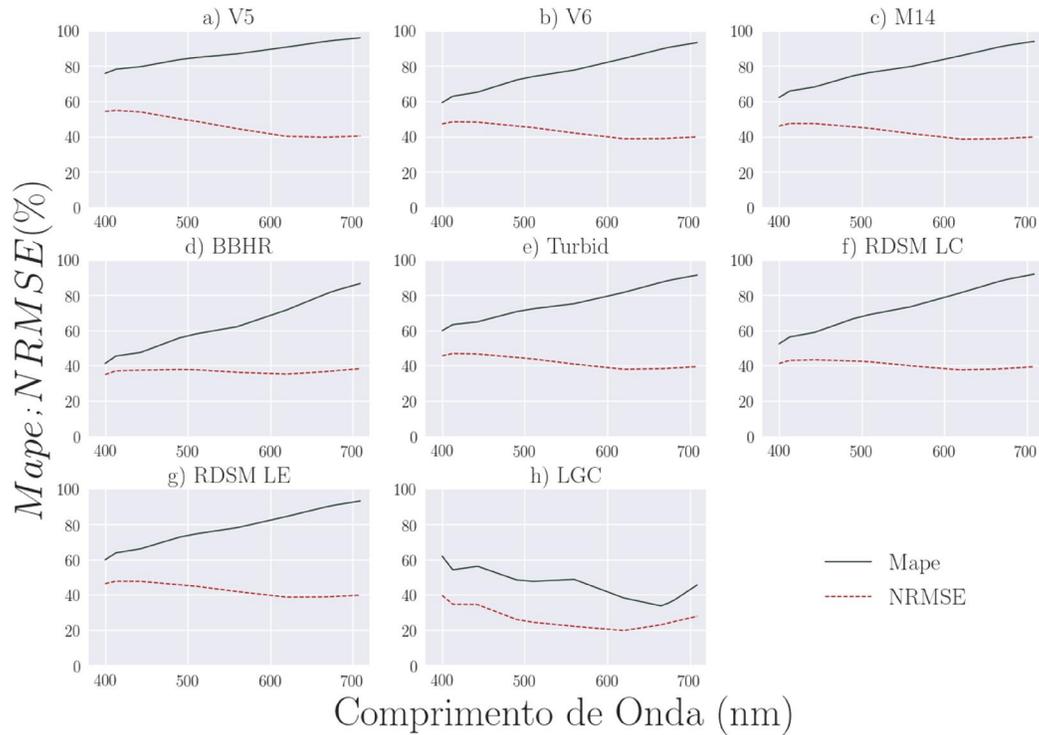
Figura 5.13 - Dispersão de $\alpha_{CDM}(\lambda)$ estimados em relação aos dados de campo.



Fonte: Produção do Autor.

A Figura 5.14 apresenta os resultados espectrais de MAPE e NRMSE dos valores de $\alpha_{CDM}(\lambda)$ estimados em relação os valores reais medidos. Dentre os modelos da literatura testados, o QAA_{BBHR} apresentou a melhor média de MAPE com 66,98% e NRMSE de 37%, o restante dos algoritmos obtiveram valores de MAPE acima de 75% e NRMSE acima de 40%, sendo o QAA_{V5} o pior modelo (MAPE=87,98% e NRMSE=45%). As estatísticas (MAPE e NRSME) obtiveram o mesmo comportamento para todos os modelos testados, com valores de MAPE menores para 400 nm e crescente até 709 nm e NRMSE contínuo em todo espectro próximo de 40%. O QAA_{LGC} foi capaz de derivar os valores de $\alpha_{CDM}(\lambda)$ com boa precisão, obtendo valores médios de MAPE de 47,15% e NRMSE de 27,60%, as bandas em 620, 665, 674 e 681 nm obtiveram os melhores desempenhos, com MAPE próximo de 35% e NRMSE próxima a 23%. As bandas iniciais (400, 413 e 443 nm) do QAA_{LGC} obtiveram os piores desempenhos com MAPE e NRMSE acima de 55% e 35%, respectivamente.

Figura 5.14 - Resultados de MAPE e NRMSE para $\alpha_{CDM}(\lambda)$ estimado em relação aos dados de campo.



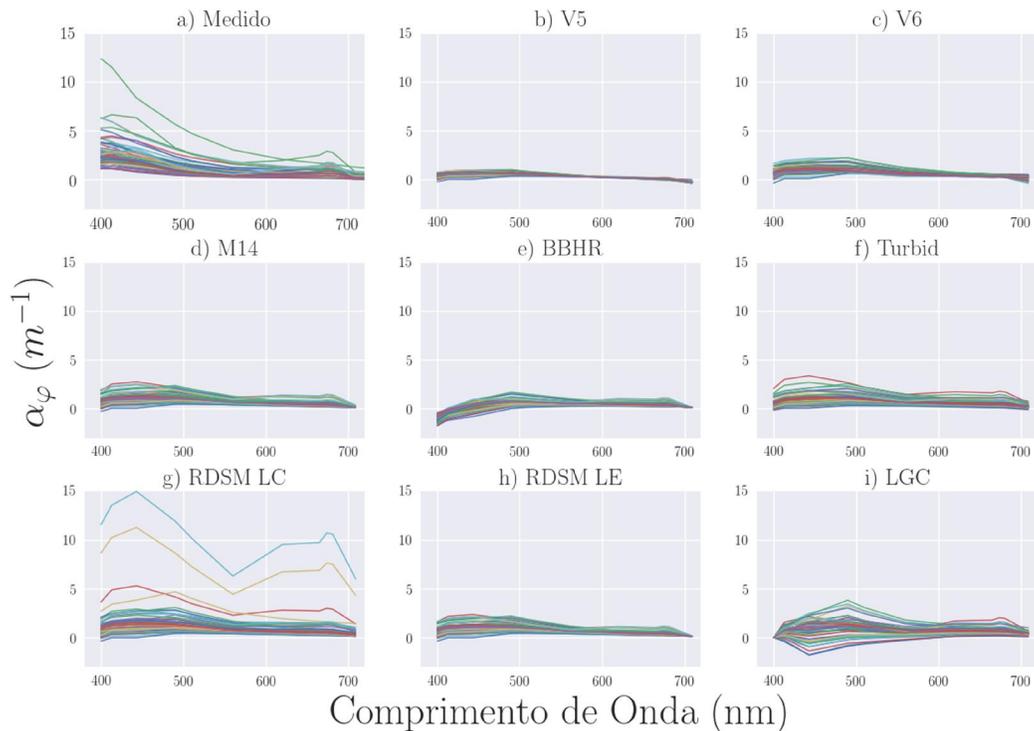
Fonte: Produção do Autor.

