



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

sid.inpe.br/mtc-m21c/2018/04.04.18.17-TDI

**CARACTERIZAÇÃO BIO-ÓPTICA E
IMPLEMENTAÇÃO DE ALGORITMOS
SEMI-ANALÍTICOS PARA O ESTUDO DA QUALIDADE
DA ÁGUA NA RESERVA DE DESENVOLVIMENTO
SUSTENTÁVEL MAMIRAUÁ**

Daniel Schaffer Ferreira Jorge

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Cláudio Clemente Faria Barbosa, e Adriana Gomes Affonso, aprovada em 24 de abril de 2018.

URL do documento original:

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

INPE
São José dos Campos
2018

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

E-mail: pubtc@inpe.br

COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):

Presidente:

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

Membros:

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (COCST)

Dr. André de Castro Milone - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

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

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

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

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

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 Duca Barbedo - Serviço de Informação e Documentação (SESID)

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SESID)

EDITORAÇÃO ELETRÔNICA:

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SESID)

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



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

sid.inpe.br/mtc-m21c/2018/04.04.18.17-TDI

**CARACTERIZAÇÃO BIO-ÓPTICA E
IMPLEMENTAÇÃO DE ALGORITMOS
SEMI-ANALÍTICOS PARA O ESTUDO DA QUALIDADE
DA ÁGUA NA RESERVA DE DESENVOLVIMENTO
SUSTENTÁVEL MAMIRAUÁ**

Daniel Schaffer Ferreira Jorge

Tese de Doutorado do Curso de Pós-Graduação em Sensoriamento Remoto, orientada pelos Drs. Cláudio Clemente Faria Barbosa, e Adriana Gomes Affonso, aprovada em 24 de abril de 2018.

URL do documento original:

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

INPE
São José dos Campos
2018

Dados Internacionais de Catalogação na Publicação (CIP)

Jorge, Daniel Schaffer Ferreira.

J768c Caracterização bio-óptica e implementação de algoritmos semi-analíticos para o estudo da qualidade da água na reserva de desenvolvimento sustentável Mamirauá / Daniel Schaffer Ferreira Jorge. – São José dos Campos : INPE, 2018.
xxvii + 133 p. ; (sid.inpe.br/mtc-m21c/2018/04.04.18.17-TDI)

Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

Orientadores : Drs. Cláudio Clemente Faria Barbosa, e Adriana Gomes Affonso.

1. Sensoriamento Remoto. 2. Propriedades bio-ópticas.
3. Lagos da Amazônia. 4. Algoritmos semi-analíticos. 5. Simulação de sensores. I.Título.

CDU 528.8:519.165(811.3)



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): **Daniel Schaffer Ferreira Jorge**

Título: "CARACTERIZAÇÃO BIO-ÓPTICA E IMPLEMENTAÇÃO DE ALGORITMOS SEMI-ANALÍTICOS PARA O ESTUDO DA QUALIDADE DA ÁGUA NA RESERVA DE DESENVOLVIMENTO SUSTENTÁVEL MAMIRAUÁ"

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

Dra. Evlyn Márcia Leão de Moraes Novo


Presidente / INPE / SJCampos - SP

Participação por Video - Conferência

Dr. Cláudio Clemente Faria Barbosa


Orientador(a) / INPE / SJCampos - SP

Participação por Video - Conferência

Dra. Adriana Gomes Affonso


Orientador(a) / INPE / São José dos Campos - SP

Participação por Video - Conferência

Dra. Natália de Moraes Rudorff


Membro da Banca / INPE / Cachoeira Paulista - SP

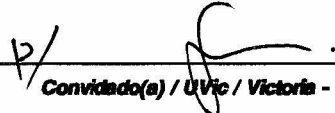
Participação por Video - Conferência

Dr. Lino Augusto Sander de Carvalho


Membro da Banca / INPE / São José dos Campos - SP

Participação por Video - Conferência

Dra. Maycira Costa


Convidado(a) / UVic / Victoria - CAN

Participação por Video - Conferência

Dra. Aurea Maria Ciotti


Convidado(a) / USP/CEBIMAR / São Sebastião - SP

Participação por Video - Conferência

Este trabalho foi aprovado por:

maioria simples

unanimidade

São José dos Campos, 24 de abril de 2018

AGRADECIMENTOS

Aos meus orientadores Claudio Barbosa e Adriana Affonso, por toda a confiança, ajuda, paciência e amizade dos últimos 4 anos, e pelas oportunidades que eles tornaram possíveis durante este percurso.

Ao INPE, e todos os seus funcionários, pelo suporte para tornar este trabalho possível, especialmente a Evlyn Novo, por todas as discussões.

Ao pessoal do LabISA por proporcionar todo o apoio técnico e científico antes, durante e depois de todos os campos, principalmente ao pessoal que me acompanhou até Mamirauá: Lino, Renato, Felipe, Vitor, Maria, Jean, Waterloo, Francieli e Rivolo.

Ao Instituto Mamirauá e seus funcionários, por todo o apoio logístico durante os campos.

Aos meus pais e irmãos, pelo apoio incondicional.

Aos meus amigos de São José dos Campos, São Paulo e Orlandia, por tornar esse processo mais fácil e mais divertido.

Ao CNPq pela bolsa de estudos, a FAPESP processo 2014/23903-9 que financiou as coletas de dados in situ como parte do projeto “Caracterização bio-óptica espaço-temporal e desenvolvimento de algoritmos analíticos para o monitoramento sistemático das massas de água que circulam pela planície de inundação do médio e baixo Amazonas”. Aos projetos MSA-BNDES 1022114003005 e CNPq 461469/2014-6 que complementaram recursos para as missões de campo.

RESUMO

O desenvolvimento de algoritmos com boa acurácia e precisão para obtenção de informações ópticas de águas interiores é fundamental para aumentar a aplicabilidade de dados de sensoriamento remoto para fins de monitoramento. Embora os algoritmos semi-analíticos tenham sido desenvolvidos para as águas oceânicas, diversos trabalhos adaptaram e aplicaram estes em águas continentais e costeiras, com relativo sucesso, entretanto para águas opticamente complexas ainda não foi possível validá-los. Para compreender melhor estes ambientes e auxiliar o desenvolvimento de ferramentas para o monitoramento de planícies de inundação da Amazônia, este estudo possui 3 objetivos: i) Realizar a caracterização bio-óptica da Reserva de Desenvolvimento Sustentável Mamirauá (RDSM) ii) Avaliar o impacto do SNR nos algoritmos para estimativa de Chl-a e TSS em quatro lagos localizados na RDSM iii) Avaliar dois algoritmos semi-analíticos aplicados aos lagos da Amazônia, que são muito dinâmicos, e com alta variabilidade na concentração de matéria orgânica, sedimentos e fitoplâncton. Para isto, dados ópticos *in situ* foram obtidos durante cinco missões entre 2015 e 2016, com um total de 102 pontos de amostragem. A análise das propriedades óticas deste ambiente mostrou que estas são controladas por duas forçantes, tempo e espaço. Durante a vazante, os lagos possuem características relativamente homogêneas, enquanto que durante a enchente, o impacto varia em função da posição dos lagos em relação aos rios de entorno. Para os lagos localizados dentro da floresta e longe dos rios principais, observou-se um aumento na matéria orgânica, enquanto que para os lagos localizados próximos aos rios, observou-se um aumento de detrito. Para avaliar o impacto do SNR em medidas bio-ópticas, dois conjuntos de dados foram simulados (espectros com e sem ruído) com base em medições *in situ* e nas características do sensor (MSI / Sentinel-2, OLCI / Sentinel-3 e OLI / Landsat 8). O conjunto de dados foi testado em três algoritmos empíricos para TSS e em quatro para Chl-a. Os resultados mostraram que o impacto do SNR em cada algoritmo exibiu padrões semelhantes para ambos os constituintes. Para algoritmos lineares e aditivos, a amplitude do erro é constante para toda a faixa de concentração. No entanto, para algoritmos multiplicativos, o erro muda de acordo com a equação do algoritmo e a magnitude da R_{rs} . Por fim, para o algoritmo exponencial, a amplitude de erro é maior para concentração baixa. O sensor OLCI possui o melhor desempenho (erro de até 2 $\mu\text{g/L}$ para o Chl-a, com faixa entre 9 e 14 $\mu\text{g/L}$, e 3 mg/L para o TSS, com faixa entre 5 e 30 mg/L). Para MSI, o erro dos algoritmos aditivos e lineares para TSS e Chl-a é baixo (até 5 mg/L e 1 $\mu\text{g/L}$, respectivamente); mas, para o algoritmo multiplicativo, os erros foram acima de

10 µg/L. A simulação OLI resultou em erros abaixo de 3 mg/L para o TSS. No entanto, o número e a posição das bandas do OLI restringem a estimativa de Chl-a. Para a avaliação dos algoritmos semi-analíticos, foram testados dois algoritmos para os lagos da RDSM: Spectral Optimization Algorithm (SOA); e Quasi-Analitical Algorithm (QAA). Cada algoritmo foi calibrado, utilizando tanto a estrutura original quanto mudanças propostas para águas opticamente complexas. Os algoritmos foram inicialmente testados para todo o conjunto de dados coletados *in situ* com resultados não satisfatórios para o QAA. Para melhorar o desempenho dos algoritmos, o conjunto de dados foi dividido em lagos escuros (Bua Bua e Mamiraua) e lagos claros (Pirarara e Pantaleão), com base no espectro de R_{rs} . Os resultados mostraram que os espectros de absorção total derivados do SOA, quando comparados a medidas *in situ*, apresentaram alta correlação, entretanto ao discriminar as frações em fitoplâncton e detrito+CDOM, o algoritmo não foi capaz de discriminar a fração do fitoplâncton em lagos escuros. Para o QAA, os resultados se mostraram satisfatórios, tanto para a absorção total, quanto para as absorções fracionada. Entretanto, observou-se uma tendência do QAA subestimar os valores de absorção. Considerando que os algoritmos não foram desenvolvidos para ambientes opticamente complexos e com grande variação espacial e temporal os resultados se mostraram satisfatórios, sendo uma ferramenta fundamental para o desenvolvimento de programas de monitoramento para águas Amazônicas.

Palavras-chave: Sensoriamento Remoto. Propriedades bio-ópticas. Lagos da Amazônia. Algoritmos semi-analíticos. Simulação de sensores.

BIO-OPTICAL CHARACTERIZATION AND IMPLEMENTATION OF SEMI-ANALYTICAL ALGORITHMS FOR THE STUDY OF MAMIRAUÁ SUSTAINABLE DEVELOPMENT RESERVE WATER QUALITY.

ABSTRACT

The development of algorithms with good precision and accuracy to obtain optical information from inland waters is fundamental to increase the applicability of remote sensing data for monitoring purposes. Although semi-analytical algorithms had been developed for ocean waters, several works adapted and applied them on coastal and inland waters, with relative success, but for extremely complex waters, validations have yet to be achieved. To understand better those environments and to develop new tools to monitor Amazonian flood plains, this has 3 objectives: i) Accomplish the bio-optical characterization of the Mamirauá Sustainable Development Reserve (MSDR) ii) Evaluate the impact of signal-to-noise ratio (SNR) on Chl-a and TSS algorithms in four lakes located in the Mamirauá Sustainable Development Reserve (RDSM) iii) Evaluate two semi-analytical algorithms applied to Amazon lakes, which are dynamic and with high variability in the organic matter, sediments and phytoplankton concentration. To accomplish that, *in situ* optical data were obtained during five missions between 2015 and 2016, with a total of 102 sampling stations. The evaluation of the optical properties of this environment showed that those are controlled by 2 forces, time and space. During the receding water, the lakes have relatively homogeneous characteristics, while during the flood, the impact changes based on the lakes position in relation with the surrounding rivers. For the lakes located inside the forest and far from the main rivers, an increase in organic matter was observed, while for the lakes located near the rivers, an increase in detritus was observed. To evaluate the impact of the SNR on bio-optical measurements, two datasets were simulated (noisy and noiseless), based on *in situ* measurements and sensors design (MSI / Sentinel-2, OLCI / Sentinel-3 e OLI / Landsat 8). The dataset was tested in three empirical algorithms for TSS and four for Chl-a. The results showed that the impact of the SNR on each algorithm showed similar patterns for both constituents. For linear additive algorithms, the error amplitude is constant for all the concentration range. But for multiplicative algorithms, the uncertainty changed based on the algorithm equation and R_{rs} magnitude. Lastly, for exponential algorithms, the error amplitude is higher for lower concentration. OLCI sensor had the best performance (error of up to 2 $\mu\text{g/L}$ for Chl-a, with range between 9 and 14 $\mu\text{g/L}$ and 3 mg/L for TSS with range between 5 and 30 mg/L). For MSI, the additive and linear algorithms error for TSS and Chl-a is low (up to 5 mg/L and 1 $\mu\text{g/L}$, respectively); but for multiplicative algorithms, the errors were above 10 $\mu\text{g/L}$. OLI simulation resulted in errors below 3 mg/L for TSS. However, OLI band positions and numbers is restrictive for Chl-a estimation.

To evaluate the semi-analytical algorithms, two algorithms were tested for RDSM lakes: Spectral Optimization Algorithm (SOA); and Quasi-Analytical Algorithm (QAA). Each algorithm was calibrated, using both the original structure and proposed changes for optically complex waters. The algorithms were initially tested for all the dataset sampled *in situ*, but the results were not satisfactory for QAA. To increase the algorithm performance the dataset was divided on dark lakes (Bua Bua and Mamirauá) and bright lakes (Pirarara and Pantaleão), based on R_{rs} spectrum. The results showed that the total absorption spectra derived from SOA, when compared to *in situ* measurements, presented high correlation, however when discriminating the phytoplankton and detritus+CDOM fractions, the algorithm was not successful to discriminate the phytoplankton fraction on dark lakes. For the QAA, the results were satisfactory, for both total and fractioned absorption. However, QAA showed a tendency to underestimate the absorption magnitude. Considering that the algorithms were not developed for optically complex environments and with high spatial and temporal variability, the results were satisfactory, being a fundamental tool for the development of monitoring programs for Amazon waters.

Keywords: Remote sensing. Bio-optical properties. Amazon lakes. semi-analytical algorithms. Sensor simulation.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 3.1 Série temporal do nível da água ao longo dos anos de 2010 a 2015 para a RDSM. A linha preta representa o nível da água em metros e as cores representam a fase do pulso. Vermelho se refere à cheia, verde à vazante, azul à seca e amarelo à enchente.	9
Figura 3.2 Coeficiente de retrospalhamento do material particulado normalizado em 400 nm e modelado para 7 valores de Y (0 a 1.2).....	25
Figura 3.3 Coeficiente de absorção do CDOM + detrito normalizado em 440 nm e modelado para 7 valores de S (0 a 0,03).	26
Figura 3.4 Exemplo de curvas obtidas pela técnica SOA, evidenciando a forma em U (em vermelho) e V (em azul)	30
Figura 4.1 Mapa da área de estudo. Lagos em vermelho representam os lagos selecionados. Após o campo preliminar realizado em 2015, os 4 lagos centrais foram selecionados. Buabua a Noroeste, Pantaleão a Nordeste, Mamiraua a Sudoeste e Pirarara a Sudeste em relação ao centro da imagem.	40
Figura 4.2 Visão esquemática dos 6 sensores TRIOS utilizados para a coleta de dados radiométricos. Onde $ESky$ é a irradiância incidente na superfície, $Lsky$ é a radiância do céu, Lw é a radiância ascendente da água, Ed é a irradiância descendente, Eu é a irradiância ascendente e Lu é a radiância ascendente.....	47
Figura 4.3 Fotografia mostrando como os 6 sensores trios foram posicionados no barco.	48
Figura 4.4 Fluxograma das 5 etapas realizadas para a simulação dos sensores	53
Figura 5.1 Distribuição da concentração dos dados limnológicos dos lagos da RDSM e do Lago Grande do Curuai. As cores se referem aos 5 lagos, “e” e “v” se referem aos valores médios obtidos durante a enchente e vazante, respectivamente. Os dados referentes ao lago Grande do Curuai foram obtidos por Carvalho (2016).....	69

Figura 5.2 Ternário do coeficiente de absorção para os COAs presentes na água para 4 comprimentos de onda (400, 440 550 e 676 nm) e para as 3 fases coletadas. A numeração na legenda se refere as missões em que cada ponto foi coletado. As missões 2 e 3 se referem ao período de enchente, enquanto que as missões 1, 4 e 5 se referem ao período de vazante. A distribuição de cores se refere aos 4 lagos analisados. Os círculos representam a primeira missão durante a fase do pulso, e os triângulos representam a segunda missão.....	72
Figura 5.3 Coeficiente de absorção do CDOM para as 5 missões e 4 lagos analisados. As missões 2 e 3 se referem ao período de enchente de 2016, enquanto que as missões 1, 4 e 5 se referem ao período de vazante de 2015 e 2016. A distribuição de cores se refere aos 4 lagos analisados.....	75
Figura 5.4 Coeficiente de absorção do detrito para as 5 missões e 4 lagos analisados. As missões 2 e 3 se referem ao período de enchente de 2016, enquanto que as missões 1, 4 e 5 se referem ao período de vazante de 2015 e 2016. A distribuição de cores se refere aos 4 lagos analisados.....	76
Figura 5.5 Coeficiente de absorção do fitoplâncton para as 5 missões e 4 lagos analisados. As missões 2 e 3 se referem ao período de enchente de 2016, enquanto que as missões 1, 4 e 5 se referem ao período de vazante de 2015 e 2016. A distribuição de cores se refere aos 4 lagos analisados.....	76
Figura 5.6 Valores médios dos coeficientes de absorção total medidos pelo AC-S para os lagos escuros (a) e claros (b). A distribuição de cores se refere as 5 missões. A linha contínua representa os valores médios e a barra de erro se refere ao desvio padrão. “E” se refere a enchente e “V” se refere a vazante...	78
Figura 5.7 Valores médios dos coeficientes de espalhamento total medidos pelo AC-S para os lagos escuros (a) e claros (b). A distribuição de cores se refere as 5 missões. A linha contínua representa os valores médios e a barra de erro se refere ao desvio padrão. “E” se refere a enchente e “V” se refere a vazante.....	80
Figura 5.8 Exemplo do efeito do glint para uma estação amostral do lago Mamirauá.	83

Figura 5.9 <i>Rrs</i> estimada pelas metodologias Mobley e Mobley+Kutser. As cores se referem aos 4 lagos analisados. As linhas contínuas se referem as amostras coletadas durante a vazante e a linha pontilhada se refere as amostras coletas durante a enchente.	84
Figura 5.10 Distribuição do campo de luz subaquático para um único ponto dos lagos Pirarara e Bua Bua em cada missão de campo. A distribuição de cores se refere ao valor de <i>Ed</i> estimado a partir do <i>KD</i> para cada profundidade e comprimento de onda, e normalizado pelo valor em superfície. A linha preta representa $1KD$ e a linha vermelha representa 1% da zona eufótica (<i>Zeu</i>).	86
Figura 5.11 <i>Rrs</i> espectral simulada para os sensores MSI, OLCI e OLI. A primeira coluna se refere aos valores de <i>Rrs</i> sem ruído e a segunda coluna se refere ao erro percentual na <i>Rrs</i> devido ao ruído. A distribuição de cores se refere aos 4 lagos e as barras em cinza se referem as bandas estimadas para cada sensor.	88
Figura 5.12 Performance de cada algoritmo utilizado para estimar a concentração de Chl-a para o sensor MSI. (a) CLH; (b) 2B; (c) 3B; (d) NDCI. Os pontos em vermelho representam a concentração estimada incluindo o ruído e os pontos em amarelo a concentração estimada sem ruído.	90
Figura 5.13 Performance de cada algoritmo utilizado para estimar a concentração de Chl-a para o sensor OLCI. (a) CLH; (b) 2B; (c) 3B; (d) NDCI. Os pontos em vermelho representam a concentração estimada incluindo o ruído e os pontos em amarelo a concentração estimada sem ruído.	91
Figura 5.14 Exemplo pontual do impacto da magnitude de <i>Rrs</i> para o sensor OLCI na estimativa de concentração de Chl-a utilizando os quatro algoritmos. (a) e (c) se referem a uma estação amostral para o Lago Bua Bua e (b) e (d) para o Lago Pirarara. (a) e (b) apresentam a magnitude de <i>Rrs</i> e (c) e (d) o erro absoluto na concentração de clorofila-a para os 4 algoritmos.	94
Figura 5.15 Exemplo da relação entre o ruído e o tamanho da janela de pixels, variando de 1x1 até 3x3 pixels.	96
Figura 5.16 Performance do algoritmo TSS_linear para estimativa de concentração de TSS para os 3 sensores selecionados, onde: (a) sensor MSI.	

(b) sensor OLCI, (c) sensor OLI. Pontos em vermelhos se referem a estimativa de concentração de TSS com ruído e pontos em amarelo ao dado sem ruído.97

Figura 5.17 Performance do algoritmo TSS_exp para estimativa de concentração de TSS para os 3 sensores selecionados, onde: (a) sensor MSI. (b) sensor OLCI, (c) sensor OLI. Pontos em vermelhos se referem a estimativa de concentração de TSS com ruído e pontos em amarelo ao dado sem ruído.97

Figura 5.18 Performance do algoritmo TSS_NSSI para estimativa de concentração de TSS para os 3 sensores selecionados, onde: (a) sensor MSI. (b) sensor OLCI, (c) sensor OLI. Pontos em vermelhos se referem a estimativa de concentração de TSS com ruído e pontos em amarelo ao dado sem ruído.98

Figura 5.19 Coeficientes de absorção total estimados pelo algoritmo QAA para os dois métodos de correção da *Rrs*. A primeira coluna utilizou a *Rrs* estimada pelo método Mobley, e a segunda pelo método Mobley+Kutser. A terceira coluna se refere aos dados medidos *in situ* pelo AC-S, tratado como referência. As linhas em azul e vermelho se referem aos lagos escuros e as linhas verde e amarela se referem aos lagos claros..... 101

Figura 5.20 Gráfico de dispersão entre os valores de absorção total estimados pelo QAA e medidos *in situ* para os 4 lagos. A distribuição de cores se refere aos 4 lagos..... 102

Figura 5.21 Gráfico de dispersão entre os valores de absorção estimados pelo QAA e medidos *in situ* para os 4 lagos. Os gráficos superiores se referem as medidas de *adg*, enquanto que os gráficos inferiores se referem as medidas de *aphy*. A distribuição de cores se refere aos 4 lagos..... 103

Figura 5.22 Gráfico de dispersão entre os valores de *aCDOM* e *adg* estimados pelo QAA e medidos *in situ* para os lagos claros. Os gráficos superiores se referem as medidas de *adet*, enquanto que os gráficos inferiores se referem as medidas de *aCDOM*. As cores representam os lagos Pirarara (amarelo) e Pantaleão (verde)..... 107

Figura 5.23 Gráfico de dispersão entre os valores de absorção estimados pelo SOA e medidos *in situ* para os 4 lagos. Os gráficos superiores se referem ao *at* em dois comprimentos de onda e os gráficos inferiores se referem a *adg* e

$aphy$ para um único comprimento de onda. As cores representam os 4 lagos.

109

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 3.1 Características gerais dos sensores orbitais apresentados neste trabalho.	22
Tabela 3.2 Exemplo da evolução do algoritmo QAA ao longo do tempo, contendo as adaptações propostas por cada autor para a primeira etapa de calibração do algoritmo	34
Tabela 4.1 Configurações do sensor MSI/Sentinel-2 usadas como entrada para a simulação. CC é o comprimento de onda central (nm), LB é a largura da banda (nm), RS é a resolução espacial (m), $LTOA_{ref} (W.m - 2.sr - 1.\mu m - 1)$ é a radiancia na qual o SNR foi calculado, Quant é a quantização e $LTOA_{MAX} (W.m - 2sr - 1.\mu m - 1)$ é a radiância máxima que pode ser medida pelo sensor.....	54
Tabela 4.2 Configurações do sensor OLCI-Sentinel 3 usadas como entrada para a simulação. CC é o comprimento de onda central (nm), LB é a largura da banda (nm), RS é a resolução espacial (m), $LTOA_{ref} (W.m - 2.sr - 1.\mu m - 1)$ é a radiancia na qual o SNR foi calculado, Quant é a quantização e $LTOA_{MAX} (W.m - 2sr - 1.\mu m - 1)$ é a radiância máxima que pode ser medida pelo sensor.....	55
Tabela 4.3 Configurações do sensor OLI/Landsat 8 usadas como entrada para a simulação. CC é o comprimento de onda central (nm), LB é a largura da banda (nm), RS é a resolução espacial (m), $LTOA_{ref} (W.m - 2.sr - 1.\mu m - 1)$ é a radiancia na qual o SNR foi calculado, Quant é a quantização e $LTOA_{MAX} (W.m - 2sr - 1.\mu m - 1)$ é a radiância máxima que pode ser medida pelo sensor.....	56
Tabela 4.4 Parâmetros usados durante a conversão do espectro solar no TOA para irradiância de superfície para todos os sensores.	60
Tabela 4.5 Exemplo dos parâmetros obtidos e usados durante a simulação atmosférica para o sensor MSI. $F0_{TOA}$ é a irradiância solar no TOA para cada	

banda, τ_r é a densidade óptica de Rayleigh para uma atmosfera padrão e τ_{OZ} é a densidade óptica do ozônio para 300 DU de ozônio na atmosfera. 60

Tabela 4.6 Algoritmos para a estimativa de Chl-a e TSS. O comprimento de onda exato foi adaptado a cada sensor testado. CLH é um algoritmo de linha de altura de Chl-a (MATTHEWS et al., 2012), 2B é um algoritmo de razão de banda para 2 bandas (MOSES et al., 2009), 3B é um algoritmo de razão de bandas para 3 bandas (MOSES et al., 2009), NDCI é um algoritmo de razão de bandas para 2 bandas (MISHRA; MISHRA et al., 2012), TSS_linear é um algoritmo linear a partir da banda do vermelho (BINDING et al., 2003), TSS_exp é um algoritmo exponencial (CHEN et al., 2015) e TSS_NSSI é um algoritmo exponencial baseado em uma razão de bandas (LOBO et al., 2015).

62

Tabela 4.7 Parâmetros de entrada para o algoritmo SOA..... 66

Tabela 5.1 Distribuição da concentração dos dados limnológicos dos lagos da RDSM. Os lagos Escuros se referem aos lagos Bua Bua e Mamirauá e os lagos Claros se referem aos lagos Pantaleão e Pirarara; “E” e “V” se referem a à enchente e vazante, respectivamente. Média se refere aos valores médios, DP ao desvio padrão, CV ao coeficiente de variação, Min ao mínimo e Max ao máximo..... 70

Tabela 5.2 Distribuição das IOPs dos lagos da RDSM. Os lagos Escuros se referem aos lagos Bua Bua e Mamirauá e os lagos Claros se referem aos lagos Pantaleão e Pirarara. Média se refere aos valores médios, DP ao desvio padrão, CV ao coeficiente de variação, Min ao mínimo e Max ao máximo. c (m^{-1}) se refere ao coeficiente de atenuação, a (m^{-1}) ao coeficiente de absorção e b (m^{-1}) ao coeficiente de retroespalhamento. 81

Tabela 5.3 Distribuição das IOPs dos lagos da RDSM. Os lagos Escuros se referem aos lagos Bua Bua e Mamirauá e os lagos Claros se referem aos lagos Pantaleão e Pirarara. Média se refere aos valores médios, DP ao desvio padrão, CV ao coeficiente de variação, Min ao mínimo e Max ao máximo. $acdom$ (m^{-1}) se refere ao coeficiente de absorção do CDOM, $adet$ (m^{-1}) ao

coeficiente de absorção do detrito, $a_{phy}(m^{-1})$ ao coeficiente de absorção do fitoplâncton e $bb(m^{-1})$ ao coeficiente de retroespalhamento.	82
Tabela 5.4 Valor de NRMSE obtido para estimativa de at pelo algoritmo QAA para as duas metodologias de correção da Rrs (Lagos escuros) para os 4 comprimentos de onda selecionados.	104
Tabela 5.5 Valor de NRMSE obtido para estimativa de at pelo algoritmo QAA para as duas metodologias de correção da Rrs (Lagos claros) para os 4 comprimentos de onda selecionados.	104
Tabela 5.6 Valor de NRMSE obtido para estimativa de adg e $aphy$ pelo algoritmo QAA para os lagos claros e escuros para os 4 comprimentos de onda selecionados.	105
Tabela 5.7 Valor de NRMSE obtido para estimativa de at , adg e $aphy$ pelo algoritmo SOA para os lagos claros e escuros para os dois comprimentos de onda selecionados.	109
Tabela 6.1 Resumo geral da caracterização bio-óptica da RDSM em função das variáveis espaciais e temporais.	112
Tabela 6.2 Resumo geral das conclusões referentes a simulação dos sensores orbitais. $\downarrow Rrs$ se refere a espectros com baixa magnitude de Rrs , $\uparrow Rrs$ com alta magnitude de Rrs , $\propto SNR$ significa proporcional a relação sinal ruído, Erro(\square) proporcional a concentração, $\propto SNRn$ proporcional a SNR, mas com carácter exponencial, $\neq \square$ independe da concentração, Erro($1Rrs$) é inversamente proporcional a magnitude da Rrs e $\neq Rrs$ independe da Rrs	114
Tabela 6.3 Resumo geral das conclusões referentes ao QAA e SOA para os Lagos Claros e Escuros da RDSM. at , adg , $aphy$, $adet$ e $aCDOM$ são os coeficientes de absorção total, detrito+CDOM, fitoplâncton, detrito e CDOM, respectivamente, e δ é referente a incerteza dos resultados.	115

LISTA DE SIGLAS E ABREVIATURAS

RDSM	Reserva de Desenvolvimento Sustentável Mamirauá
MODIS	Moderate Resolution Imaging Spectroradiometer
SR	Sensoriamento Remoto
NRC	National Research Council
CDOM	Colored Dissolved Organic Matter
Chl-a	Clorofila-a
QAA	Quasi Analytical algorithm
GSM	Garver-Siegel-Maritorena
COA	Componente opticamente ativo
IOP	Inherent Optical Property
AOP	Apparent Optical Property
OLCI	Ocean and Land Colour Instrument
OLI	Operational Land Imager
VSF	Volume Scattering Function
FLH	Fluorescence Line Height
IOCCG	International Ocean-Colour Coordinating Group
SNR	Signal-to-noise Ratio
REM	Radiação Eletromagnética
SOA	Spectral Optimization Algorithm
DI	Deionizada
DIC	Dissolved Inorganic Carbon
DOC	Dissolved Organic Carbon
DMSO	Dimetilsulfóxido

HOPE	Hyperspectral Optimization Process Exemplar
HPLC	High Performance Liquid Chromatography
iCDOM	Índice de CDOM
LMI	Linear Matrix Inversion
RMSE	Root Mean Squared Error
NRMSE	Normalized Root Mean Squared Error
PML	Plimouth Marine Laboratory
REM	Radiação Eletromagnética
SNR	Signal to Noise Ratio
SOA	Spectral Optimiation Algorithm
SR	Sensoriamento Remoto
TOA	Topo da atmosfera
TSS	Total de Sólidos Suspensos
TSIS	Total de Sólidos Inorgânicos Suspensos
TSOS	Total de Sólidos Orgânicos Suspensos