5.3.4.2 Estimativa de $\alpha_{\varphi}(\lambda)$

A Figura 5.15 apresenta os valores $\alpha_{\varphi}(\lambda)$ espectral determinado: a) medido, b) QAA_{V5} (LEE et al., 2009), c) QAA_{V6} (LEE, 2014), d) QAA_{M14} (MISHRA et al., 2014), e) QAA_{BBHR} (WATANABE et al., 2016), f) QAA_{Turbid} (YANG et al., 2013), g) $QAA_{RDSM-LC}$ (JORGE, 2018), h) $QAA_{RDSM-LE}$ (JORGE, 2018) e i) QAA_{LGC} . Em consequência da dedução matemática de $\alpha_{\varphi}(\lambda)$ de $\alpha_t(\lambda)$ e $\alpha_{CDM}(\lambda)$, erros nas duas últimas estimativas podem acarretar grandes variações nos valores de $\alpha_{\varphi}(\lambda)$, produzindo até mesmo valores negativos (MISHRA et al., 2014). Todos os modelos apresentaram pontos com a estimativa de $\alpha_{\varphi}(\lambda)$ negativo, entretanto o QAA_{BBHR} obteve valores negativos para grande parte dos pontos até 490 nm. O QAA_{V5} apresentou o pior resultado, com valores de absorção menores que $0,79 \text{ m}^{-1}$ em todo o espectro, e média de $-0,24 \text{ m}^{-1}$ em 709 nm. As versões QAA_{M14} , $QAA_{RDSM-LE}$, QAA_{Turbid} e QAA_{V6} demonstraram uma melhor estimativa da magnitude de $\alpha_{\varphi}(\lambda)$, principalmente até 550 nm, porém ainda

subestimando os valores. Em dois pontos amostrais (Curuai09 e Curuai10 de 2017) os valores estimados pelo $QAA_{RDSM-LC}$ foram espúrios, acima de 5 m^{-1} . Com a subestimação de $\alpha_t(\lambda)$ e a superestimação de $\alpha_{CDM}(\lambda)$ os valores de $\alpha_\varphi(\lambda)$ tenderam ao negativo com maior intensidade que os outros modelos da literatura.

Figura 5.15 - Espectro $\alpha_\varphi(\lambda)$ determinado para cada modelo testado e a versão parametriza QAA_{LGC} .

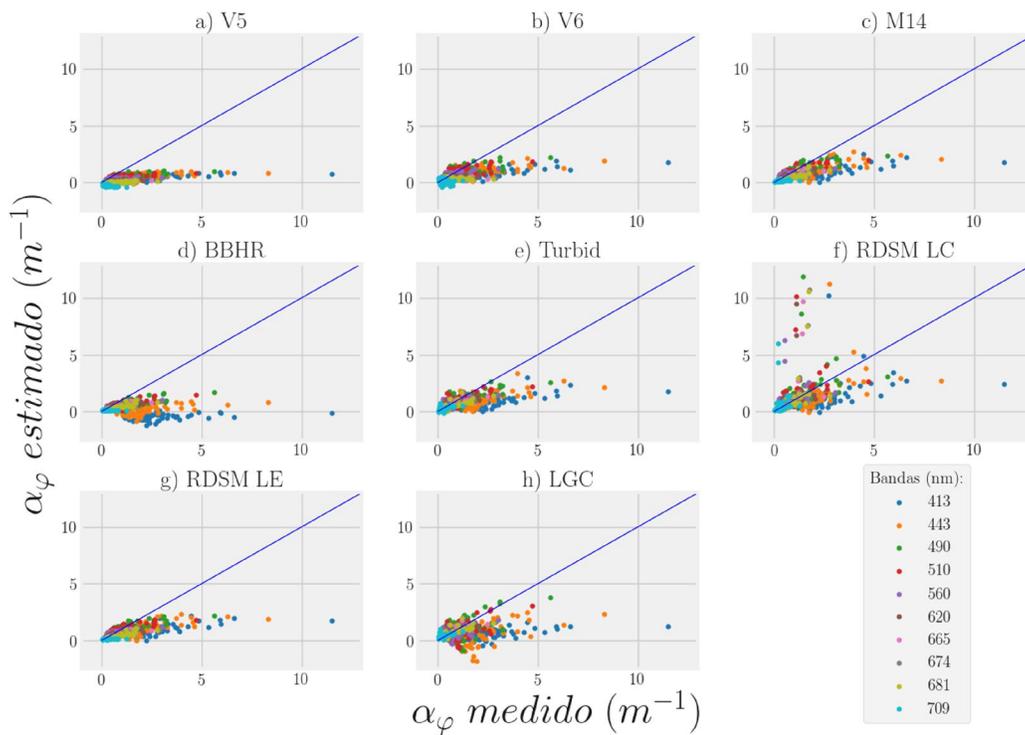


Fonte: Produção do Autor.

A Figura 5.16 apresenta a dispersão dos resultados de $\alpha_\varphi(\lambda)$ estimados por cada algoritmo testado em comparação aos dados medidos, para 10 bandas do sensor OLCI (413, 443, 490, 510, 560, 620, 665, 674, 681 e 709 nm). Com exceção do $QAA_{RDSM-LC}$, todos os outros modelos testados obtiveram valores de bias negativo ao longo de todo o espectro. Os maiores erros no bias foram em 400 nm, variando de $-1,73$ ($QAA_{RDSM-LC}$) até $-3,98 \text{ m}^{-1}$ (QAA_{BBHR}). Todos os modelos obtiveram valores de bias entre $-0,5$ e $0,5 \text{ m}^{-1}$ a partir de 510 nm. Os valores de bias para o QAA_{LGC} subestimaram fortemente nas bandas de 400 (-

2,935 m^{-1}), 413 (-2,217 m^{-1}) e 443 nm (-1,634 m^{-1}), devido a superestimação dos valores de $\alpha_{CDM}(\lambda)$ no passo anterior. A partir de 560 nm, o QAA_{LGC} passa a superestimar os valores, com bias variando de 0,011 m^{-1} (665 nm) até 0,29 m^{-1} (754 nm). Os valores mais baixos de bias, aproximadamente zero, foram encontrados nas bandas de 620, 665, 674 e 681 nm, relacionadas com a presença de ficocianina, Chl-a, e fluorescência da Chl-a, respectivamente.

Figura 5.16 - Dispersão de $\alpha_{\varphi}(\lambda)$ estimados em relação aos dados de campo.

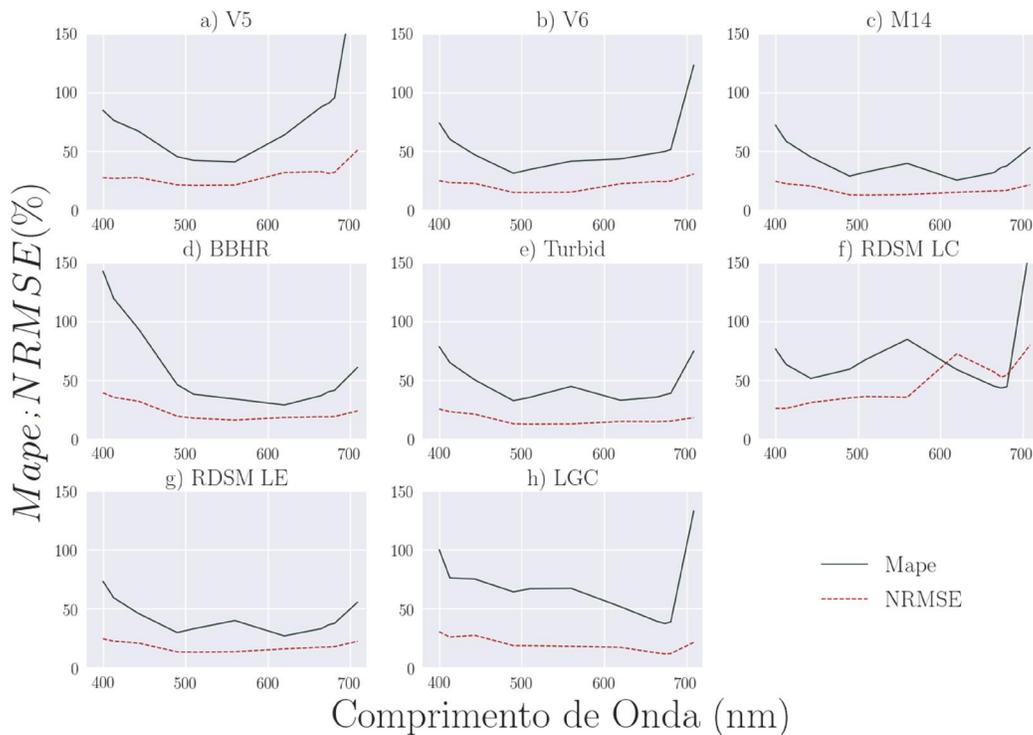


Fonte: Produção do Autor.

A Figura 5.17 apresenta os resultados espectrais de MAPE e NRMSE dos valores de $\alpha_{\varphi}(\lambda)$ estimados em relação aos valores reais medidos. O modelo da literatura com maior valor médio de MAPE (82,09%) e NRMSE (29,16%) foi o QAA_{V5} , seguido do $QAA_{RDSM-LC}$ com 68,84% de MAPE e NRMSE de 45,64%. Os modelos QAA_{M14} e QAA_{Turbid} apresentaram os menores resultados de MAPE com 41,59% e 47,52%, e NRMSE de 17,12% e 17,96%, respectivamente. Em relação ao QAA_{LGC} , os valores de MAPE e NRMSE

médios foram de 68,25% e 19,36%, respectivamente. Seus valores mínimos foram para a banda de 674 nm, com MAPE de 37,43% e NRSME de 11,59% e seu valores máximos foram para a banda de 709 nm com 133% de MAPE e 21,39 de NRMSE. A banda em 400 nm também obteve um desempenho ruim no QAA_{LGC}, com MAPE de 100% e NRMSE de 30,32%. Resultados satisfatórios foram obtidos para a banda de absorção da Chl-a (665 nm) com 39,03% de MAPE e 12,26% de NRMSE. Todos os modelos testados, incluindo o QAA_{LGC}, obtiveram os resultados menos satisfatórios de MAPE e NRMSE para as bandas de 400 e 709 nm, podendo ser atribuído à má remoção da influência do material particulado.

Figura 5.17 - Resultados de MAPE e NRMSE para $\alpha_p(\lambda)$ estimado em relação aos dados de campo.

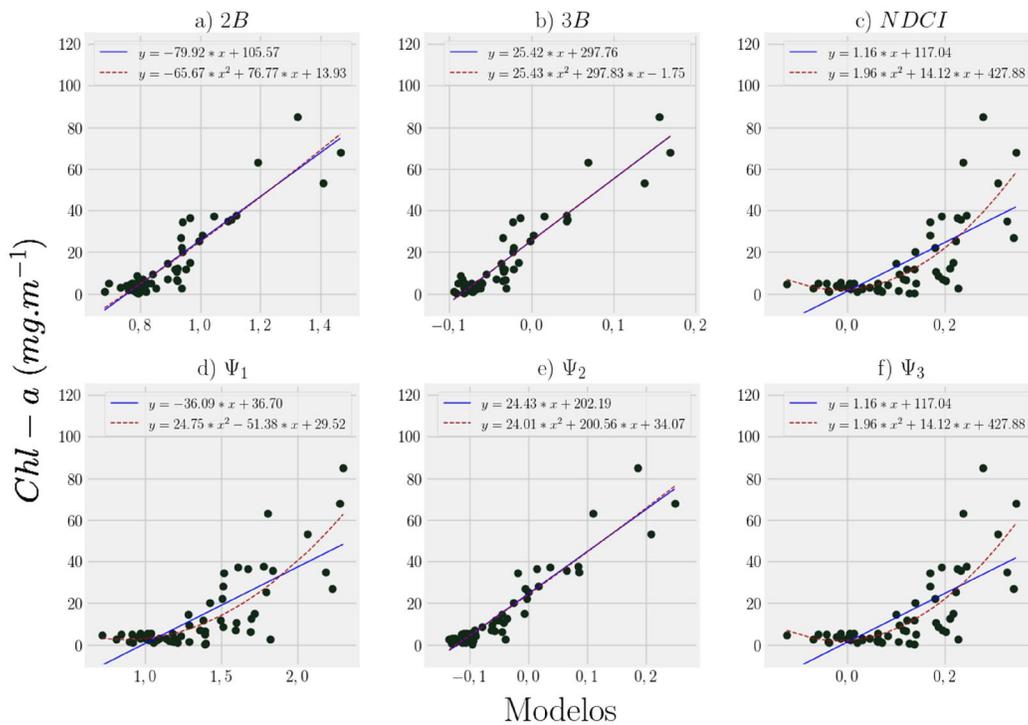


Fonte: Produção do Autor.

5.3.5 Concentração de Chl-a utilizando as IOPs do QAA_{LGC}

Buscando avaliar e validar as IOPs derivadas pelo QAA_{LGC}, algoritmos empíricos para a estimativa de Chl-a foram aplicados nos dados de $R_{rs}(\lambda)$ simulados e também nos índices em função das IOPs ($\alpha_\phi(\lambda)$, $\alpha_w(\lambda)$ e $\alpha_{CDM}(\lambda)$) derivadas. Foram testados os algoritmos 2B, 3B (GITELSON et al., 2008) e NDCI (MISHRA; MISHRA, 2012), e seus respectivos índices ψ_1 , ψ_2 e ψ_3 . A Figura 5.18 exibe os ajustes lineares e quadráticos para cada algoritmo e índice testado. As estimativas obtidas pelos algoritmos ajustados aos dados de $R_{rs}(\lambda)$ apresentaram altas correlações com a concentração de Chl-a, com R^2 de 0,82 para 2B, 0,95 para 3B e 0,78 para o NDCI. Os algoritmos empíricos em função das IOPs resultaram em valores de R^2 de 0,91 para ψ_1 , 0,94 para ψ_2 e 0,92 para ψ_3 .

Figura 5.18 - Gráfico de dispersão mostrando os ajustes entre a concentração de Chl-a e os índices empíricos aplicados a $R_{rs}(\lambda)$ (a, b e c) e suas derivações aplicadas às IOPs (d, e, f).



Fonte: Produção do Autor.

Para avaliar e validar o desempenho dos algoritmos empíricos ajustados, foi realizada uma simulação MC com 20 mil interações, com a seleção aleatória das 58 amostras, divididas entre treinamento e teste, nas proporções 70% e 30% respectivamente. Os valores modais das estatísticas MAPE, NRMSE e R^2 foram utilizados para avaliar as estimativas da concentração de Chl-a pelos algoritmos. A Tabela 5.5 apresenta os resultados de validação dos algoritmos testados.

Tabela 5.5 - Validação dos modelos para estimativa de Chl-a utilizando simulações Monte Carlo.

Algoritmo	Calibrados com a $R_{rs}(\lambda)$ (n=17)						Calibrados com IOPs (n=17)					
	2B	2B	3B	3B	NDCI	NDCI	ψ_1	ψ_1	ψ_2	ψ_2	ψ_3	ψ_3
Ajuste	Lin	Quad	Lin	Quad	Lin	Quad	Lin	Quad	Lin	Quad	Lin	Quad
R^2	0,86	0,83	0,85	0,80	0,86	0,74	0,42	0,67	0,95	0,88	0,64	0,66
NRMSE (%)	11,79	10,38	11,22	17,26	12,26	20,05	22,89	23,22	16,04	13,19	17,09	25,42
MAPE (%)	90,65	118,97	59,09	56,34	140,37	96,61	126,09	75,52	50,91	37,73	122,71	78,37
Bias ($\text{mg}\cdot\text{m}^{-3}$)	-2,44	0,15	0,06	1,54	-1,30	0,43	2,25	-3,69	-5,99	1,24	-2,66	-7,06

Fonte: Produção do Autor.