LISTA DE SÍMBOLOS

a	Coeficiente de absorção
b	Coeficiente de espalhamento
β	Função de espalhamento volumétrico
Φ_0	Fluxo radiante incidente
Φ_a	Fluxo radiante absorvido
Φ_b	Fluxo radiante espalhado
Δr	Largura de uma camada infinitesimalmente fina
dI	Intensidade radiante para o ângulo θ
dV	Elemento Volumétrico
$d\theta$	Ângulos entre 0 e 180 °
$d\omega$	Ângulos entre 0 e 4 π sr
K_D	Coeficiente de atenuação vertical difuso
R_{rs}	Reflectância de Sensoriamento remoto
L_w	Radiância ascendente proveniente da água
E_d	Irradiância descendente
f/Q	Termo que depende do campo de luz incidente
$a_t(\lambda)$	Coeficiente de absorção total da água
$a_w(\lambda)$	Coeficiente de absorção da água pura
$a_{cdm}(\lambda)$	Coeficiente de absorção do detrito+CDOM
$a_{dg}(\lambda)$	Coeficiente de absorção do detrito+CDOM
$a_{CDOM}(\lambda)$	Coeficiente de absorção da CDOM
$a_{phy}(\lambda)$	Coeficiente de absorção do fitoplâncton
$a_{det}(\lambda)$	Coeficiente de absorção do detrito
b_b	Coeficiente de retroespalhamento
b_f	Coeficiente de espalhamento frontal
b_{bp}	Coeficiente de retroespalhamento do material particulado
b_{bw}	Coeficiente de retroespalhamento da água pura
L_{sky}	Radiância descendente proveniente do céu

L_u	Radiância ascendente
E_s	Irradiância descendente
E_u	Irradiância ascendente
ρ_{sky}	Fator de correção fixo para o glint
ρ_{sky}^*	Fator de correção variável para o glint
z_{ref}	Profundidade de referência
$\sigma(K_{bb})$	Fator de correção para o equipamento hydroscat
ρ_T	Transmitância normalizada pelo branco
ρ_R	Reflectância normalizada pelo branco
R_f	Reflectância do branco
τ	Fator de correção para o método T-R
OD_{sus}	Absorbância do material em suspensão
OD_{phy}	Absorbância do fitoplâncton
OD_{total}	Absorbância corrigida do particulado
OD_{det}	Absorbância do detrito
RF	Função resposta do sensor
L_{TOA}	Radiância no topo da atmosfera
F_0	Espectro solar
t_0	Transmitância difusa sol/água
t_v	Transmitância difusa água/sensor
tr	Espessura óptica de Rayleigh
toz	Espessura óptica do Ozônio
h_0	Altura da concentração máxima do ozônio
sr	Esterradianos
λ	Comprimento de onda

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO.....	1
1.1 Delineamento do Trabalho.....	4
1.1.1 Motivação.....	4
1.1.2 Pergunta.....	5
1.1.3 Premissas.....	5
1.1.4 Hipótese	5
2 OBJETIVOS.....	7
2.1 Objetivo Geral.....	7
2.2 Objetivos específicos.....	7
2.3 Estrutura da Tese	7
3 FUNDAMENTAÇÃO TEÓRICA	9
3.1 O pulso de inundação e os tipos de água Amazônicas	9
3.2 Características bio-ópticas das águas Amazônicas.....	10
3.3 Propriedades ópticas da água	13
3.3.1 Propriedades Ópticas Inerentes.....	13
3.3.2 Propriedades Ópticas Aparentes.....	14
3.3.3 Relação entre Propriedades Ópticas Aparentes e inerentes.....	15
3.4 Sensoriamento remoto da cor da água e algoritmos bio-ópticos	18
3.5 Histórico dos algoritmos bio-ópticos	19
3.6 Características ópticas dos sensores orbitais e o futuro do sensoriamento remoto	20
3.7 Consolidando algoritmos semi-analíticos.....	22
3.7.1 Base teórica dos algoritmos semi-analíticos	23
3.7.2 Estratégias bottom-up	27
3.7.2.1 Spectral Optimization Algorithm (SOA)	27
3.7.3 Estratégias top-down.....	32
3.7.3.1 Quasi-Analytical Algorithm (QAA)	32
4 MATERIAIS E MÉTODOS	39

4.1	Área de Estudo	39
4.2	Estratégias de amostragem	41
4.2.1.1	Análise Laboratorial	42
4.2.1.1.1	Absorção do CDOM.....	43
4.2.1.1.2	Absorção do material particulado	44
4.2.2	Caracterização Óptica.....	46
4.2.2.1	AOPs.....	46
4.2.2.2	IOPs.....	50
4.2.2.2.1	Processamento AC-S	51
4.2.2.2.2	Hydroscat.....	51
4.2.3	Sensoriamento Remoto.....	52
4.2.3.1	Simulação de sensores orbitais	52
4.2.3.2	Impacto das especificações dos sensores nos algoritmos de Chl-a e TSS	61
4.3	Caracterização bio-óptica	62
4.4	Desenvolvimento e implementação do algoritmo semi-analítico	63
4.5	Estimadores de Erro	66
5	RESULTADOS E DISCUSSÃO	67
5.1	Caracterização bio-óptica	67
5.1.1	Dinâmica das Variáveis Limnológicas	67
5.1.2	IOPs – Absorção	71
5.1.2.1	IOPs medidas em laboratório.....	71
5.1.2.2	IOPs medidas <i>in situ</i>	77
5.1.3	Reflectância de Sensoriamento Remoto	82
5.1.4	Coeficiente de Atenuação Vertical Difuso <i>KD</i> da luz	85
5.2	Avaliação do impacto das características dos sensores OLI, OLCI e MSI nos algoritmos bio-ópticos.....	86
5.2.1	Simulação do Dataset	86
5.2.2	Avaliação dos algoritmos	89
5.2.2.1	Clorofila-a.....	89
5.2.2.2	TSS.....	96

5.3 Algoritmos semi analíticos	98
6 CONSIDERAÇÕES FINAIS.....	111

1 INTRODUÇÃO

A bacia do Rio Amazonas corresponde a maior bacia de drenagem do mundo, contemplando 7 países e mais de 6,8 milhões de km² (NEILL et al., 2006). Aproximadamente 17% da bacia é ocupada por áreas inundáveis (HESS et al., 2015), como mangues costeiros, regiões pantanosas de floresta aberta de palmeiras, savanas inundadas e por fim, planícies de inundaç o, que se situam   margem dos diversos rios amaz nicos (FORSBERG et al., 2000). Devido   sua dimens o, biodiversidade, riqueza em recursos naturais e seu papel nos processos globais e regionais, a bacia amaz nica vem sendo objeto de grande interesse de estudo (JUNK et al., 2011). A circula o da  gua pelas  reas inund veis da bacia   controlada por um pulso de inunda o anual, que durante o per odo de subida da  gua (per odo de enchente), passa a alimentar os canais de conex o do rio com a plan cie at  o ponto em que o n vel da  gua atinge o seu pico, quando ocorre o transbordamento da  gua sobre os terrenos laterais, nivelando a calha do rio com a plan cie. Ap s um per odo no est gio de equil brio entre plan cie e calha (per odo da cheia), o n vel da  gua come a a se reduzir (per odo da vazante) at  que atinja o n vel de  gua mais baixo (per odo da  gua baixa), quando o fluxo pelos canais de conex o se reduz significativamente (JUNK et al., 1989). Essa din mica causa uma grande variabilidade nas propriedades  pticas da  gua (AFFONSO et al., 2011), e conseq entemente nos processos biogeoqu micos na plan cie, devido   entrada de sedimentos e de mat ria org nica de origem florestal.

Em termos relativos, os ecossistemas da plan cie de inunda o Rio Amazonas s o pouco conhecidos e estudados, quando comparados aos ecossistemas terrestres amaz nicos. Estima-se a exist ncia de mais de 10 mil lagos com  rea superior a um hectare (1 ha), dos quais menos de 1% foram estudados (SIPPEL et al., 1992).

Para compreender e monitorar como os ecossistemas aqu ticos se comportam sob uma perspectiva biol gica, f sica e qu mica, tr s abordagens s o amplamente utilizadas: i) Abordagens in situ: com a coleta de dados em

campo, como amostras de água, fauna e flora, e análise de parâmetros ambientais (BARBOSA et al., 2010; AFFONSO et al., 2011; CARVALHO et al., 2015), ii) Abordagens remotas: com a utilização de sensores orbitais (MOLERI et al., 2010), e iii) Abordagem integrada: a combinação das duas anteriores (ARRAUT et al., 2010; AFFONSO, 2012).

O monitoramento de regiões remotas, como os lagos de planície de inundação dos rios amazônicos, através de abordagens *in situ*, dependem da acessibilidade frequente às áreas de estudo e demanda um grande esforço logístico, o que torna inviável o monitoramento periódico devido ao alto custo envolvido. Nessas regiões, as metodologias de baixo custo operacional, como o sensoriamento remoto tem se destacado, permitindo a aquisição de diversos parâmetros relacionados às propriedades ópticas da água (MUMBY et al., 1999). Metodologias *in situ* dependem da acessibilidade às áreas de estudo e podem acarretar em altos custos operacionais, enquanto que metodologias remotas, apesar de necessitarem de um maior investimento inicial, resultam em um melhor custo benefício (MUMBY et al., 1999).

Nas últimas décadas, o sensoriamento remoto (SR) orbital tem se sobressaído para o monitoramento de ambientes aquáticos em geral (MUOW et al., 2015). Esta ferramenta possui uma resolução espacial e temporal inalcançável de outra forma, e permite a aquisição de diferentes parâmetros ambientais relacionados a qualidade da água (NRC (National Research Council), 2011), como a clorofila-a (Chl-a), Total de Sólidos Suspensos (TSS) e matéria orgânica dissolvida colorida (CDOM em inglês Colored Dissolved Organic Matter). Considerando que a cor da água é determinada pela presença de fitoplâncton, matéria orgânica e detrito, o SR pode ser utilizado com diferentes objetivos, como estudos da dinâmica hidrológica (BARBOSA, 2005), transporte de matéria orgânica e sedimentos (MOLERI et al., 2010) e taxonomia (ALVAIN, et al., 2005).

A reflectância medida por um sensor orbital é convertida em diferentes produtos de interesse ao monitoramento dos ambientes aquáticos por meio da

utilização de algoritmos específicos (e.g. Chl-a, TSS). Os quais podem ser divididos didaticamente em dois grandes, algoritmos empíricos e semi-analíticos. Algoritmos empíricos se referem ao estabelecimento de relações matemáticas diretas entre a reflectância medida e a variável de interesse, por meio de ajustes estatísticos. Os algoritmos de Matthews et al. (2012), Moses et al. (2009) e Mishra e Mishra (2012) são exemplos de algoritmos empíricos para a estimativa de clorofila-a. Já algoritmos semi-analíticos se apoiam na compreensão dos processos de interação da luz com os componentes opticamente ativos presentes na água. Por não serem puramente analíticos, os coeficientes dos algoritmos são ajustados empiricamente. O Quasi Analytical Algorithm - QAA (LEE, 2002) e o Garver, Siegel & Maritorena - GSM inicialmente desenvolvido por Garver e Siegel (1997) e aprimorado por (MARITORENA et al., 2002) são exemplos de algoritmos semi-analíticos.

No entanto, nas águas interiores, e em geral opticamente complexas, a comunidade fitoplanctônica, a CDOM e o detrito interagem concomitante com a luz, sendo que o efeito da interação de um constituinte mascara parcialmente o efeito de outro constituinte, diferentemente dos ambientes oceânicos, em que a cor da água varia principalmente em função da interação do fitoplâncton com a luz (PRESENDORFER, 1961; CIOTTI et al., 1999; MOREL; MARITORENA, 2001; MOREL; GENTILI 2009,). Desta forma, algoritmos desenvolvidos para o oceano produzem resultados insatisfatórios quando aplicados a águas interiores. Dentro desse contexto, a comunidade científica passou a desenvolver algoritmos específicos para águas interiores ou adaptar os algoritmos existentes (DEKKER et al., 2002; KUTSER, 2004) e um dos desafios atuais é a implementação de algoritmos semi-analíticos em ambientes mais complexos do que aqueles para os quais os algoritmos haviam sido desenvolvidos, ou seja, as águas oceânicas.

Além das incertezas atribuídas aos algoritmos, estas podem ser potencializadas em função das características do alvo. Para lagos de planície de inundação dos rios Amazônicos, estes algoritmos necessitam estar

adaptados à sazonalidade do ambiente, uma vez que as características ópticas são influenciadas pelo pulso de inundação (JUNK, 1989), com grande variabilidade no aporte de CDOM e TSS. Assim, os lagos localizados na Reserva de Desenvolvimento Sustentável Mamirauá - RDSM na planície de inundação dos Rios Japurá e Solimões no interior da Amazônia permitem testar o potencial destes algoritmos e nortear como estes devem evoluir para permitir o monitoramento de ambientes interiores e opticamente complexos por meio de dados orbitais.

Considerando as dificuldades relacionadas ao monitoramento de áreas de acesso restrito, às dimensões da planície de inundação e sua acessibilidade, o presente trabalho pretende combinar técnicas de sensoriamento remoto *in situ*, orbital e laboratorial com a aquisição de dados limnológicos para avaliar o uso de algoritmos baseados em sensoriamento remoto orbital voltados ao monitoramento sistemático dos ambientes aquáticos da RDSM. Assim, através da calibração de algoritmos semi-analíticos, será possível utilizar toda a gama de sensores orbitais para o monitoramento da cor da água neste ambiente, e esta informação poderá servir de subsídio para estudos ópticos e estudos voltados ao impacto da cor da água na fauna e flora da região.

1.1 Delineamento do Trabalho

Este trabalho propõe a calibração e implementação de 2 algoritmos semi analíticos inversos utilizando medidas bio-ópticas coletadas *in situ* nos lagos da RDSM, visando a obtenção de medidas quantitativas dos componentes opticamente ativos na água.

1.1.1 Motivação

A RDSM é a maior reserva existente dedicada à conservação da várzea Amazônica, extremamente preservada, de grande interesse multidisciplinar e é um dos sítios brasileiros da Convenção Ramsar das Nações Unidas para proteção das áreas alagáveis. A área é regida por um pulso de inundação sazonal que controla o ecossistema local. Por estar localizada numa área de

difícil acesso, no interior do Amazonas, a aquisição remota de dados de concentração de clorofila-a, sedimentos e matéria orgânica dissolvida é a mais adequada. Além disso, para o estabelecimento de algoritmos precisos para o monitoramento deste ambiente, é necessário o entendimento dos processos que controlam a variabilidade das propriedades ópticas da água ao longo do tempo e espaço. Sendo este um ambiente pouco antropizado, onde os processos que controlam as propriedades ópticas da água são naturais, será possível entender a dinâmica natural e avaliar se algoritmos calibrados para ambientes antropizados são diretamente aplicáveis nestas regiões.

1.1.2 Pergunta

É possível calibrar e implementar, a partir de medidas *in situ*, algoritmos bio-ópticos disponíveis da literatura para o desenvolvimento de metodologias para estudar e monitorar os lagos da RDSM? Após implementados, eles podem ser adaptados para utilização dos sensores atualmente disponíveis?

1.1.3 Premissas

- O pulso de inundação sazonal controla a entrada de matéria orgânica, de sedimentos e a concentração de Chl-a nos lagos da RDSM;
- As características espectrais dos Componentes Opticamente Ativos (COAs) são regidas pelo pulso de inundação, possuindo um componente sazonal.
- O conjunto de medidas *in situ*, planejado e coletado, é suficiente para calibrar e implementar os algoritmos selecionados;
- As imagens dos sensores disponíveis são adequadas para calibrar os algoritmos em função das suas bandas;
- É necessário assumir uma correção atmosférica ideal para quantificar o impacto das características dos sensores orbitais nas medidas radiométricas.

1.1.4 Hipótese

As propriedades ópticas da água dos lagos da RDSM podem ser monitoradas por sensoriamento remoto.

2 OBJETIVOS

2.1 Objetivo Geral

O objetivo geral do trabalho é a calibração e implementação de dois algoritmos semi-analíticos para a estimativa dos coeficientes de absorção e espalhamento dos componentes ópticamente ativos presentes na água nos lagos da RDSM.

2.2 Objetivos específicos

- i) Realizar a caracterização bio-óptica dos lagos da RDSM a partir de medidas *in situ* das IOPs (em inglês Propriedades Ópticas Inerentes), AOPs (em inglês Propriedades Ópticas Aparantes), e dados limnológicos e biológicos;
- ii) Simular os sensores orbitais OLI/LANDSAT 8, MSI/SENTINEL-2 e OLCI/SENTINEL-3, a partir dos espectros *in situ*, para a implementação dos algoritmos propostos, assim como avaliar os impactos das especificações de projeto dos sensores na incerteza das estimativas dos constituintes.
- iii) Parametrizar os algoritmos semi-analíticos a partir do conjunto de dados obtidos *in situ* e em laboratório;

2.3 Estrutura da Tese

A estrutura da tese está dividida em fundamentação teórica, materiais e métodos, resultados e discussão e considerações finais.