Os resultados da simulação de Monte Carlo mostraram valores de R^2 máximo de 0,95 (ψ_2) e MAPE de 50,91%. O algoritmo com melhor desempenho foi o de 3B bandas com ajuste quadrático, com MAPE de 56,34% e R^2 de 0,80 para os dados de $R_{rs}(\lambda)$ e para seu respectivo índice (ψ_2) MAPE de 37,73 e R^2 de 0,88. O índice ψ_2 linear apresentou uma forte subestimação dos valores (bias=-5,99 $\text{mg}\cdot\text{m}^{-3}$), enquanto sua versão quadrática apresentou superestimação, porém menor (bias = 1,24 $\text{mg}\cdot\text{m}^{-3}$). Os índices baseados nos algoritmos de 3B (ψ_2) e NDCI (ψ_3) obtiveram resultados melhores em comparação com suas versões calibradas com os dados de $R_{rs}(\lambda)$, com uma redução no MAPE de aproximadamente 20%. Com os resultados obtidos para a simulação de MC foi

possível observar a eficácia das IOPs do QAA em estimar a concentração de Chl-a nas campanhas testadas.

Com o intuito de avaliar a possibilidade de aplicação do QAA_{LGC} em condições diferentes, o algoritmo foi aplicado na campanha de março de 2016 para a estimativa das IOPs que foram então aplicadas nos algoritmos empíricos. A Tabela 5.6 apresenta os resultados obtidos para a validação dos modelos empíricos, por meio das estatísticas R^2 , MAPE, NRMSE e bias.

Tabela 5.6 - Validação dos modelos para estimativa de Chl-a utilizando o conjunto de dados independentes de março 2016.

Algoritmo	Calibrados com a $R_{rs}(\lambda)$ (n=15)						Calibrados com IOPs (n=15)					
	2B	2B	3B	3B	NDCI	NDCI	Ψ_1	Ψ_1	Ψ_2	Ψ_2	Ψ_3	Ψ_3
Ajuste	Lin	Quad	Lin	Quad	Lin	Quad	Lin	Quad	Lin	Quad	Lin	Quad
R^2	0,09	0,09	0,10	0,10	0,14	0,13	0,04	0,04	0,29	0,29	0,04	0,04
NRMSE (%)	38,53	45,75	31,48	31,47	30,06	34,57	30,06	30,95	31,47	28,74	30,77	30,06
MAPE (%)	73,30	73,39	38,03	38,04	56,54	55,45	45,12	43,82	27,61	27,74	50,00	42,44
Bias (mg.m^{-3})	-8,05	-8,28	5,37	5,37	-4,42	-4,90	2,83	3,36	6,78	7,06	1,02	4,10

Fonte: Produção do Autor.

Ainda que os algoritmos empíricos, aplicados nos dados de março de 2016, não tenham apresentado desempenho muito satisfatório, é possível observar que os índices utilizando as IOPs derivadas do QAA_{LGC} melhoraram as estimativas em relação aos modelos calibrados com a $R_{rs}(\lambda)$. O algoritmo de 3 bandas (3B) e seu respectivo índice produziram os melhores resultados MAPE de aproximadamente 38% e 27%, respectivamente, indicando que algoritmos analíticos são mais promissores do que os empíricos, embora os desafios ainda sejam grandes. A maior diferença de MAPE foi observada no algoritmo 2B, com a redução do valor de aproximadamente 73% (2B) para próximo de 44% (Ψ_1). A campanha de campo utilizada para esta validação encontra-se em um período hidrológico distinto do conjunto de dados utilizados para calibrar

QAA_{LGC} , possuindo concentrações de TSS muito elevadas, o que pode justificar a pouca correlação de α_φ com a concentração de Chl-a.

5.4 Conclusão

O algoritmo QAA_{LGC} parametrizado para águas interiores túrbidas de lagos da planície de inundação do baixo amazonas obteve resultados satisfatórios na estimativa de $\alpha_t(\lambda)$, $\alpha_{CDM}(\lambda)$ e $\alpha_\varphi(\lambda)$. As principais versões do QAA presentes na literatura, tanto para águas costeiras e oceânicas (QAA_{v5} e QAA_{v6}) quanto para águas interiores (QAA_{M14} , QAA_{BBHR} , QAA_{Turbid} e QAA_{RDSM}), não foram capazes de derivar as propriedades inerentes dos dados da área de estudo. A necessidade de calibração e reparametrização, mostrou-se indispensável com os resultados obtidos pelos modelos da literatura. A parametrização das relações empíricas e sua calibração foram de grande importância para o aperfeiçoamento de cada etapa entorno das estimativas de $\alpha_t(\lambda)$, $\alpha_{CDM}(\lambda)$ e $\alpha_\varphi(\lambda)$, mesmo que consideradas de segunda ordem de impacto (LEE et al., 2002).

Como demonstrado com os modelos testados (Figura 5.7) e também com QAA_{LGC} desenvolvido, a escolha do λ_0 tem alta influência sobre o restante do desenvolvimento do algoritmo. Devido às águas altamente túrbidas da área de estudo o λ_0 precisou ser deslocado para comprimentos de onda maiores, buscando amparar a premissa inicial do QAA ($\alpha_t(\lambda_0) = \alpha_w(\lambda_0)$). A definição do λ_0 em 754 nm para o QAA_{LGC} justificou-se devido as altas cargas de CDOM e materiais em suspensão na área de estudo.

Na parametrização da equação para estimação de χ nota-se a importância da escolha das bandas espectrais mais representativas para as condições do ambiente. A escolha das bandas do QAA_{LGC} em 400, 413, 490 e 674 nm possibilitou estimativas mais precisas de $\alpha_t(\lambda)$. As bandas 400, 413 e 490 nm buscam compensar os efeitos devido à alta influência de CDOM e material particulado em todo o espectro. Mesmo com baixa concentração de Chl-a em todo o conjunto de dados, a banda em 674 nm foi selecionada com o intuito de reduzir os efeitos do pico de absorção da Chl-a em 665 nm. Com os

coeficientes h_0 , h_1 e h_2 propostos por Lee et al. (2009), foi possível evitar a calibração desta etapa com dados de campo, o que viabiliza a aplicação do QAA_{LGC} em outros dados, visto que necessita apenas da $R_{rs}(\lambda)$.

Na segunda etapa do QAA_{LGC} , a calibração e parametrização dos coeficientes ζ e ξ se mostraram necessárias para boas estimativas de $\alpha_{CDM}(\lambda)$ e $\alpha_{\phi}(\lambda)$. Porém, as relações empíricas propostas nestas etapas ainda não são claras para águas interiores altamente turbidas, gerando assim incerteza. Portanto, a proposição de $\alpha_w(400) = \alpha_{CDM}(400)$ buscou reduzir as incertezas relacionadas com a baixa influência da Chl-a nos dados de LCG.