Na fundamentação teórica, apresenta-se uma visão geral sobre o pulso de inundação e os diferentes tipos de água Amazônica, tanto em função da sua composição química, quanto em função das suas propriedades ópticas. Em seguida, uma revisão sobre a teoria das propriedades óticas da água e sobre a estimativa das mesmas através de sensoriamento remoto. Por fim, este capítulo descreve os diferentes algoritmos bio-ópticos utilizados em sensoriamento remoto, como eles se relacionam com os sensores orbitais

disponíveis e a base teórica para os dois algoritmos semi-analíticos selecionados.

Nos materiais e métodos descreve-se a área de estudo e o conjunto de dados amostrados, assim como as diferentes etapas entre a aquisição do dado e o seu processamento. Por fim, este capítulo apresenta a abordagem estatística selecionada para a análise dos dados, as diferentes etapas de calibração dos algoritmos e os estimadores de erro selecionados durante as análises.

O capítulo resultados e discussão foi dividido em 3 seções. A primeira faz a caracterização bio-óptica do ambiente utilizando os diferentes dados coletados in situ. A segunda apresenta a simulações dos sensores orbitais e o impacto da relação sinal ruído em modelos empíricos. A terceira apresenta os resultados da calibração e validação dos dois algoritmos semi-analíticos.


Por fim, o último capítulo relaciona-se as considerações finais para este trabalho.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 O pulso de inundação e os tipos de água Amazônicas

O pulso de inundação é o fator chave nos processos ecológicos da várzea Amazônica, que transforma periodicamente ambientes terrestres em aquáticos (JUNK, et al., 1997) através do transbordamento lateral das águas dos canais, lagos e rios. O pulso tem um padrão anual monomodal, apesar de variabilidade interanual determinada pelo regime de chuvas na região e dos Andes. Durante o período de enchente, o nível da água excede a altura da calha iniciando o transbordamento da água sobre os terrenos laterais, e alimentando toda a planície de inundação. No período que a água atinge o seu pico de alagamento, a magnitude do nível da água varia aproximadamente 10 m (RAMALHO et al., 2009). Em seguida, o nível da água começa a baixar atingindo o nível de água mais baixo em que apenas os rios principais, alguns canais de conexão e os lagos mais profundos da planície contenham água. A Figura 3.1 descreve a variação do pulso de inundação ao longo do tempo para a RDSM.

Figura 3.1 Série temporal do nível da água ao longo dos anos de 2010 a 2015 para a RDSM. A linha preta representa o nível da água em metros e as cores representam a fase do pulso. Vermelho se refere à cheia, verde de vazante, azul à seca e amarelo à enchente.



Fonte: Produção do autor.

Dessa forma, a variação do nível da água permite que o ambiente possua características tanto terrestres quanto aquáticas, de acordo com a época do ano (JUNK et al., 1997). Essa variação sazonal aumenta a diversidade biológica e durante parte do seu ciclo, atua como fonte de alimento e de abrigo contra predadores para diversas espécies, se caracterizando como um ambiente que propicia o desenvolvimento de espécies migratórias (GOULDING et al., 1996; ARAUJO-LIMA, 2001). Outro fator importante para a ecologia desses ambientes, é a alta produtividade primária, contribuindo para a disponibilidade de energia para toda a cadeia trófica (FORSBERG et al., 1993; PAROLIN et al., 2004; ARRAUT et al., 2010), principalmente durante o período de seca e vazante (AFFONSO et al., 2011). Durante o período de enchente e cheia, ocorre a homogeneização das propriedades ópticas dos ambientes lagunares próximos, enquanto que durante a seca e vazante, se espera um comportamento contrário, devido ao isolamento dos lagos. Essa dinâmica causa uma grande variabilidade nas propriedades ópticas da água (AFFONSO et al., 2011), devido a entrada de sedimentos pelos rios e de matéria orgânica de origem florestal.

Essa planície é alagada por diferentes tipos de água que variam em função da sua origem, tipo de solo e das condições climáticas (JUNK, 1997), e são divididas em 3 grandes grupos, baseados no pH e na concentração dos materiais particulados e dissolvidos. O primeiro grupo corresponde a águas pretas (Rio Negro), com um pH entre 3,8 e 4,9 e com grande concentração de matéria orgânica dissolvida. O segundo grupo corresponde a águas brancas (Rio Solimões), com um pH entre 6,2 e 7,2 e grande concentração tanto de materiais dissolvidos quanto particulados. O terceiro grupo corresponde a águas claras (Rio Tapajós), com um pH entre 4,5 e 7,8 e baixa concentração tanto de materiais dissolvidos quanto de particulados (SIOLI, 1950).

3.2 Características bio-ópticas das águas Amazônicas

O regime de cheias das águas e de chuvas na Amazônia influencia a qualidade da água, alterando as concentrações das substâncias que controlam a cor da

água ao longo das fases da hidrógrafa. Estudos realizados por Barbosa (2005) na várzea do Lago Grande de Curuai, médio Amazonas, integraram medidas *in situ*, limnológicas, radiométricas e batimétricas em 144 estações amostrais e imagens Landsat-TM 5, e indicaram que em média, ao longo do ano hidrológico, 80% da planície é dominada por águas brancas, variando de 820 km² na cheia para 650 km² na seca.

Na várzea da Reserva de Desenvolvimento Sustentável Mamirauá, no Baixo Solimões, Affonso et al. (2011) observaram que entre os anos de 2008 e 2010, os lagos são ocupados predominantemente por águas brancas no período da cheia (entre junho e julho). Durante a vazante (agosto e setembro) e a seca (outubro e novembro) os autores observaram que os lagos apresentam maior amplitude nas suas propriedades químicas e físicas, com a ocorrência de ambientes dominados por água preta. Deve-se levar em conta que esta classificação foi baseada no pH, e não na concentração dos COAs. A precipitação possui grande influência na entrada de sedimentos de origem fluvial, com a predominância de partículas inorgânicas durante a seca e aumento na biomassa fitoplanctônica durante o fim da vazante, devido aos processos de ressuspensão e sedimentação, respectivamente.

Expandindo a abordagem de Barbosa (2005), Carvalho (2016) demonstrou como as propriedades ópticas do Lago Grande do Curuai variaram em função das diferentes fases do pulso de inundação, com um aumento do TSS durante a seca e enchente, enquanto que o CDOM se manteve relativamente estável ao longo do ano, condizente com as medidas *in situ* de coeficiente de absorção do CDOM e do detrito. Já no caso da RDSM, espera-se uma maior variação no CDOM, pelo fato dos lagos estarem localizados no interior da floresta.

Outro fator relevante para planícies de inundação se refere ao seu comportamento hidrodinâmico. Bonnet et al. (2008) discute que para o Lago grande do Curuai, o rio Amazonas é responsável por 77% da descarga fluvial anual, enquanto que a precipitação, escoamento e águas subterrâneas contribuem com apenas 9%, 10% e 4% (respectivamente) para sua

composição. Sazonalmente, foi observada uma maior influência do rio Amazonas durante o Verão, e uma maior influência da precipitação e das nascentes da Terra Firme durante o Outono. Para a RDSM, espera-se predomínio de contribuição fluvial dos rios adjacentes (Japurá e Solimões). Entretanto, este balanço hídrico ainda não foi realizado para esta região.

Quanto à biomassa fitoplanctônica da RDSM, Affonso et al. (2011) observaram que em condições extremas, quanto ao pulso de inundação, os lagos apresentavam condições oligotróficas durante a cheia e condições hiper-eutróficas durante a seca, com concentrações de clorofila-a de 5 e 130 µg/L, respectivamente. Os lagos possuem uma grande variabilidade natural nos parâmetros de qualidade de água, em resposta momentânea do ambiente ao pulso de inundação. A produtividade primária varia em função de diversas características do ambiente, e as condições oligotróficas observadas durante a cheia podem estar relacionadas à excessiva turbulência, ao aumento na concentração de CDOM, ao baixo tempo de residência da água e/ou baixa disponibilidade de luz (KIRK, 1994).

Casali et al. (2011) identificaram o predomínio de três grupos distintos de fitoplâncton na região do Baixo Amazonas, com Criptofíceas (Flagelados) durante a cheia e Cianobactérias e Diatomáceas durante a seca. Costa et al. (2013) observaram, por meio de análise HPLC (em inglês High Performance Liquid Chromatography), que existe um padrão na distribuição dos pigmentos fotossintetizantes, presentes nos grupos fitoplanctônicos, em função do tipo de água presente, com o domínio de clorofila-a, zeaxantina e clorofila-b (Cianobactéria) em águas claras, clorofila-a e Aloxantina (Criptofíceas) em águas pretas e clorofila-a em águas brancas. Outro fator relevante para a ecologia desses ambientes se refere à variabilidade dos grupos taxonômicos presentes, com maior variabilidade de pigmentos acessórios em águas claras e pretas.

A distribuição temporal e espacial dos grupos fitoplanctônicos possui grande relevância para a compreensão dos processos naturais e impactos das

atividades antrópicas. Durante as últimas décadas, diversos trabalhos (CIOTTI, 2002; SISWANTO, 2013) têm correlacionado as propriedades ópticas da água com índices que quantificam e/ou detectam a presença de grupos fitoplanctônicos através de seus pigmentos acessórios. Em águas opticamente complexas, todos os componentes podem contribuir de forma significativa para a sua coloração, sendo necessário quantificar esses diferentes componentes para compreender melhor as propriedades biofísicas desses ambientes.

3.3 Propriedades ópticas da água

A coloração superficial da água, ou reflectância espectral, resulta da interação entre a irradiância solar na faixa espectral visível (400 a 700 nm), e os constituintes opticamente ativos presentes no corpo, através de processos de absorção e espalhamento (PREISENDORFER, 1961). A partir destes processos divide-se conceitualmente as propriedades ópticas de corpos de água em 2 grupos: propriedades ópticas inerentes (IOP) e aparentes (AOP) (PREISENDORFER, 1961; MOBLEY 1994).

3.3.1 Propriedades Ópticas Inerentes

As IOPs são propriedades intrínsecas ao meio e não dependem da geometria do campo de luz, sendo as principais os coeficientes de absorção (a), de espalhamento (b) e a função de espalhamento volumétrico (β) (PREISENDORFER, 1961).

O coeficiente de absorção é definido como a fração do fluxo (energia) incidente que é absorvida por unidade de distância no meio aquático (Equação 3.1).

$$a = \frac{\left(\frac{\Phi_a}{\Phi_0}\right)}{\Delta r} (m^{-1}) \quad 3.1$$

Onde Φ_0 é o fluxo radiante (energia por unidade de tempo) incidente na forma de um feixe paralelo em determinado sistema físico e Φ_a é o fluxo radiante absorvido pelo sistema em uma camada infinitesimalmente fina de largura Δr , com unidade de m^{-1} (KIRK, 2011).

O coeficiente de espalhamento é definido como a fração do fluxo (energia) incidente que é espalhado por unidade de distância no meio aquático (Equação 3.2).

$$b = \frac{\left(\frac{\Phi_b}{\Phi_0}\right)}{\Delta r} (m^{-1}) \quad 3.2$$

Onde Φ_b é o fluxo radiante espalhado pelo sistema. Os coeficientes de absorção e espalhamento possuem como unidade 1/largura, e são normalmente descritos com unidade de m^{-1} .

A função de espalhamento volumétrico $\beta(\phi)$ descreve como a radiação eletromagnética incidente em um determinado elemento volumétrico dV é espalhada em todas as direções. Ela é definida como a intensidade radiante dI ($W \cdot sr^{-1}$) em uma determinada direção theta, emanada por elemento volumétrico dV iluminado por um feixe paralelo de luz, por unidade de irradiância incidente ($W \cdot m^{-2}$) (Equação 3.3).

$$\beta(\theta) = \frac{dI(\theta)}{E} dV (m^{-1} sr^{-1}) \quad 3.3$$

Uma definição alternativa para o coeficiente de espalhamento é a integral da função de espalhamento volumétrico em todas as direções, e pode ser descrita como:

$$b = 2\pi \int_0^\pi \beta(\theta) \sin \theta d\theta = \int_{4\pi} \beta(\theta) d\omega (m^{-1}) \quad 3.4$$

onde $d\theta$ se refere aos ângulos entre 0 e 180° e $d\omega$ se refere aos ângulos sólidos entre 0 e 4π sr.

3.3.2 Propriedades Ópticas Aparentes

Já as AOPs, dependem do meio (por meio dos processos de absorção e espalhamento), da geometria de distribuição do campo de luz incidente e

possuem feições regulares e estáveis, podendo ser utilizadas para descrever o corpo d'água. As principais AOPs são a reflectância (cor da água) e o coeficiente de atenuação da irradiância difusa descendente (K_d).

Uma AOP extremamente relevante para o estudo das propriedades ópticas em ambientes aquáticos, por meio de sensores orbitais, é a $R_{rs}(\lambda)$ (sr^{-1}), que é a base de todos os estudos em sensoriamento remoto e foco deste trabalho. De forma simplificada, a reflectância de sensoriamento remoto ou $R_{rs}(\lambda)$ pode ser estimada utilizando a razão entre a radiância que emerge da superfície da água (atravessa a atmosfera e atinge os sensores orbitais) e a irradiância incidente no corpo d'água:

$$R_{rs}(\lambda) = \frac{L_w(\lambda)}{E_s(\lambda)} (sr^{-1}) \quad 3.5$$

Onde $R_{rs}(\lambda)$ corresponde à reflectância de sensoriamento remoto, $L_w(\lambda)$ corresponde 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, ajustadas em função da posição entre o sensor e o ponto medido (MOBLEY, 1999), com unidade sr^{-1} (esterradianos).

3.3.3 Relação entre Propriedades Ópticas Aparentes e inerentes

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 componentes opticamente ativos da água, dado que tanto o retroespalhamento quanto a absorção são funções dos COAs (GORDON et al., 1989). Esta relação é definida como:

$$R_{rs}(\lambda) = f/Q \frac{b_b(\lambda)}{a_t(\lambda) + b_b(\lambda)} (sr^{-1}) \quad 3.6$$

onde $b_b(\lambda)$ é o coeficiente de retroespalhamento total, $a_t(\lambda)$ o coeficiente de absorção total e f/Q é um termo que depende do campo de luz incidente, que considera o efeito da interface ar-água, da variação de $Rrs(\lambda)$ devido a variação angular do campo de luz incidente e o efeito de espalhamento bidirecional (KIRK 1984; GORDON, 1989).

O coeficiente de absorção da luz em um corpo de água, $a_t(\lambda, m^{-1})$, pode ser decomposto em função das absorções dos seus COAs, sendo definido como:

$$a_t(\lambda) = a_w(\lambda) + a_{CDOM}(\lambda) + a_{phy}(\lambda) + a_{det}(\lambda)(m^{-1}) \quad 3.7$$

Onde $a_w(\lambda)$, $a_{CDOM}(\lambda)$, $a_{phy}(\lambda)$ e $a_{det}(\lambda)$ correspondem à absorção de luz pelas moléculas de água (w), pela matéria orgânica dissolvida colorida ($CDOM$), pelo fitoplâncton (phy) e pelos detritos (det), respectivamente, onde λ representa o comprimento de onda. Apesar do distrito estar normalmente atribuído as partículas ($>0,7 \mu m$) em decomposição de origem fitoplanctônica, para este estudo $a_{det}(\lambda)$ se refere a todas as partículas não algais (fitoplâncton vivo), ou seja, inclui tanto a parcela originada do fitoplâncton quanto a parcela do sedimento. Durante florações de fitoplâncton, a contribuição de $a_{phy}(\lambda)$ para $a(\lambda)$ geralmente supera a dos demais componentes opticamente ativos (WANG et al., 2010). Em águas em que o coeficiente de absorção é dominado pelo fitoplâncton (águas Caso I), a influência de CDOM e detritos varia apenas com a concentração de clorofila-a (PRESENDORFER, 1961; MOREL; MARITORENA, 2001; MOREL; GENTILI, 2009). Em ambientes opticamente complexos (águas Caso II), $a_{CDOM}(\lambda)$ e $a_{det}(\lambda)$ tendem a apresentar maiores magnitudes que $a_{phy}(\lambda)$ nos comprimentos de onda no azul e no vermelho, e seu comportamento óptico não covaria com a clorofila-a (GALLEGOS; NEALE, 2002; CHEN et al., 2003; D'SA; MILLER, 2003). Todavia, caso se conheça o comportamento espectral dos componentes opticamente ativos da água, ou caso estes não variem ao longo do tempo, é possível discriminar a absorção devido ao fitoplâncton da absorção dos demais componentes ópticos (CIOTTI, 1999).