A avaliação das IOPs estimadas pelo QAA_{LGC} por meio de algoritmos empíricos corroborou com a possibilidade da estimativa de Chl-a por meio do $\alpha_{CDM}(\lambda)$ e $\alpha_{\phi}(\lambda)$. Os índices gerados a partir das IOPs obtiveram resultados acima de 0,90 para R^2 , porém a validação utilizando simulação Monte Carlo obteve resultados satisfatórios apenas para o modelo de 3B. Embora, outras versões do QAA tenham estimado $\alpha_{\phi}(\lambda)$ mais acuradamente, os resultados estimados pelo QAA_{LGC} produziu resultados satisfatórios para estimar Chl-a, visto as limitações do ambiente de estudo.

A parametrização do algoritmo QAA_{LGC} pode apresentar uma alternativa para o monitoramento dos COAs em ambientes altamente turbidos. Levando em consideração a necessidade apenas de dados de $R_{rs}(\lambda)$ para sua aplicação, o QAA_{LGC} pode ser adotado para o monitoramento periódico por meio de imagens de satélite. Neste sentido o sensor OLCI/Sentinel-3, tem grande potencial devido à sua alta resolução temporal e cobertura (FOV). Como opção de sensor de média resolução espacial para trabalhos futuros, o MSI/Sentinel-2, mostra-se possível de utilização no QAA mesmo com algumas limitações de bandas.

6 CONCLUSÕES E TRABALHOS FUTUROS

Os resultados obtidos neste trabalho foram importantes para ampliar a compreensão da dinâmica dos constituintes presentes nas águas turbidas dos lagos da planície de inundação amazônica. Entretanto, neste ambiente dominado por materiais particulados, principalmente inorgânicos, as estimativas da concentração de Chl-a por sensoriamento remoto ainda necessitam ser aperfeiçoadas. Em relação a modelagem, os algoritmos empíricos mostraram-se pouco consistentes devido à alta influência dos sólidos em suspensão e CDOM na região do visível, onde são localizadas as feições de absorção da Chl-a. Mesmo os algoritmos de 3 bandas ficam prejudicados devido aos efeitos remanescentes dos sólidos nas regiões do NIR. A sazonalidade dos constituintes e a alta dinâmica dos lagos pôde ser observado nas calibrações para apenas uma campanha de campo, onde os algoritmos empíricos foram mais efetivos para os dados *in situ*, porém pouco satisfatórios em imagem de data distinta à coleta.

Ao se tratar da calibração e parametrização do algoritmo semi-analítico QAA, os resultados obtidos enfatizaram a necessidade de adaptação do algoritmo. O QAA_{LGC} parametrizado obteve resultados satisfatórios em comparação com as versões da literatura. Ainda que com sucesso na determinação de $\alpha_t(\lambda)$, as relações empíricas na primeira etapa do QAA ainda carecem de clareza para águas turbidas. Assim, estimativas mais precisas de $\alpha_t(\lambda)$ são essenciais para um desempenho satisfatório nos passos seguintes. Mesmo que fora do escopo deste trabalho, a calibração das etapas de determinação do $b_b(\lambda)$ com dados de campo podem apresentar resultados mais robustos. Na segunda etapa, a baixa correlação dos fatores ζ e ξ com as relações empíricas proposta no QAA, para as águas turbidas da área de estudo, também agregaram incerteza na parametrização. Portanto, a remoção do fator ζ , como realizado por Jorge, (2018), agregou ao QAA_{LGC} uma abordagem mais robusta para a separação de $\alpha_\phi(\lambda)$ e $\alpha_{CDM}(\lambda)$, visto a dominância do α_{CDM} na absorção total. A heterogeneidade das campanhas impossibilitou a validação no conjunto de

dados independente. Assim, para trabalhos futuros deseja-se a aplicação do QAA_{LGC} em dados *in situ* e imagens do sensor OLCI concomitantes com as características de calibração do QAA_{LGC} .

REFERÊNCIAS BIBLIOGRÁFICAS

ALCANTARA, C. E. et al. Integração de dados de alta frequência temporal e imagens MODIS/TERRA para o estudo da turbidez na planície de Curuai. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007. **Anais..** São José dos Campos: INPE, 2007. p. 6549–6556.

AMMENBERG, P. et al. Bio-optical modelling combined with remote sensing to assess water quality. **International Journal of Remote Sensing**, v. 23, n. 8, p. 1621–1638, 2002.

BABIN, M. et al. Variations in the light absorption coefficients of phytoplankton, nonalgal particles, and dissolved organic matter in coastal waters around Europe. **Journal of Geophysical Research: Oceans**, v. 108, n. C7, 2003.

BAILLARIN, S. J. et al. Sentinel-2 level 1 products and image processing performances. In: GEOSCIENCE AND REMOTE SENSING SYMPOSIUM (IGARSS), 2012. **Proceedings...** IEEE, 2012.

BARBARISI, B. F. **Integração de imagem MODIS e de dados censitários na avaliação do impacto da pecuária sobre o estado trófico de sistemas aquáticos do Baixo Amazonas**. 2010. 169p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010.

BARBOSA, C. C. F. **Sensoriamento remoto da dinâmica de circulação da água do sistema planície de Curuai/Rio Amazonas**. São José dos Campos: INPE, 2005.

BARBOSA, C. C. F. et al. Geospatial analysis of spatiotemporal patterns of pH, total suspended sediment and chlorophyll-a on the Amazon floodplain. **Limnology**, v. 11, n. 2, p. 155–166, 2009.

BARSI, J. A. et al. The spectral response of the Landsat-8 operational land imager. **Remote Sensing**, v. 6, n. 10, p. 10232–10251, 2014.

BRICAUD, A. et al. Variability in the chlorophyll-specific absorption coefficients of natural phytoplankton: analysis and parameterization. **Journal of Geophysical Research: Oceans**, v. 100, n. C7, p. 13321–13332, 1995.

BRICAUD, A.; MOREL, A. Light attenuation and scattering by phytoplanktonic cells: theoretical modeling. v. 25, n. 4, p. 571–580, 1986.

BRICAUD, A.; MOREL, A.; PRIEUR, L. Absorption by dissolved organic matter of the sea (yellow substance) in the UV and visible domains. **Limnology and Oceanography**, v. 26, n. 1, p. 43–53, 1981.

BUKATA, R. P. Retrospection and introspection on remote sensing of inland water quality: "Like Déjà Vu all over again". **Journal of Great Lakes Research**, n. 39, p. 2–5, 2013.

BUKATA, R. P. et al. **Optical properties and remote sensing of inland and coastal waters**. [s.l.] CRC press, 2018.

CARDER, K. L. et al. Semianalytic moderate-resolution imaging spectrometer algorithms for chlorophyll a and absorption with bio-optical domains based on nitrate-depletion temperatures. **Journal of Geophysical Research: Oceans**, v. 104, n. C3, p. 5403–5421, 1999.

CHEN, J. et al. A simple two-band semi-analytical model for retrieval of specific absorption coefficients in coastal waters. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 91, p. 85–97, 2014.

CIOTTI, M. et al. Assessment of the relationships between dominant cell size in natural phytoplankton communities and the spectral shape of the absorption coefficient. **Limnology and Oceanography**, v. 47, n. 2, p. 404–417, 2002.

CLAVANO, W. R.; BOSS, E. S.; KARP-BOSS, L. Inherent Optical Properties of Non-Spherical Marine-Like Particles - From Theory To Observation. In: **Oceanography and marine biology: An Annual Review**. [s.l.] CRC Press, 2007. p. 5–42.