A magnitude de $a_w(\lambda)$ aumenta exponencialmente a partir dos comprimentos de onda na região espectral do vermelho (POPE; FRY 1997), e pode ser considerada relativamente constante (varia com a salinidade e temperatura). Ambas as magnitudes de $a_{CDOM}(\lambda)$ e $a_{det}(\lambda)$ diminuem exponencialmente com o aumento do comprimento de onda (BRICAUD et al., 1981). O comportamento espectral de $a_{phy}(\lambda)$ é determinado pelos pigmentos presentes nas células (HOEPFFNER; SATHYENDRANATH, 1991), tamanho celular (CIOTTI et al., 2002) e grupo taxonômico (BARLOW et al., 2002).

A CDOM é em geral constituída por ácidos húmicos e fúlvicos (CARDER et al., 1989; BLOUGH; GREEN, 1995) e pode ter origem local, pela degradação de células do fitoplâncton (THURMAN, 1985) ou de outras partículas orgânicas, ou pode ter origem alóctone (eCOBLE, 2007; STUBBINS et al., 2010). Em ambientes estuarinos e de águas interiores, observa-se uma maior concentração de CDOM (SIEBURTH; JENSEN, 1969; BRICAUD et al., 1981; CARDER et al., 1989). Como o comportamento espectral de $a_{det}(\lambda)$ se assemelha àquele de $a_{CDOM}(\lambda)$ e por não ser possível separar os dois componentes de forma simples, em algoritmos para a sua detecção por sensoriamento remoto (KIRK, 1994), a absorção de luz de ambos é geralmente combinada em um único termo, designado como $a_{dg}(\lambda)$ ou $a_{cdm}(\lambda)$ (CARDER et al., 1991; SIEGEL et al., 2002).

O espectro de absorção do pigmento clorofila-a possui picos nas faixas do azul (~440 nm) e do vermelho (~670 nm) e determina, em grande parte, as variações espectrais de $a_{phy}(\lambda)$. A composição dos pigmentos além da clorofila-a (pigmentos acessórios), determinados pela sua taxonomia, e efeito de empacotamento são os fatores que alteram a variabilidade de $a_{phy}(\lambda)$ em segunda ordem em termos de forma e magnitude (BRICAUD et al., 1995, 2004; CIOTTI et al., 2002). Essas alterações em $a_{phy}(\lambda)$, por sua vez, se relacionam às condições de luz e concentração de nutrientes sob as quais o fitoplâncton se encontra (MARRA et al., 2007).

O coeficiente de espalhamento $b(\lambda)$ por sua vez, pode ser subdividido em duas frações em função da direção de espalhamento; coeficiente de espalhamento frontal $b_f(\lambda, m^{-1})$ e coeficiente de retroespalhamento $b_b(\lambda, m^{-1})$.

O $b_b(\lambda)$ se refere ao espalhamento entre 90 e 180°, em relação a direção de propagação da luz. Para comunidades fitoplanctônicas, WHITMIRE et al. (2010) demonstram como $b_b(\lambda)$ varia para diferentes espécies em cultivo, mas são escassos os estudos com medidas de $b_b(\lambda)$ em associação a florações de fitoplâncton em ambientes lagunares. Em geral, $b_b(\lambda)$ é composto por duas frações: i) $b_{bp}(\lambda)$ que se refere a todo o material particulado (fitoplâncton+detrimento); ii) $b_{bw}(\lambda)$, que se refere a água (Equação 3.8).

$$b_b(\lambda) = b_{bp}(\lambda) + b_{bw}(\lambda)(m^{-1}) \quad 3.8$$

3.4 Sensoriamento remoto da cor da água e algoritmos bio-ópticos

Essencialmente, o desenvolvimento de algoritmos bio-ópticos pode ser subdividido em duas abordagens; empíricas e analíticas. Abordagens empíricas se referem a ajustes matemáticos/estatísticos entre dados radiométricos/limnológicos coletados *in situ* e dados radiométricos/produtos extraídos de imagens orbitais adquiridas concomitantemente (O'REILLY et al., 1998). Já as abordagens analíticas utilizam a teoria da transferência radiativa na coluna d'água e na atmosfera para ajustar algoritmos entre dados extraídos das imagens e dados de propriedades ópticas inerentes e aparentes medidas *in situ* (e.g. Hydrolight). Algoritmos semi-analíticos são classificados dessa forma por possuírem parcelas empíricas e analíticas no seu desenvolvimento, uma vez que parte da calibração é feita baseada em ajustes estatísticos entre as variáveis (CLARK, 1997; CIOTTI et al., 2002; LEE et al., 2002; MARITORENA et al., 2002; CARDER et al., 2003).

No contexto de sensoriamento remoto para corpos d'água, podemos exemplificar a diferença entre estas duas abordagens através de algoritmos para a estimativa de clorofila-a. Em algoritmos empíricos, são feitas regressões

entre R_{rs} e concentração de Chl-a, testando diferentes comprimentos de onda, razões de banda e número de bandas, por exemplo os algoritmos OC2 e OCx, (MOSES, et al., 2009; HU et al, 2012; MATTHEWS, et al., 2012; MISHRA; MISHRA, 2012) e selecionando a regressão com o melhor ajuste estatístico. Entretanto, para algoritmos semi-analíticos para estimativa de Chl-a, as relações entre a R_{rs} e as variáveis de interesse são baseadas nas equações de transferência radiativa., Estas equações são derivadas das propriedades de absorção e espalhamento de todos os componentes opticamente ativos presentes na água e seus respectivos algoritmos bio-ópticos. Desta forma, a concentração de Chl-a e as IOPs são derivadas simultaneamente (MARITORENA et al., 2002; LEE et al., 2002; BOSS; ROESLER, 2006; MISHRA et al., 2013; LEE et al., 2014; WATANABE et al., 2016).

3.5 Histórico dos algoritmos bio-ópticos

Uma série de algoritmos bio-ópticos empíricos foram desenvolvidos para estimar a concentração de clorofila-a em águas caso I utilizando o sensor CZCS e posteriormente revistos para os sensores SeaWiFS e MODIS-Aqua. Em geral, estes algoritmos utilizam a magnitude de R_{rs} nas bandas espectrais centradas em 443 nm, 490 nm, 510 nm e 555 nm para o sensor SeaWiFS e 443 nm, 488 nm e 547 nm para o sensor MODIS-Aqua (O'REILLY et al., 1998; CARDER et al., 2003). As bandas do azul são referentes ao máximo de absorção de clorofila-a, e a banda no verde referente ao seu mínimo. Tal algoritmo utiliza a maior razão de R_{rs} entre as bandas do azul e do verde para o cálculo de clorofila-a, minimizando os efeitos da absorção de luz devido ao CDOM e detritos ($a_{dg}(\lambda)$) e relação sinal-ruído.

Outro produto obtido através de razões entre R_{rs} é o índice de CDOM – i-DOM desenvolvido por Morel e Gentili (2009) para águas caso I, e estima a relação entre CDOM e clorofila-a no corpo de água com base na razão de R_{rs} entre 412/443 nm e 490/555 nm. Resumidamente, valores de iCDOM entre 0 e 1 sugerem águas dominadas por $a_{phy}(\lambda)$, enquanto que valores de iCDOM acima de 1, águas dominas por $a_{dg}(\lambda)$.

Um outro exemplo de algoritmos bio-ópticos relevante para o estudo das propriedades ópticas do fitoplâncton é a linha de altura da fluorescência, FLH (em inglês Fluorescence Line Height), descrito inicialmente por Abbott e Letelier (1999). Em teoria, FLH é proporcional à intensidade de fluorescência natural emitida pelo fitoplâncton nas bandas do vermelho. O algoritmo pressupõe que, na ausência de clorofila-a, a R_{rs} varia linearmente entre 667 nm e 748 nm e que desta forma, qualquer variação da magnitude em 678 nm é devido ao aumento da magnitude da R_{rs} pela fluorescência. Assim, o algoritmo extrai dois valores de R_{rs} em 678 nm, o primeiro é o valor medido e o segundo é o valor estimado segundo um ajuste linear entre 667 nm e 748 nm. O nome FLH deriva desta linha de altura formada em 748 nm, e a sua magnitude é a diferença entre os valores medidos e estimados.

Baseados em dados *in situ* e laboratoriais, foi possível desenvolver algoritmos empíricos de classificação taxonômica da comunidade fitoplanctônica. As propriedades ópticas do fitoplâncton foram estudadas de forma a compreender como a R_{rs} se comporta em função de alterações nos grupos fitoplanctônicos predominantes, tamanho celular (CIOTTI, 1999) e composição de pigmentos acessórios (ALVAIN et al., 2005). Porém, é incerto se algoritmos que se baseiam nessas relações são apropriados para águas caso II. Em ambientes opticamente complexos, a obtenção de informações do fitoplâncton através de R_{rs} (WEAVER; WRIGLEY, 1994; RICHARDSON, 1996) será possível, provavelmente, durante florações fitoplanctônicas e/ou em situações em que o sinal óptico devido ao fitoplâncton for maior do que o dos demais constituintes ópticos (CULLEN et al., 1997; KIRKPATRICK et al., 2000; SUBRAMANIAM et al., 2002).

3.6 Características ópticas dos sensores orbitais e o futuro do sensoriamento remoto

Uma das primeiras revisões a debater as características mínimas para o sensoriamento remoto em ambientes aquáticos foi o primeiro Relatório do International Ocean-Colour Coordinating Group (IOCCG, 1998). Este relatório

deu ênfase em águas caso I, e discutiu quais são os parâmetros necessários para a aquisição de dados orbitais confiáveis. Neste discutiu-se a importância de bandas espectrais em regiões de interesse, (detecção da clorofila-a, CDOM e detrito), e no caso da clorofila-a, mostrou a necessidade de bandas tanto no azul como no vermelho, dependendo do ambiente. Outro fator importante referente a resolução espectral se refere a correção atmosférica, destacando a necessidade de bandas no infravermelho para uma correção mais precisa.

Um segundo aspecto destacado é a resolução radiométrica, que está relacionada a quão precisa é a medida feita por determinado sensor orbital. Esta precisão é estabelecida em função dos níveis de quantização que o sensor consegue distinguir, por exemplo, um sensor de 8 bits é capaz de discriminar 256 valores distintos. Além disto, a resolução radiométrica deve ser sensível o suficiente para permitir a detecção de diferentes concentrações dos COAs. Outros aspectos discutidos, são a necessidade de sensores com resolução temporal e espacial adequadas ao seu propósito, bem como a acessibilidade ao seu dado (tanto formato do arquivo quanto custo pela aquisição das imagens). Como conclusão, o trabalho mostra a necessidade de uma constelação de sensores orbitais e usa o sensor SeaWiFS como base para missões futuras, por possuir uma série de parâmetros adequados ao monitoramento de ambientes aquáticos. No entanto, essas conclusões estão baseadas em trabalhos em águas oceânicas.

Em 2012, 15 anos depois deste primeiro levantamento, a IOCCG publicou o seu 13º relatório (IOCCG, 2012), discutindo quais os requisitos mínimos para missões futuras. Apesar de não determinar um intervalo de valores para cada parâmetro, o trabalho discute diferentes aspectos dos sensores orbitais, mostrando quais são mais críticos e fazendo recomendações sobre como determinar as características ideais de acordo com o objeto de estudo. Entretanto, a ênfase se manteve para águas oceânicas, não discutindo sensores amplamente utilizados em águas interiores como a missão Landsat. Apesar disso, o trabalho mostra alguns aspectos relevantes para trabalhos que

visem estimar a concentração dos COAs de forma precisa, e demonstra como o sensoriamento remoto evoluiu ao longo do tempo. Entre elas, a resolução radiométrica deve estar entre 8 e 16 bits, a resolução espectral entre 2,5 e 100 nm e relação sinal ruído entre 50 e 1700. Considerando estes intervalos, nota-se que não existe um padrão nas missões passadas, e sim um constante avanço para a seleção de valores mais adequados aos objetivos propostos. Esta grande diversidade nas características ópticas dos sensores orbitais como resolução espacial, temporal, radiométrica e espectral, relação sinal ruído, tempo de imageamento, altitude, tamanho da cena, entre outras estão exemplificadas na Tabela 3.1

Tabela 3.1 Características gerais dos sensores orbitais apresentados neste trabalho.

	Landsat 8	MSI	OLCI
Nbits	12	12	12
Número de bandas	11	13	21
Largura de banda	20-180	15-180	7,5-40
SNR	150-350	50-172	152-2188
Desenvolvedor	NASA	ESA	ESA
Período da Missão	>2013	>2015	>2016

Fonte: Produção do autor.

3.7 Consolidando algoritmos semi-analíticos

Considerando toda a evolução previamente descrita, podemos notar que a maior parte dos algoritmos foi desenvolvido enfatizando a relação entre razões de banda e determinação de coeficientes, auxiliando a estimativa destes parâmetros em ambientes naturais. Entretanto, identifica-se a necessidade de desenvolvimento de algoritmos com embasamento teórico mais robusto, refletindo as reais interações entre a radiação eletromagnética e os corpos d'água. Idealmente, os parâmetros dos algoritmos devem descrever todo o

processo de interação entre os COAs e as propriedades ópticas dos meios, entretanto esta abordagem ainda não é totalmente possível. Considerando as duas vertentes, algoritmos semi-analíticos visam auxiliar o entendimento dos processos de interação por meio da combinação de parcelas teóricas e empíricas, e este capítulo visa discutir algumas abordagens para o desenvolvimento de algoritmos semi-analíticos, destacando suas limitações e aplicações.

3.7.1 Base teórica dos algoritmos semi-analíticos

Dentre os algoritmos semi-analíticos descritos na literatura, tanto o embasamento teórico quanto as simulações numéricas da equação da transferência radiativa, partem do pressuposto de que a r_{rs} varia em função dos coeficientes de absorção e espalhamento a e b , e que esta relação pode ser ajustada em função de dois parâmetros (g_1 e g_2) (Equação 3.9) (GORDON et al., 1988). Da mesma forma r_{rs} (reflectância de sensoriamento remoto em sub superfície) pode ser estimada a partir da R_{rs} (Equação 3.12), com um erro de 2 a 10%.

$$r_{rs} = \sum_{i=1}^2 g_i \left(\frac{b_b(\lambda)}{a_t(\lambda) + b_b(\lambda)} \right)^i (sr^{-1}) \quad 3.9$$

$$r_{rs}(\lambda) = g_1 u(\lambda) + g_2 [u(\lambda)]^2 (sr^{-1}) \quad 3.10$$

$$u(\lambda) = \frac{b_b(\lambda)}{a(\lambda) + b_b(\lambda)} = \frac{-g_1 + \sqrt{g_1^2 + 4g_2 \cdot r_{rs}(\lambda)}}{2g_2} \quad 3.11$$

$$r_{rs}(\lambda) = \frac{R_{rs}(\lambda)}{0,52 + 1,7R_{rs}(\lambda)} (sr^{-1}) \quad 3.12$$

Os fatores de proporcionalidade g_1 e g_2 , geralmente variam entre 0,084 a 0,15 sr^{-1} para a radiância no nadir, e dependem de como a parcela da radiação eletromagnética (REM) retroespalhada se relaciona com o coeficiente de retroespalhamento. Assim, estes dependem da função de espalhamento volumétrico entre 90 e 180° e da distribuição do campo de luz subaquático. Desta forma, a maior parte dos efeitos direcionais de equação de transferência radiativa está contida nestes parâmetros (GORDON et al., 1988). A Equação 3.9 é a etapa inicial de grande parte dos algoritmos semi-analíticos, e a obtenção destes parâmetros de forma precisa é essencial. Entretanto, em alguns casos, utilizam-se valores pré-estabelecidos na literatura para determinados ambientes. As constantes estabelecidas na Equação 3.12 foram determinadas em Gordon et al. (1988)

Para a estimativa dos espectros de absorção e espalhamento dos COAs da água, estes são subdivididos de acordo com os seus comportamentos teóricos e funções consolidadas na literatura, e podem ser descritos da seguinte forma: (Equações 3.13, 3.14 e 3.15).

$$b_{bp}(\lambda) = b_{bp}(\lambda_0) \left(\frac{\lambda}{\lambda_0} \right)^{-Y} (m^{-1}) \quad 3.13$$

Onde $b_{bp}(\lambda_0)$ é o coeficiente de retroespalhamento para o comprimento de onda de referência (λ_0), e Y é a inclinação da curva.

$$a_{dg}(\lambda) = a_{dg}(\lambda_0) e^{-S(\lambda-\lambda_0)} (m^{-1}) \quad 3.14$$

Onde $a_{dg}(\lambda_0)$ é o coeficiente de absorção do detrito+CDOM para o comprimento de onda de referência (λ_0), e S é a inclinação da curva.

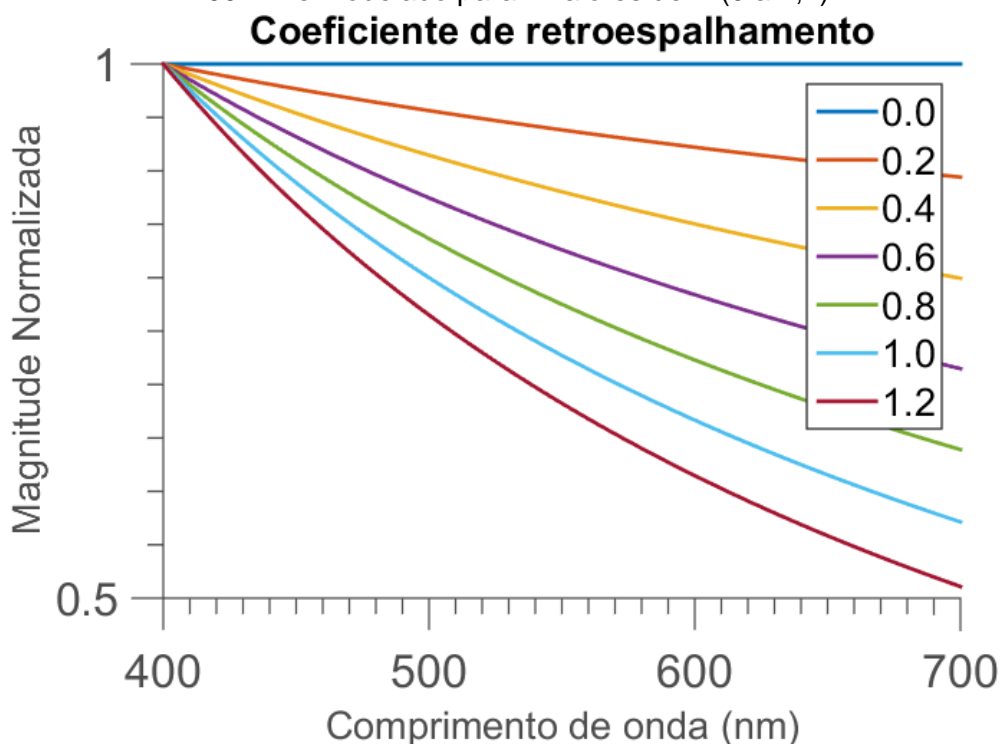
$$a_{phy}(\lambda) = Chl. a_{phy}^*(\lambda) (m^{-1}) \quad 3.15$$

Onde $a_{phy}^*(\lambda)$ é o coeficiente de absorção específico do fitoplâncton para cada comprimento de onda (λ) e Chl é a concentração de clorofila-a.

As equações consideram que $b_{bp}(\lambda)$ decai segundo o expoente Y de forma constante ao longo dos comprimentos de onda, e que este pode ser

simplificado através de uma equação de potência. Nessa abordagem, dois parâmetros de entrada são necessários, $b_{bp}(\lambda_0)$ e Y . $b_{bp}(\lambda_0)$ pode ser obtido previamente por meio de relações empíricas com R_{rs} , ou através de métodos para solução de sistemas de equações e Y é pré-selecionada de acordo com a metodologia adotada pelo algoritmo. Na Figura 3.2 podemos observar espectros teóricos de b_{bp} e seu comportamento quando alteramos o valor de Y .

Figura 3.2 Coeficiente de retrospalhamento do material particulado normalizado em 400 nm e modelado para 7 valores de Y (0 a 1,2).




Fonte: Produção do autor.

A Equação 3.14 descreve a parcela referente ao coeficiente de absorção do CDOM e detrito, partindo do pressuposto de que este pode ser simplificado através de uma equação exponencial. Assim como na Equação 3.13, são necessários dois parâmetros de entrada, $a_{dg}(\lambda_0)$ e S . O $a_{dg}(\lambda_0)$ é obtido durante a solução dos sistemas de equações e S pré-selecionada de acordo com a metodologia adotada pelo algoritmo. Desta forma, podemos destacar que tanto Y quanto S são selecionados de forma semelhante, podendo utilizar

bancos de dados para a obtenção de um valor médio, ou estabelecer limiares e através de simulações selecionar o valor mais adequado. Na Figura 3.3 podemos observar espectros teóricos de a_{dg} e seu comportamento quando alteramos o valor de S .

Figura 3.3 Coeficiente de absorção do CDOM + detrito normalizado em 440 nm e modelado para 7 valores de S (0 a 0,03).



Fonte: Produção do autor.

Por fim, a Equação 3.14 descreve o coeficiente de absorção do fitoplâncton como uma função que depende unicamente da concentração de clorofila-a e do coeficiente de absorção específico do fitoplâncton (o qual considera qual seria o espectro de absorção para 1 mg/m^3 de Chl-a). Este é obtido através da normalização dos coeficientes de absorção do fitoplâncton pela sua concentração de clorofila-a (em laboratório). Desta forma, $a_{phy}^*(\lambda)$ é um dos parâmetros de entrada e normalmente corresponde a um espectro médio para as comunidades fitoplanctônicas da região de interesse. Entretanto, alguns algoritmos estimam este espectro como será mostrado na sessão 3.7.3.

No presente trabalho, os algoritmos semi-analíticos foram divididos em duas categorias: estratégias bottom-up e top-down (MUOW et al., 2015). As duas estratégias buscam explorar a dependência das IOPs com os espectros de

absorção e retroespalhamento dos seus três componentes principais (CDOM+detrito+fitoplâncton). Os algoritmos bottom-up necessitam de algoritmos bio-ópticos de todos os COAs durante o seu processamento e derivam tanto as componentes individuais quanto o total simultaneamente (e.g. SOA - Spectral Optimization Algorithm e LMI - Linear Matrix Inversion). Já os algoritmos top-down não necessitam de algoritmos bio-ópticos para todos os componentes durante o processo de inversão, e em vez disso, estimam os coeficientes de absorção e retroespalhamento totais e separam estes em função das suas frações atribuídas aos COAs (e.g. QAA e PML (Plimouth Marine Laboratory)). Como resultado, um algoritmo bottom-up não obtém o espectro dos COAs de forma independente, como é o caso de algoritmos top-down.

Outra diferença é o processo de calibração destes algoritmos. No caso dos top-down, esta ocorre em diversas etapas, correlacionando a r_{rs} ou R_{rs} com a variável de interesse. No caso de algoritmos bottom-up, estes estabelecem constantes, como as taxas de inclinação Y e S, e o a_{phy}^* . A etapa de calibração consiste na utilização de determinado estimador de erro e de métodos de solução de equações para a seleção de cada espectro. Desta forma, na estratégia bottom-up, a etapa de calibração consiste da utilização das constantes que mais se adequam a área de interesse, enquanto que no caso da estratégia top-down, esta é feita por meio da correlação com os dados *in situ*.

3.7.2 Estratégias bottom-up

3.7.2.1 Spectral Optimization Algorithm (SOA)

Uma das metodologias para o desenvolvimento da estratégia bottom-up é a SOA, utilizada pelos algoritmos GSM (Garver-Siegel-Maritorena - inicialmente desenvolvido por Garver e Siegel (1997) e aprimorado em Maritorena et al. (2002) e Hyperspectral Optimization Process Exemplar - HOPE (LEE, 1994; LEE et al.,1999). O SOA foi inicialmente idealizada no começo da década de 90 (DOERFFER; FISHER, 1994) para o sensor CZCS, mas devido à alta

demanda computacional para a época, o seu uso era limitado. Entretanto, com o atual avanço computacional, é possível implementar este procedimento em dados orbitais de forma operacional.

Assume-se uma forma espectral (autovetor) para cada COA e estima-se a magnitude (autovalor) destes autovetores, reproduzindo o espectro do alvo de forma mais precisa. Parte-se do pressuposto que não existe correlação entre os COAs e que este pode ser representado por um único espectro de referência, o que pode induzir erros na R_{rs} final.

A metodologia assume que para um corpo de água sem efeito de fundo, a R_{rs} pode ser modelada em função dos coeficientes de absorção e retroespalhamento totais, de forma que:

$$R_{rs} = fun(a(\lambda), b_b(\lambda)) (sr^{-1}) \quad 3.16$$

E sua função de erro (definida como δR_{rs}) pode ser estimada a partir de (LEE et al, 2011):

$$\delta R_{rs} = \frac{\sqrt{\int_{\lambda_1}^{\lambda_2} (R_{rs}(\lambda) - \overline{R_{rs}(\lambda)})^2 d\lambda}}{\int_{\lambda_1}^{\lambda_2} R_{rs}(\lambda) d\lambda} \quad 3.17$$

onde $\int_{\lambda_1}^{\lambda_2}$ representa a média da magnitude entre os comprimentos de onda λ_1 e λ_2 , $R_{rs}(\lambda)$ é o espectro medido e $\overline{R_{rs}(\lambda)}$ é o espectro modelado.

As funções definidas para cada COAs podem ser agrupadas da seguinte forma:

$$a_{phy}(\lambda) = \chi_1 \cdot a_{ph}^*(\lambda) (m^{-1}) \quad 3.18$$

$$a_{dg}(\lambda) = \chi_2 \cdot \tilde{a}_{dg}(\lambda) (m^{-1}) \quad 3.19$$

$$b_{bp}(\lambda) = \chi_3 \cdot \tilde{b}_{bp}(\lambda) (m^{-1}) \quad 3.20$$

Onde χ_1 é a concentração de clorofila-a, χ_2 é o a_{dg} para o comprimento de onda de referência e χ_3 é o b_{bp} para o comprimento de onda de referência,

$a_{ph}^*(\lambda)$ é o espectro de absorção específico do fitoplâncton e \tilde{a}_{dg} e \tilde{b}_{bp} são modelos espectrais determinados baseados nas medidas *in situ*.

Desta forma, $\overline{R_{rs}(\lambda)}$ se torna uma função de χ_i , e δR_{rs} pode ser escrita da seguinte forma:

$$\delta R_{rs} = fun(\chi_i) \quad 3.21$$

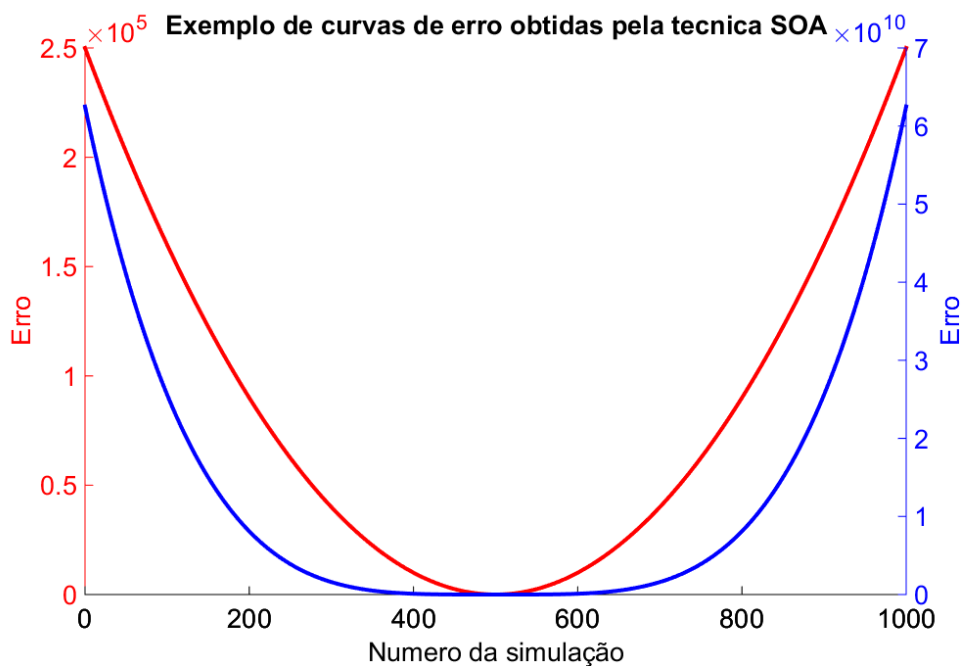
Para determinado $\overline{R_{rs}(\lambda)}$, os valores de χ_i são ótimos quando δR_{rs} é mínimo (δ_{Rrs}^{min}), ou seja, o processo de otimização correlaciona os COAs com a R_{rs} buscando a solução mais provável.

Apesar das pequenas diferenças no algoritmo de transição de IOP para AOP e da função de erro, a maior incerteza no algoritmo está atribuída aos espectros dos coeficientes de absorção e retroespalhamento assumidos para os COAs (LEE et al, 2011). Assim, durante o processo de otimização, diferentes algoritmos SOA podem gerar diferentes δ_{Rrs}^{min} . Da mesma forma, é possível encontrar δ_{Rrs}^{min} idênticos, uma vez que a $\overline{R_{rs}(\lambda)}$ pode ser semelhante a $R_{rs}(\lambda)$ em diferentes comprimentos de onda. Este comportamento ocorre pelo fato do δ_{Rrs}^{min} ser uma solução matemática, e desta forma, diferentes soluções matemáticas podem gerar o mesmo valor de δ_{Rrs}^{min} . Devido a esta característica, os dados obtidos por sensoriamento remoto através dos algoritmos SOA são primariamente dependentes dos espectros utilizados para descrever os coeficientes de absorção e espalhamento.

Quando comparamos com soluções algébricas, as quais, são soluções explícitas, observamos que no caso do SOA, não existem soluções explícitas, sendo necessário a determinação de um mínimo global para δR_{rs} (Figura 3.4). Deve-se levar em conta que o valor de δR_{rs} é estimado em um processo de otimização que busca valores mínimos, e que este processo pode resultar em duas curvas distintas para a magnitude de δR_{rs} . No caso de curvas em formato de U (Figura 3.4), notamos que R_{rs} varia pouco para diferentes valores de χ_i , sendo necessário um maior número de simulações para encontrar um mínimo local. Já no caso de curvas em formato de V, a R_{rs} varia de forma mais

clara entre diferentes valores de χ_i , e o tempo de processamento será menor com resultados serão menos ambíguos.

Figura 3.4 Exemplo de curvas obtidas pela técnica SOA, evidenciando a forma em U (em vermelho) e V (em azul)



Fonte: Produção do autor.

Para exemplificar o uso da SOA em uma abordagem semi-analítica, o algoritmo selecionado para descrever as suas características ao longo dessa seção foi o GSM (GARVER; SIEGEL 1997; MARITORENA et al., 2002).