DALL'OLMO, G. et al. Assessing the potential of SeaWiFS and MODIS for estimating chlorophyll concentration in turbid productive waters using red and near-infrared bands. **Remote Sensing of Environment**, v. 96, n. 2, p. 176–187, 2005.

DALL'OLMO, G.; GITELSON, A. A. Effect of bio-optical parameter variability and uncertainties in reflectance measurements on the remote estimation of chlorophyll-a concentration in turbid productive waters: modeling results. **Applied Optics**, v. 45, n. 15, p. 3577, 2006.

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, p. 8–11, 2003.

DEKKER, A. G. **Detection of optical water quality parameters for eutrophic waters by high resolution remote sensing**. Tese (Doutorado em Ciências da Terra) - Proefschrift Vrije Universiteit, Amsterdam, 1993.

DEKKER, A. G.; BUKATA, R. P. Remote sensing of inland and coastal waters. **The Review of Radio Science 1999–2002 USRI**, v. 61, n. 2, p. 519–534, 2002.

DIERSSEN, H. M. Perspectives on empirical approaches for ocean color remote sensing of chlorophyll in a changing climate. **Proceedings of the National Academy of Sciences**, v. 107, n. 40, p. 17073–17078, 2010.

DOXARAN, D. et al. Spectral signature of highly turbid waters: application with SPOT data to quantify suspended particulate matter concentrations. **Remote sensing of Environment**, v. 81, n. 1, p. 149–161, 2002.

DRUSCH, M. et al. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. **Remote sensing of Environment**, v. 120, p. 25–36, 2012.

EUROPEAN SPACE AGENCY - ESA. **Missions European Space Agency**. 2015. Disponível em: <<https://earth.esa.int/web/guest/>>.

EUROPEAN SPACE AGENCY - ESA. Sentinel 2 - Copernicus. Paris: ESA, 2017.

ESTEVEES, F. A. **Fundamentos de limnologia**. [S.l.]: Interciência, 1998.

FARGION, G. S.; MUELLER, J. L. **Ocean optics protocols for satellite ocean color sensor validation, revision 2**. Greenbelt, MD: National Aeronautics and Space Administration, Goddard Space Flight Center, 2000.

GILERSON, A. A. et al. Algorithms for remote estimation 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 radiance spectra of algae and water: relationships of its magnitude and position with chlorophyll concentration. **International Journal of Remote Sensing**, v. 13, n. 17, p. 3367–3373, 1992.

GITELSON, A. A. et al. Remote estimation of chlorophyll concentration in productive waters: principals, algorithm development and validation. In: NWQMC NATIONAL MONITORING CONFERENCE, 2000, Austin, Texas. **Proceegins...** 2000.

GITELSON, A. A. et al. Remote estimation of leaf area index and green leaf biomass in maize canopies. **Geophysical Research Letters**, v. 30, n. 5, 2003.

GITELSON, A. A. et al. A simple semi-analytical model for remote estimation of chlorophyll-a in turbid waters: validation. **Remote Sensing of Environment**, v. 112, n. 9, p. 3582–3593, 2008.

GITELSON, A. A. et al. 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, n. 2, p. 24023, 2011.

GITELSON, A. A.; KEYDAN, G. P.; MERZLYAK, M. N. Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher plant leaves. **Geophysical Research Letters**, v. 33, n. 11, p. 2–6, 2006.

GITELSON, A. A.; KONDRATYEV, K. Y. Optical models of mesotrophic and eutrophic water bodies. **International Journal of Remote Sensing**, v. 12, n. 3, p. 373–385, 1991.

GITELSON, A.; KEYDAN, G.; SHISHKIN, V. Inland waters quality assessment from satellite data in visible range of the spectrum. **Soviet Remote Sensing**, v. 6, p. 28–36, 1985.

GITELSON, A.; KONDRAT'EV, K.; GARBUSOV, G. New approach to monitoring aquatic ecosystem quality. **Transmission USSR Academy of Science**, v. 295, p. 825–827, 1987.

GORDON, H. R. et al. A semianalytic radiance model of ocean color. **Journal of Geophysical Research: Atmospheres**, v. 93, n. D9, p. 10909–10924, 1988.

GORDON, H. R.; MOREL, A. Y. **Remote assessment of ocean color for interpretation of visible satellite imagery: a re-view**. New York: Springer-Verlag, 1983.

GURLIN, D. **Near infrared-red models for the remote estimation of chlorophyll- α concentration in optically complex turbid productive waters: from in situ measurements to aerial imagery**. 2012. 150p. Tese (Doutorado em Ciências dos Recursos Naturais) - University of Nebraska, Lincoln, 2012.

INTERNATIONAL OCEAN COLOUR COORDINATING GROUP - IOCCG. **Remote sensing of inherent optical properties: fundamentals, tests of algorithms, and applications**. Dartmouth, Canada: IOCCG, 2006. (IOCCG Report, 5).

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos naturais**. São José dos Campos: Parêntese, 2009.

JORGE, D. S. F. **Caracterização bio-óptica e implementação de algoritmos semi-analíticos para o estudo da qualidade da água na Reserva de Desenvolvimento Sustentável Mamirauá**. 2018. 163p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

JUNK, W. J.; MELLO, J. A. S. Impactos ecológicos das represas hidrelétricas na Bacia Amazônica brasileira. **Estudos avançados**, v. 4, n. 8, p. 126–143, 1990.

KALLIO, K.; KOPONEN, S.; PULLIAINEN, J. Feasibility of airborne imaging spectrometry for lake monitoring: a case study of spatial chlorophyll a distribution in two meso-eutrophic lakes. **International Journal of Remote Sensing**, v. 24, n. 19, p. 3771–3790, 2003.

KIRK, J. T. O. Monte Carlo modeling of the performance of a reflective tube absorption meter. **Applied Optics**, v. 31, n. 30, p. 6463–6468, 1992.

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

KOPONEN, S. et al. Lake water quality classification with airborne hyperspectral spectrometer and simulated MERIS data. **Remote Sensing of Environment**, v. 79, n. 1, p. 51–59, 2002.

KUTSER, T. et al. Mapping lake CDOM by satellite remote sensing. **Remote Sensing of Environment**, v. 94, n. 4, p. 535–540, 2005.

LAURANCE, W. F.; PERES, C. A. **Emerging threats to tropical forests**. [S.l.]: University of Chicago Press, 2006.

LAURION, I.; LEAN, D. R. S.; VINCENT, W. F. UVB effects on a plankton community: results from a large-scale enclosure assay. **Aquatic Microbial Ecology**, v. 16, n. 2, p. 189–198, 1998.

LE, C. et al. A four-band semi-analytical model for estimating chlorophyll a in highly turbid lakes: the case of Taihu Lake, China. **Remote Sensing of Environment**, v. 113, n. 6, p. 1175–1182, 2009.

LE, C. et al. Evaluation of chlorophyll-a remote sensing algorithms for an optically complex estuary. **Remote Sensing of Environment**, v. 129, p. 75–89, 2013.

LEE, Z. et al. Hyperspectral remote sensing for shallow waters: 2. deriving bottom depths and water properties by optimization. **Applied Optics**, v. 38, n. 18, p. 3831–3843, 1999.

LEE, Z. **Remote sensing of inherent optical properties: fundamentals, tests of algorithms, and applications**. Dartmouth: International Ocean-Colour Coordinating Group, 2006.

LEE, Z. et al. Euphotic zone depth: its derivation and implication to ocean-color remote sensing. **Journal of Geophysical Research: Oceans**, v. 112, n. C3, 2007.