O GSM assume a relação quadrática entre r_{rs} e os coeficientes de absorção e espalhamento descritos em Gordon et al. (1988) (Equação 3.9), e estabelece que os fatores de proporcionalidade g_1 e g_2 tem valores fixos (0,0949 e 0,0794 respectivamente). Por fim, o GSM assume as Equações 3.13, 3.14 e 3.15 para os COAs. Desta forma, tem-se como incógnita a magnitude de $Chl-a$, $a_{dg}(443)$ e $b_{bp}(443)$, enquanto que Y (Equação 3.13), S (Equação 3.14) e a_{pny}^* são obtidos a partir de dados *in situ* ou simulados.

Desta forma, $\chi_{1\sim 3}$ são as três variáveis escalares (autovalores) que serão derivadas de um R_{rs} medido, através do SOA. Enquanto que $a_{phy}^*(\lambda)$, $\tilde{a}_{dg}(\lambda)$ e $\tilde{b}_{bp}(\lambda)$ são modelos espectrais (autovetores) determinados através de medidas *in situ*.

Os parâmetros de inclinação de curva Y e S variam de acordo com o ambiente. Entretanto, para o GSM, S é fixada em 0,0206 e Y em 1,03. Já no caso de $a_{phy}^*(\lambda)$, este é constante para águas oceânicas.

Para todas as soluções numéricas, é necessário estabelecer os valores iniciais de χ_i . Estes são estabelecidos da seguinte forma:

$$\chi_1 = 0,05 \left(\frac{R_{rs}(440)}{R_{rs}(555)} \right)^{-0,5} (mg.m^{-3}) \quad 3.22$$

$$\chi_1 = \chi_2 (m^{-1}) \quad 3.23$$

$$\chi_3 = 20(0,06 + 0,3\chi_1)R_{rs}(555)(m^{-1}) \quad 3.24$$

Por fim, o algoritmo assume um critério de máximos e mínimos de valores aceitáveis, e estes são:

$$0,02 < \chi_1 < 100 mg.m^{-3};$$

$$0,002 < \chi_2 < 5 m^{-1};$$

$$0,0001 < \chi_3 < 0,5 m^{-1};$$

A implementação da rotina de processamento desta simulação pode ser feita de diferentes formas (e.g. Matlab, R, Excell) sendo um algoritmo de fácil aplicação. Entretanto, podemos notar algumas deficiências ao aplicarmos estes parâmetros em águas interiores. A primeira grande deficiência se refere ao uso de valores fixos de Y , S e $a_{phy}^*(\lambda)$ estabelecidos em águas oceânicas. A segunda se refere à variabilidade destes valores nestes ambientes, uma vez que o algoritmo parte do pressuposto que estes não variam no tempo ou espaço.

3.7.3 Estratégias top-down

3.7.3.1 Quasi-Analytical Algorithm (QAA)

Uma das abordagens metodológica para desenvolvimento da estratégia top-down foi proposta por Lee et al. (2002), atualizada em Lee et al. (2007) e atualmente está na versão 6 (atualização não publicada). A inovação nesta abordagem se refere à estimativa das IOPs de forma independente (ao contrário dos algoritmos previamente descritos). Para simplificar o entendimento do QAA, este pode ser dividido em duas etapas. A primeira corresponde a estimativa dos coeficientes de absorção e retroespalhamento totais, e a segunda a decomposição dos coeficientes em função dos seus componentes.

Assim como na abordagem anterior, o QAA utiliza as equações de Gordon et al. (1988) e assume que r_{rs} varia em função de u (Equação 3.11). Para as constantes g_1 e g_2 os valores utilizados são 0,089 e 0,125, ajustados para uma maior diversidade de ambientes (águas caso I e II). A primeira etapa do processamento se refere a estimativa do coeficiente de absorção total para um único comprimento de onda, utilizados como referência (λ_0). O conceito da seleção do comprimento de onda de referência é determinar em qual comprimento de onda a_t é dominado por a_w . Por exemplo, em águas caso I, é possível observar este padrão nos comprimentos de onda próximos de 555 nm, enquanto que para águas caso II, esta seleção é comumente feita na região do infravermelho próximo, próximo de 708 nm. Na primeira versão do algoritmo QAA, esta etapa é feita da seguinte forma (LEE et al., 2002):

$$\begin{aligned} a_t(555) &= 0,0596 + 0,2[a_t(440) - 0,01] (m^{-1}); & 3.25 \\ a_t(440) &= \exp(-2,0 - 1,4p + 0,2p^2) (m^{-1}); \\ p &= \ln [r_{rs}(440)/r_{rs}(555)] \end{aligned}$$

onde $a_t(555)$ e $a_t(440)$ se referem ao coeficiente de absorção total para o respectivo comprimento de onda e $r_{rs}(440)$ e $r_{rs}(555)$ se referem a reflectância de sensoriamento remoto abaixo da água.

Esta primeira etapa foi inicialmente calibrada e implementada em águas oceânicas (LEE et al., 2007; LEE et al., 2009; LEE et al., 2014), e em diversos trabalhos, os autores adaptaram os comprimentos de onda de referência e a equação de acordo com a área de estudo (MISHRA et al., 2013; WATANABE et al., 2016). Para exemplificar estas variações, a Tabela 3.2 descreve a primeira etapa para cada trabalho citado anteriormente.

Tabela 3.2 Exemplo da evolução do algoritmo QAA ao longo do tempo, contendo as adaptações propostas por cada autor para a primeira etapa de calibração do algoritmo

Referência	Equações teórica	
Lee 2007	$\chi = \log \left(\frac{r_{rs}(443) + r_{rs}(490)}{r_{rs}(\lambda_0) + 2 \frac{r_{rs}(640)}{r_{rs}(490)} r_{rs}(640)} \right);$ $a_t(\lambda_0) = a_w(\lambda_0) + 10^{h_0 + h_1 \chi + h_2 \chi^2} (m^{-1})$ $h_0 \sim h_2 = -1,226; -1,214 \text{ e } -0,350$	3.26
Lee 2009	$\chi = \log \left(\frac{r_{rs}(443) + r_{rs}(490)}{r_{rs}(\lambda_0) + 5 \frac{r_{rs}(667)}{r_{rs}(490)} r_{rs}(667)} \right);$ $h_0 \sim h_2 = -1,146; -1,366 \text{ e } -0,469$	3.27
Lee 2014	$\chi = \log \left(\frac{r_{rs}(443) + r_{rs}(490)}{r_{rs}(\lambda_0) + 5 \frac{r_{rs}(670)}{r_{rs}(490)} r_{rs}(670)} \right);$ $h_0 \sim h_2 = -1,1459, \quad -1,3658 \text{ e } -0,46927$	3.28
Mishra 2013	$\chi = \log \left(\frac{v(443) + r_{rs}(620)}{r_{rs}(\lambda_0) + 0,005 \frac{r_{rs}(620)}{r_{rs}(443)} r_{rs}(620)} \right);$ $h_0 \sim h_2 = \text{são } -0,8125, \quad -2,3404 \text{ e } 1,24$	3.29
Watanabe 2016	$\chi = \log \left(\frac{r_{rs}(443) + r_{rs}(665)}{r_{rs}(\lambda_0) + 5 \frac{r_{rs}(620)}{r_{rs}(443)} r_{rs}(620)} \right);$ $h_0 \sim h_2 = -0,7702, \quad 0,0999 \text{ e } 0,0566$	3.30

Em geral, a primeira evolução do algoritmo QAA entre Lee (2002) e Lee (2007) foi a seleção de 5 bandas de r_{rs} para o cálculo de $a_t(\lambda_0)$, em vez das 2 bandas utilizadas previamente (Equação 3.25), aumentando a sensibilidade do

algoritmo ao espectro de entrada. A segunda evolução se refere a seleção do comprimento de onda de referência, visando minimizar a influência dos COAs no espectro de r_{rs} , utilizando bandas próximas de 555 para águas oceânicas, e se deslocando em direção ao infravermelho para águas opticamente complexas (buscando reduzir a contribuição por CDOM e detrito).

O segundo passo desta etapa se refere à estimativa de b_{bp} , no mesmo comprimento de onda da absorção total, feita da seguinte forma:

$$b_{bp}(\lambda_0) = \frac{u(\lambda_0) \cdot a(\lambda_0)}{1 - u(\lambda_0)} - b_{bw}(\lambda_0)(m^{-1}) \quad 3.31$$

Considerando que $a(\lambda_0)$ pode ser determinado pela equação (3.25), $u(\lambda_0)$ determinado pela equação (11) e b_{bw} é conhecido, b_{bp} pode ser obtido de forma simples pela equação 3.31. Conhecendo b_{bp} para um comprimento de onda de referência, pode-se determiná-lo para os demais comprimentos de onda:

$$b_b(\lambda) = b_{bp}(\lambda_0) \left(\frac{\lambda}{\lambda_0} \right)^{-Y} + b_{bw}(\lambda)(m^{-1}) \quad 3.32$$

Onde Y é a inclinação da curva potencial, sendo determinado por:

$$Y = 2 \left(1 - 1,2 e^{(-0,9 \frac{rrs(443)}{rrs(\lambda_0)})} \right) \quad 3.33$$

Para esta etapa do processamento, Yang et al. (2013), sugerem uma modificação na equação para águas túrbidas, assumindo que Y possui um comportamento logarítmico e utilizando um polinômio de segunda ordem. A equação é descrita da seguinte forma:

$$Y = -372,99 \left[\log \left(\frac{u(750)}{u(780)} \right) \right]^2 + 37,286 \left[\log \left(\frac{u(750)}{u(780)} \right) \right] + 0,84 \quad 3.34$$

Com a magnitude de b_b para cada comprimento de onda (estimado a partir das equações 3.32 ou 3.34) pode-se isolar $a(\lambda)$, na Equação 3.31, obtendo o coeficiente de absorção total espectral da seguinte forma:

$$a_t(\lambda) = \frac{(1 - u(\lambda))b_b(\lambda)}{u(\lambda)} (m^{-1}) \quad 3.35$$

Como podemos notar, o algoritmo QAA segue uma abordagem analítica e busca minimizar o uso de associações empíricas. Entretanto tanto $a(555)$ (Equação 3.25) quanto Y (Equação 3.33) são obtidos de forma empírica. A primeira vantagem deste algoritmo pode ser notada pela obtenção de $a_t(\lambda)$ e $b_b(\lambda)$ durante a primeira parte do processamento.

A segunda etapa deste algoritmo se refere à decomposição dos coeficientes de absorção, utilizando como referência $a(\lambda_1)$ e $a(\lambda_2)$. Durante essa etapa, é necessário estimar 2 parâmetros, ζ e ξ :

$$\zeta = \frac{a_{phy}(\lambda_1)}{a_{phy}(\lambda_2)} = 0,71 + \frac{0,06}{0,8 + r_{rs}(\lambda_3)/r_{rs}(\lambda_4)} \quad 3.36$$

$$\xi = \frac{a_{dg}(\lambda_1)}{a_{dg}(\lambda_2)} = e^{[S(\lambda_2 - \lambda_1)]} \quad 3.37$$

Onde ζ está relacionada à absorção pelo fitoplâncton nestes comprimentos de onda, e ξ está relacionada à absorção pela matéria orgânica nestes comprimentos de onda. Os comprimentos de onda λ_1 , λ_2 , λ_3 e λ_4 variam de acordo com o algoritmo testado, mas estão comumente associados a regiões no espectro onde é possível identificar a influência de a_{phy} e a_{dg} . Por exemplo, comprimentos de onda próximos de 440 nm ou 665 nm.

Assim, podemos discriminar o coeficiente de absorção total da seguinte forma:

$$a_t(\lambda_1) = a_w(\lambda_1) + \zeta a_{phy}(\lambda_2) + \xi a_{dg}(\lambda_2) (m^{-1}) \quad 3.38$$

$$a_{dg}(\lambda_2) = \frac{[a_t(\lambda_1) - \zeta a_t(\lambda_2)]}{\xi - \zeta} - \frac{[a_w(\lambda_1) - \zeta a_w(\lambda_2)]}{\xi - \zeta} (m^{-1}) \quad 3.39$$

$$a_t(\lambda_2) = a_w(\lambda_2) + a_{phy}(\lambda_2) + a_{dg}(\lambda_2)(m^{-1}) \quad 3.40$$

$$a_{phy}(\lambda_2) = a_t(\lambda_2) - a_w(\lambda_2) - a_{dg}(\lambda_2)(m^{-1}) \quad 3.41$$

Podemos notar que a estimativa de a_{phy} é feita de forma semelhante a abordagens laboratoriais, estimando a_{dg} e a_t e obtendo a_{phy} 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, algoritmos que seguem essa abordagem, como o QAA, podem gerar resultados mais precisos. Além disso, ela é matematicamente simples e transparente, permitindo adaptá-la em função do sensor selecionado e área de estudo. Outro aspecto importante se refere ao coeficiente de retroespalhamento, uma vez que é possível ajustar os parâmetros de acordo com a área de estudo, não sendo necessário assumir uma única inclinação.

4 MATERIAIS E MÉTODOS

4.1 Área de Estudo

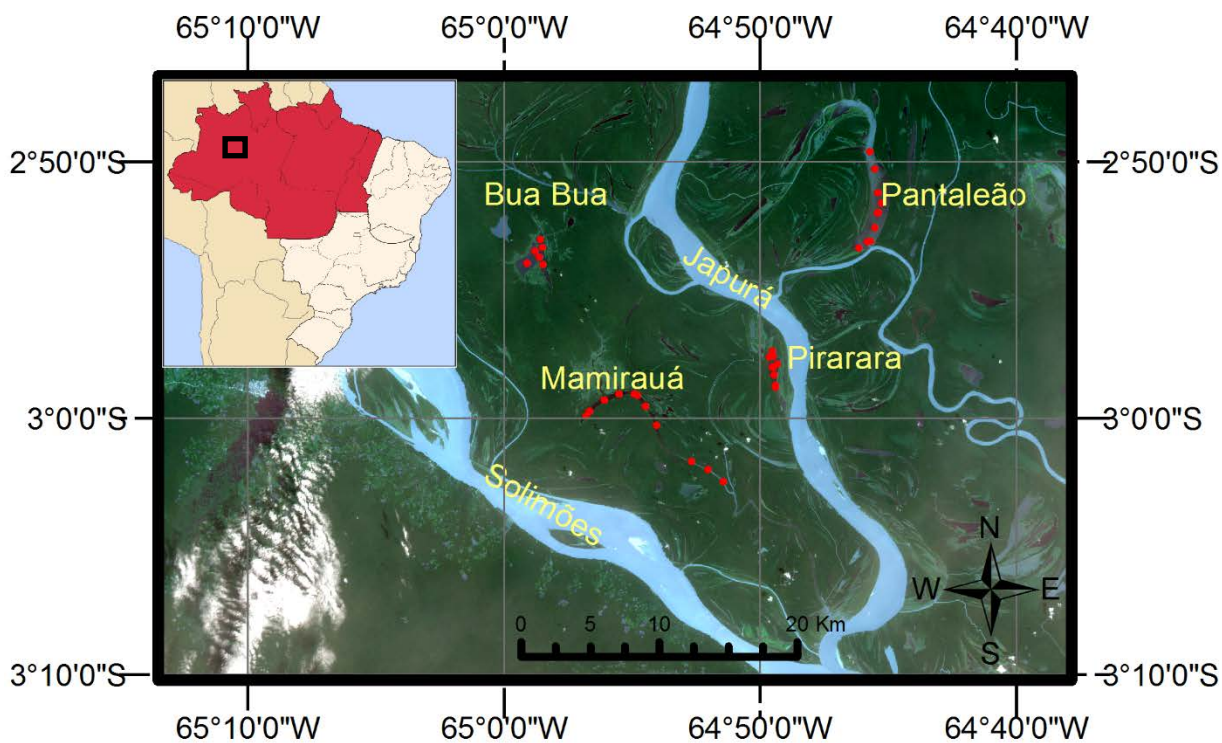
A área de estudo é formada por quatro lagos localizados na RDSM (Figura 4.1). Esta é a primeira e maior Reserva de Desenvolvimento Sustentável localizada no Brasil, dedicada exclusivamente à proteção de planícies de inundação na Amazônia e possui aproximadamente 1.123.000 hectares. Esta unidade de conservação foi criada pelo estado do Amazonas em 1996 e é uma das unidades brasileiras representadas na United Nations Ramsar Convention (<http://www.ramsar.org/>) (QUEIROZ, 2005). Consiste de uma planície de inundação pristina inundada por águas brancas, ricas em sedimento, localizada na confluência dos rios Japurá e Solimões, formando um mosaico complexo de florestas sazonalmente inundadas, lagos e canais. A composição óptica dos lagos muda constantemente devido ao transporte de sedimentos e matéria orgânica, causado pela variação anual do nível da água, que atinge até 12 m. Além disso, o pulso de inundação muda a proporção dos componentes particulados e dissolvidos na água, por conta da variação nas suas propriedades físico-químicas. Consequentemente, isso afeta o ecossistema por onde estas águas circulam.