LEE, Z. et al. **An update of the Quasi-Analytical Algorithm (QAA_v5)**. 2009. Disponível em: http://www.ioccg.org/groups/Software_OCA/QAA_v5.pdf.

LEE, Z. **An update of the Quasi-Analytical Algorithm (QAA_v6)**. Dartmouth: IOCCG, 2014.

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

LI, L. et al. An inversion model for deriving inherent optical properties of inland waters: establishment, validation and application. **Remote Sensing of Environment**, v. 135, p. 150–166, 2013.

- LI, L.; LI, L.; SONG, K. Remote sensing of freshwater cyanobacteria: an extended IOP Inversion Model of Inland Waters (IIMIW) for partitioning absorption coefficient and estimating phycocyanin. **Remote Sensing of Environment**, v. 157, p. 9–23, 2015.
- MARTINS, V. S. et al. Assessment of atmospheric correction methods for Sentinel-2 MSI images applied to Amazon Floodplain Lakes. **Remote Sensing**, v. 9, n. 4, p. 322, 2017.
- MARTINS, V. S. et al. Continental-scale surface reflectance product from CBERS-4 MUX data: Assessment of atmospheric correction method using coincident Landsat observations. **Remote Sensing of Environment**, v. 218, n. September, p. 55–68, 2018.
- 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.
- MELACK, J. M. et al. Regionalization of methane emissions in the Amazon Basin with microwave remote sensing. **Global Change Biology**, v. 10, n. 5, p. 530–544, 2004.
- MERZLYAK, M. N.; SOLOVCHENKO, A. E.; GITELSON, A. A. Reflectance spectral features and non-destructive estimation of chlorophyll, carotenoid and anthocyanin content in apple fruit. **Postharvest Biology and Technology**, v. 27, n. 2, p. 197–211, 2003.
- 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, D. R.; OGASHAWARA, I.; GITELSON, A. A. **Bio-optical modeling and remote sensing of inland waters**. [S.I.]: Elsevier, 2017.
- MISHRA, S. et al. Quantifying cyanobacterial phycocyanin concentration in turbid productive waters: a quasi-analytical approach. **Remote Sensing of Environment**, v. 133, p. 141–151, 2013.
- 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.
- MISHRA, S.; MISHRA, D. R.; LEE, Z. Bio-optical inversion in highly turbid and cyanobacteria-dominated waters. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 1, p. 375–388, 2014.
- MOBLEY, C. D. **Light and water: radiative transfer in natural waters**. [S.I.]: Academic Press, 1994.

- 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.
- MOBLEY, C. D.; BOSS, E. S.; ROESLER, C. S. **Ocean Optics Web Book**, 2017. Disponível em: <<http://www.oceanopticsbook.info>>
- MOREL, A.; PRIEUR, L. Analysis of variations in ocean color. **Limnology and oceanography**, v. 22, n. 4, p. 709–722, 1977.
- MOSES, W. J. et al. Satellite estimation of chlorophyll-a concentration using the red and NIR bands of MERIS: the Azov sea case study. **IEEE Geoscience and Remote Sensing Letters**, v. 6, n. 4, p. 845–849, 2009.
- MOSES, W. J. et al. Estimation of chlorophyll-a concentration in turbid productive waters using airborne hyperspectral data. **Water Research**, v. 46, n. 4, p. 993–1004, 2012.
- 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. et al. **Ocean optics protocols for satellite ocean color sensor validation, revision 4: volume III: radiometric measurements and data analysis protocols**. Washington: NASA, 2003.
- ODERMATT, D. et al. Review of constituent retrieval in optically deep and complex waters from satellite imagery. **Remote Sensing of Environment**, v. 118, p. 116–126, 2012.
- OKI, K.; YASUOKA, Y. Estimation of chlorophyll concentration in lakes and inland seas with a field spectroradiometer above the water surface. **Applied Optics**, v. 41, n. 30, p. 6463–6469, 2002.
- OKIN, G. S.; GU, J. The impact of atmospheric conditions and instrument noise on atmospheric correction and spectral mixture analysis of multispectral imagery. **Remote Sensing of Environment**, v. 164, p. 130–141, 2015.
- PIERSON, D. C.; STRÖMBECK, N. A modelling approach to evaluate preliminary remote sensing algorithms: use of water quality data from Swedish Great Lakes. **Geophysica**, v. 36, n. 1–2, p. 177–202, 2000.
- POPE, R. M.; FRY, E. S. Absorption spectrum (380–700 nm) of pure water: II. integrating cavity measurements. **Applied Optics**, v. 36, n. 33, p. 8710–8723, 1997.

- POZDNYAKOV, D.; GRASSL, H. **Color of inland and coastal waters: a methodology for its interpretation**. Berlin: Springer, 2003.
- PREISENDORFER, R. W. **Application of radiative transfer theory to light measurements in the sea**. Saint-Mandé: Institut Géographique National, 1961.
- PULLIAINEN, J. et al. A semi-operative approach to lake water quality retrieval from remote sensing data. **Science of the Total Environment**, v. 268, n. 1, p. 79–93, 2001.
- RODRIGUES, T. et al. Performance of existing QAAs in Secchi disk depth retrieval in phytoplankton and dissolved organic matter dominated inland waters. v. 12, n. 3, 2018.
- RODRIGUES, T. W. P. **From oligo to eutrophic inland waters: advancements and challenges for bio-optical modeling**. 2017. 146p. Tese (Doutorado em Ciências Cartográficas) - Universidade Estadual Paulista, Presidente Prudente, 2017.
- SATHYENDRANATH, S. et al. Remote sensing of phytoplankton pigments: a comparison of empirical and theoretical approaches. **International Journal of Remote Sensing**, v. 22, n. 2–3, p. 249–273, 2001.
- SHI, W.; WANG, M. An assessment of the black ocean pixel assumption for MODIS SWIR bands. **Remote Sensing of Environment**, v. 113, n. 8, p. 1587–1597, 2009.
- SIOLI, H. The Amazon and its main affluents: hydrography, morphology of the river courses, and river types. In: **The Amazon**. [s.l.] Springer, 1984. p. 127–165.
- SMITH, R. C.; BAKER, K. S. Optical properties of the clearest natural waters (200–800 nm). **Applied Optics**, v. 20, n. 2, p. 177–184, 1981.
- SZEKIELDA, K.-H. **Satellite monitoring of the earth**. [S.l.]: Wiley, 1988.
- TASSAN, S.; FERRARI, G. M. An alternative approach to absorption measurements of aquatic particles retained on filters. **Limnology and Oceanography**, v. 40, n. 8, p. 1358–1368, 1995.
- TASSAN, S.; FERRARI, G. M. A sensitivity analysis of the ‘Transmittance--Reflectance’ method for measuring light absorption by aquatic particles. **Journal of Plankton Research**, v. 24, n. 8, p. 757–774, 2002.
- TILSTONE, G. H. et al. **REVAMP-Regional Validation of MERIS Chlorophyll products in North Sea coastal waters**. [S.l.]: REVAMP Inter-calibration Report, 2002.
- TRIOS. **Trios sensor**. 2018. Disponível em: <https://www.trios.de/en/>.

VERMOTE, E. F. et al. Atmospheric correction of visible to middle-infrared EOS-MODIS data over land surfaces: background, operational algorithm and validation. **Journal of Geophysical Research: Atmospheres**, v. 102, n. D14, p. 17131–17141, 1997.

WANG, M. **Atmospheric correction for remotely-sensed ocean-colour products**. Dartmouth: IOCCG, 2010.

WATANABE, F. et al. 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, n. 9, p. 10391–10417, 2015.

WATANABE, F. et al. Parametrization and calibration of a quasi-analytical algorithm for tropical eutrophic waters. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 121, p. 28–47, 2016.

WATANABE, F. et al. 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**, v.90, n.2, p.1987-2000, 2017.

WATANABE, F.; ALCANTA, E. Estimation of chlorophyll- a concentration from optimizing a semi-analytical algorithm in productive inland waters. **Remote Sensing**, v. 10, p. 1–18, 2018.

WATERS, C. et al. Bio-optical inversion in highly turbid and cyanobacteria-dominated waters. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 1, p. 375–388, 2014.

WERDELL, P. J. et al. An overview of approaches and challenges for retrieving marine inherent optical properties from ocean color remote sensing. **Progress in Oceanography**, v. 160, n. January, p. 186–212, 2018.

WETLABS. **Spectral absorption and attenuation meter (ac-s) user's guide**. America: WET Labs, 2009. p.5-20.

YANG, W. et al. Retrieval of inherent optical properties for turbid inland waters from remote-sensing reflectance. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 6, p. 3761–3773, 2013.

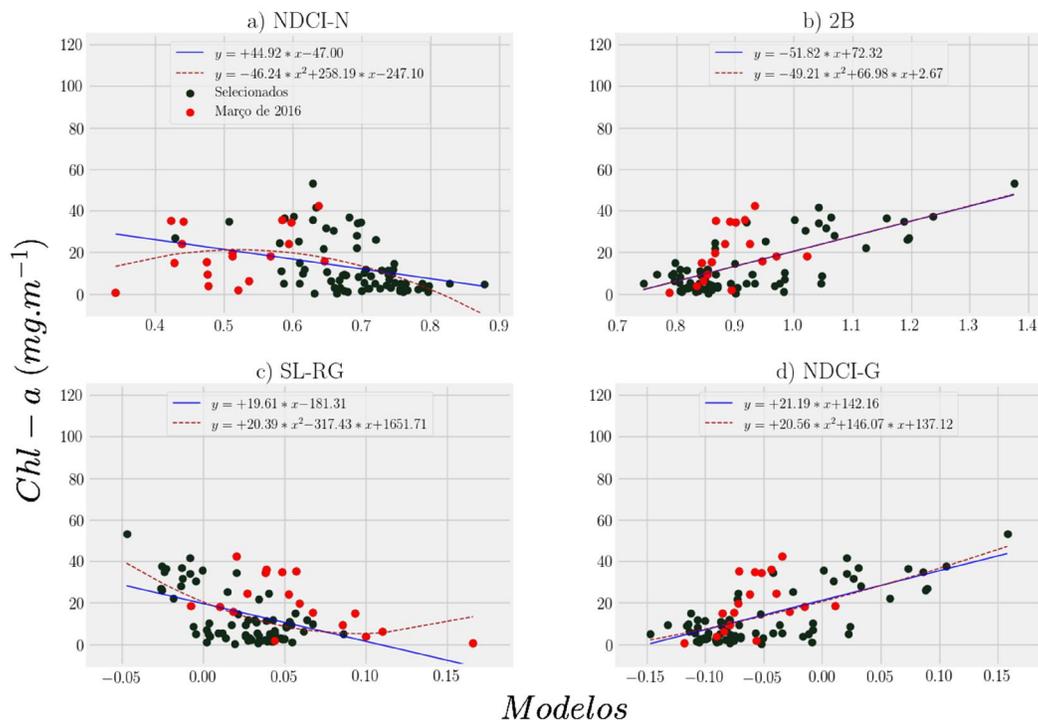
ZHANG, Y. et al. A study of absorption characteristics of chromophoric dissolved organic matter and particles in Lake Taihu, China. **Hydrobiologia**, v. 592, n. 1, p. 105–120, 2007.

ZHU, Z.; WANG, S.; WOODCOCK, C. E. Remote sensing of environment improvement and expansion of the Fmask algorithm: cloud, cloud shadow, and snow detection for Landsats 4 – 7, 8, and Sentinel 2 images. **Remote Sensing of Environment**, v. 159, p. 269–277, 2015.

ZULLO-JUNIOR, J. **Correcao Atmosferica de Imagens de Satélite e Aplicações**, 1994.

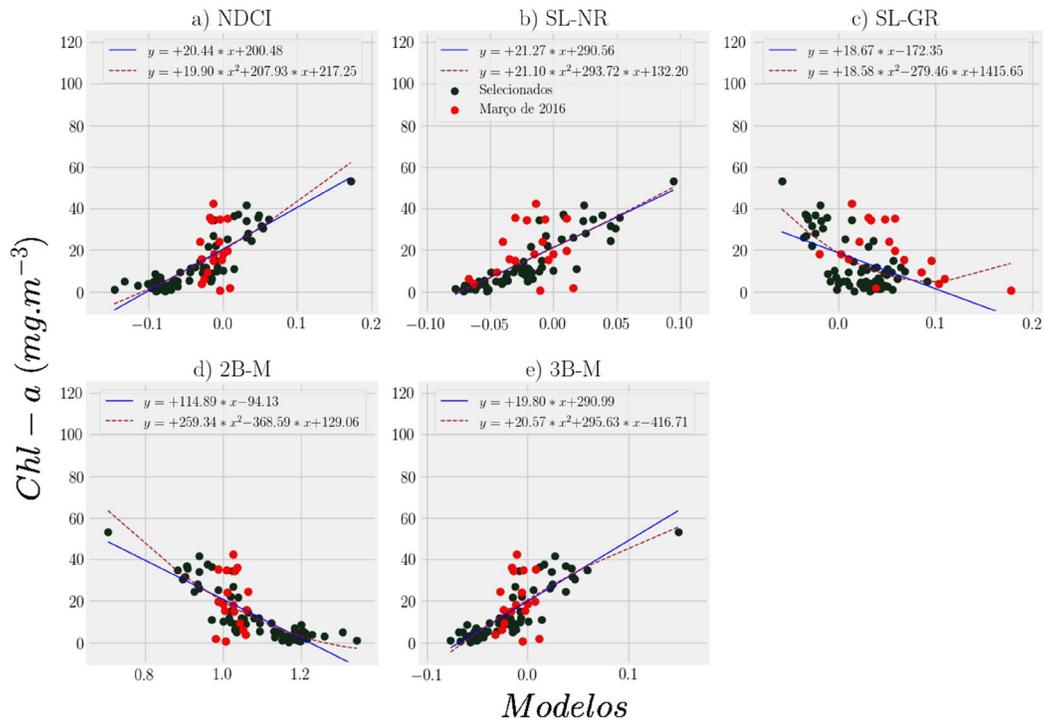
APÊNDICE A - ALGORITMOS EMPÍRICOS AJUSTADOS COM A CAMPANHA DE MARÇO DE 2016.

Figura A.1 - Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmos empíricos com a campanha de março de 2016, aplicados a $R_{rs}(\lambda)$ para o sensor OLI.



Fonte: Produção do Autor.

Figura A.2 - Dispersão e ajustes lineares e quadráticos entre a concentração de Chl-a e os algoritmos empíricos com a campanha de março de 2016, aplicados a $R_{rs}(\lambda)$ para o sensor MSI.



Fonte: Produção do Autor.