A cheia inicia em maio e termina em julho, enquanto que a seca ocorre entre setembro e novembro. A enchente começa em janeiro e água começa a vazar em setembro. O pulso de inundação tem um padrão anual monomodal, e as mudanças no nível da água são devido ao degelo nos Andes e precipitação na região pré-andeana e na bacia do Amazonas (RAMALHO et al., 2009). O plano de gestão da RDSM considera a presença de mais de 5000 lagos na área, os quais variam em forma (alongado, circular e complexo), tamanho (de 1,5 a 900 ha) e conexão com os principais rios e canais, os quais influenciam no tempo de residência da água nos lagos e na conectividade do fluxo da água durante a seca.

O critério para a seleção dos lagos incluiu o seu potencial para a análise por sensoriamento remoto (tamanho e forma dos lagos), assim como

acessibilidade ao longo do ano (largura e profundidade dos canais). Os pontos de amostragem foram selecionados para incluir a maior variabilidade possível na cor da água nos lagos. Baseado nestas restrições, os lagos Bua-Bua (forma triangular, 1km x 2,1 km), Mamirauá (forma alongada, 0,4 km x 4 km), Pirarara (forma de losango, 0,9 km x 2,7 km), e Pantaleão (forma retangular, 1,5 km x 6 km) foram selecionados. (Figura 4.1).

Figura 4.1 Mapa da área de estudo. Lagos em vermelho representam os lagos selecionados. Após o campo preliminar realizado em 2015, os 4 lagos centrais foram selecionados. Buabua a Noroeste, Pantaleão a Nordeste, Mamirauá a Sudoeste e Pirarara a Sudeste em relação ao centro da imagem.



Fonte: Produção do autor.

4.2 Estratégias de amostragem

Para o estudo dos processos bio-ópticos nos lagos da RDSM, 5 campanhas de campo foram realizadas, sendo duas durante a enchente (março e abril/2016) e três durante o início da vazante (julho/2015 e julho e agosto/2016).

A seleção e verificação da viabilidade de desenvolvimento do trabalho para estes lagos foi realizada durante a campanha de julho de 2015, em uma campanha de reconhecimento da área de estudo. Cada campanha subsequente durou aproximadamente 8 dias com 6 estações amostrais para cada lago, totalizando 102 estações amostrais. O intervalo entre as duas campanhas realizadas em cada fase do pulso foi de aproximadamente 10 dias. Inicialmente, o propósito deste intervalo foi avaliar se é possível identificar mudanças nas propriedades ópticas dos lagos da RDSM durante uma mesma fase do pulso.

O conjunto de dados coletados pode ser dividido em dados medidos em laboratório e *in situ*:

- Laboratório: Concentração de clorofila-a da camada superficial da água, concentração de total de sólidos suspensos (TSS) e carbono orgânico e inorgânico dissolvido (DOC e DIC, respectivamente). Coeficiente de absorção da CDOM e material particulado (subdividido em fitoplâncton e detrito) da camada superficial da água (~10 cm), medido em laboratório no espectrofotômetro Shimadzu UV-2600.
- *in situ*: Radiância e irradiância acima d'água, radiância difusa do céu e perfis verticais de radiância e irradiância descendente e ascendente na coluna d'água, medido pelo radiômetro RAMSES-TRIOS (abreviado ao longo do texto como TRIOS (TRIOS, 2015). Coeficiente de absorção e atenuação, medidos pelo AC-S (WETLABS, 2009). Coeficiente de retroespalhamento, medido pelo HydroScat (HYDRO-OPTICS, BIOLOGY AND INSTRUMENTATION LABORATORIES, 2010). Perfis verticais de condutividade, temperatura e pressão, medidos pelo CTD.

4.2.1.1 Análise Laboratorial

Os filtros com material para as determinações das concentrações de clorofila-a e do material em suspensão (TSS), e para a determinação dos coeficientes de absorção do material particulado (subdividido em fitoplâncton e detrito) foram mantidos congelados até o momento das análises em laboratório. Da mesma forma, os frascos com água para determinação das concentrações de DIC e DOC e dos coeficientes de absorção do CDOM também foram mantidos resfriados.

Para a determinação da concentração de Clorofila-a, e coeficiente de absorção do material particulado, as amostras de água foram filtradas em filtros Whatman GF/F (0,7 μm), enquanto que os sólidos totais em suspensão, e suas parcelas orgânicas e inorgânicas, foram filtrados em filtros Whatman GF/C (1,2 μm), ambos com 45 mm de diâmetro. Para a determinação do coeficiente de absorção do CDOM, as amostras de água foram filtradas em filtros Whatman de nylon (0,22 μm) de 45 mm de diâmetro.

Para a clorofila-a, a metodologia adotada foi proposta por Wetzel (2001), utilizando acetona 90% e DMSO (Dimetilsulfóxido) com razão 6:4 para a extração do pigmento. Para a estimativa dos coeficientes de absorção do material particulado, a metodologia selecionada foi proposta por Tassan e Ferrari (1995a, 1998, 2002), denominado método T-R, utilizando uma esfera integradora acoplada ao espectrofotômetro. A estimativa do coeficiente de absorção da CDOM seguiu a metodologia de Tiltstone et al. (2002). Em ambos os casos, foi utilizado um espectrofotômetro UV-2600 da Shimadzu. Para a absorbância do CDOM, a medida foi feita de forma direta, utilizando uma cubeta de quartzo de 10 cm. Para o material particulado, a absorbância foi calculada a partir das medidas de reflectância e transmitância, utilizando uma esfera integradora. A descrição de cada método pode ser observada abaixo:

4.2.1.1.1 Absorção do CDOM

Para remover o efeito da absorção da água, a água deionizada (DI) foi utilizada como linha de base das leituras. Para reduzir as incertezas atribuídas a variações no aparelho ao longo do tempo e limpeza da cubeta, uma medida de água deionizada (branco) foi feita antes e depois de cada amostra in situ. Desta forma, o primeiro fator de correção se refere a subtração do valor do branco de cada amostra e a conversão de absorbância (OD) para coeficiente de absorção seguiu a seguinte equação:

$$a_{CDOM} = \frac{2,303(OD_{med} - OD_{br})}{l} (m^{-1}) \quad 4.1$$

Onde l é o caminho óptico da cubeta (0,1 m), OD_{med} é a densidade óptica medida de cada amostra e OD_{br} é a OD da água DI referente a cada amostra.

Em geral, assume-se que a_{CDOM} tende a zero na região do infravermelho, sendo necessário aplicar um fator de correção para remover eventuais desvios durante a medição. Esta correção foi inicialmente proposta para águas oceânicas, e em águas interiores este valor é ligeiramente acima de 0. Entretanto, considerando que o impacto desta correção nos comprimentos de onda mais curtos é pequeno, neste estudo foi mantida esta metodologia. Este fator de correção corresponde ao valor médio de a_{CDOM} entre 750 e 800 nm, sendo aplicado da seguinte forma:

$$a_{CDOM}(\lambda) = a_{CDOM}(\lambda) - \int_{750}^{800} a_{CDOM}(m^{-1}) \quad 4.2$$

Por fim, um último passo se refere ao ajuste da medida de CDOM a uma curva de decaimento exponencial. Neste caso, 440 nm é utilizado como referência, e um decaimento exponencial é assumido entre 380 e 600 nm. A partir do slope (decaimento), obtido pelo ajuste, uma nova curva é gerada utilizando o valor medido em 440 nm e o slope obtido:

$$a_{CDOM}(\lambda) = a_{CDOM}(\lambda_{ref}) \cdot e^{-S(\lambda - \lambda_{ref})} (m^{-1}) \quad 4.3$$

Onde $a_{CDOM}(\lambda_{ref})$ é o coeficiente de absorção do CDOM em 440 nm e S é o slope da curva exponencial modelada.

4.2.1.1.2 Absorção do material particulado

Os coeficientes de absorção do material particulado, fitoplâncton e detrito foram determinados em 2 etapas. Primeiramente, estima-se o coeficiente de absorção do material particulado total e posteriormente do detrito por meio da despigmentação do filtro.

Devido às propriedades ópticas dos filtros GF/F, filtros de 45 mm são mais indicados do que os de 25 mm, uma vez que, em geral, são mais homogêneos (Tassan; Ferrari, 2002). Apesar de ser considerado mais trabalhoso, assume-se que o método T-R é o mais preciso.

A primeira etapa consiste na medição do valor de reflectância e transmitância de cada amostra, utilizando uma medida do ar como linha de base e filtros novos e umedecidos por 1 hora como "branco" (Equação 4.4, 4.5 e 4.6). Para a segunda etapa, é feita a despigmentação dos filtros, utilizando 6 gotas de NaClO (10%), deixando agir por até 20min. A verificação da eficiência durante o processo de extração foi feita segundo Tassan e Ferrari (2002), os quais indicam a utilização da região do vermelho para identificar se os pigmentos foram extraídos de forma satisfatória. Após a extração dos pigmentos o NaClO é removido utilizando água DI. Para minimizar o impacto físico deste procedimento, este é feito lentamente utilizando um conta gotas. A segunda etapa segue as mesmas medidas e equações da primeira etapa, utilizando o filtro despigmentado.

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):

$$a_s = \frac{1 - \rho T + R_f \cdot (\rho T - \rho R)}{1 + R_f \cdot \rho T \cdot \tau} (m^{-1}) \quad 4.4$$

Onde a_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, ρR 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, por meio da equação:

$$\tau = 1,15 - 0,17(OD_{TR}(\lambda) - OD_{TR}(750)) \quad 4.5$$

Onde OD_{TR} 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:

$$OD_{sus} = 0,423 \cdot OD_s + 0,479 OD_s^2 \quad 4.6$$

Onde OD_{sus} é a absorbância do material em suspensão, corrigida a partir dos valores medidos na Equação 4.5 e convertidos para valores de absorbância.

$$OD_{phy} = OD_{total} - OD_{det} \quad 4.7$$

Onde OD_{phy} é a absorbância do fitoplâncton, OD_{total} é a absorbância do material particulado em suspensão (corrigido pela Equação 4.6) e OD_{det} é a absorbância do detrito.

A conversão de absorbância para coeficiente de absorção é feita da seguinte forma:

$$a_p(\lambda) = \frac{2,303 OD_{sus}(\lambda)}{X} (m^{-1}) \quad 4.8$$

Onde X é a razão entre o volume filtrado e a área do filtro contendo amostra em metros (Valor médio obtido das amostras *in situ*).

4.2.2 Caracterização Óptica

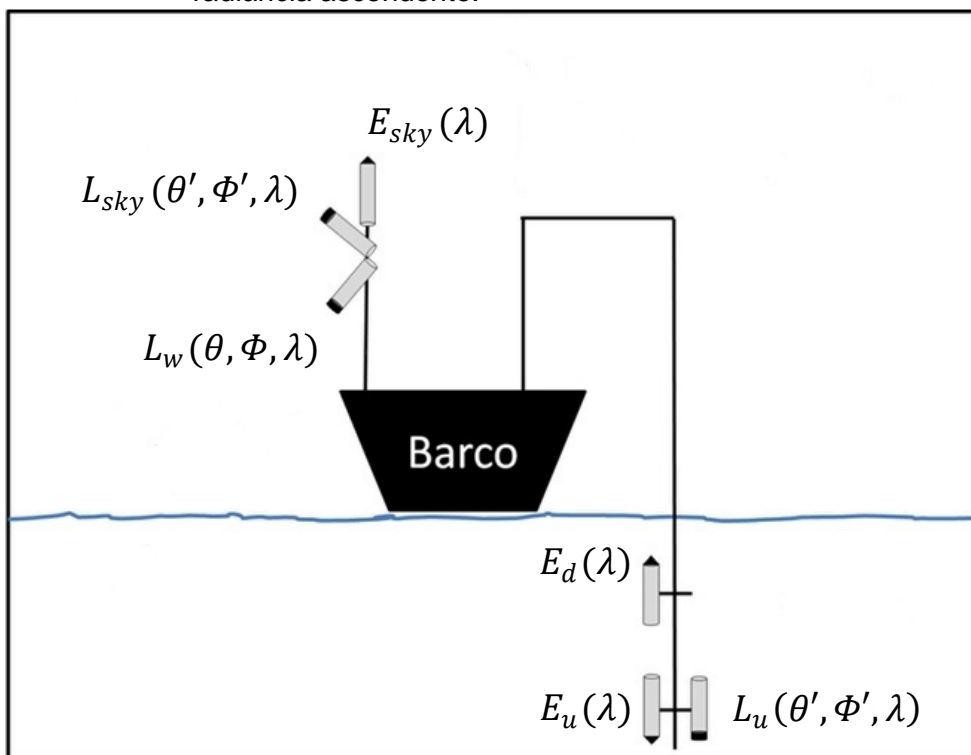
4.2.2.1 AOPs

As medidas *in situ* das quantidades radiométricas utilizaram seis sensores TRIOS, sendo três para radiância e três para irradiância. Os sensores realizam medidas entre 350 e 950 nm, com uma resolução radiométrica de 3,3 nm. Os sensores de radiância possuem um FOV de 7°, enquanto que os sensores de irradiância imageiam todo o hemisfério.

O posicionamento do barco durante a amostragem seguiu Mueller e Fargion (2002) e Mobley (1999), sendo todas as medidas realizadas entre 10:00 e 15:00 horas com pelo menos 15 medidas para cada profundidade amostrada. Os dados foram processados pelo software MSDA_XE e por rotinas de Matlab desenvolvidas no Labisa (<http://www.dpi.inpe.br/labisa/>). Para a medida dos valores das quantidades radiométricas de forma precisa, os sensores foram acoplados a duas estruturas, permitindo que os sensores mantivessem a sua posição durante todo o processo.


A primeira estrutura foi posicionada na proa do barco, e se refere a medidas fora d'água. Nesta, dois sensores de radiância e um sensor de irradiância foram acoplados. O sensor de irradiância se refere a medidas da irradiância incidente na superfície (E_s) e foi posicionado em posição vertical, os dois sensores de radiância foram posicionados a 45° em relação ao zenith (L_w), sendo o primeiro direcionado a água, e o segundo direcionado ao céu (L_{sky}) (Visão esquemática na Figura 4.2 e fotografia dos sensores posicionados no barco na Figura 4.3). A segunda estrutura, localizada na parte lateral do barco, se refere às medidas dentro da água, com 2 sensores de irradiância e 1 sensor de radiância. Os 3 sensores foram fixados em posição vertical, sendo 2 sensores voltados para baixo (E_u e L_u) e 1 sensor voltado para cima (E_d).

Figura 4.2 Visão esquemática dos 6 sensores TRIOS utilizados para a coleta de dados radiométricos. Onde E_{sky} é a irradiância incidente na superfície, L_{sky} é a radiância do céu, L_w é a radiância ascendente da água, E_d é a irradiância descendente, E_u é a irradiância ascendente e L_u é a radiância ascendente.



Fonte: Produção do autor.

Figura 4.3 Fotografia mostrando como os 6 sensores trios foram posicionados no barco.



Fonte: Produção do autor.

O processamento dos dados em Matlab ocorre em 3 etapas distintas:

1) Filtragem dos dados: Todo o conjunto de dados é filtrado de forma a garantir que apenas as medidas feitas pelos 6 sensores de forma simultânea serão mantidas, detectando possíveis falhas durante a coleta.

2) Estimativa dos índices: Para remover a variação nas medidas devido à cobertura de nuvens, foi estabelecido um índice a partir das medidas de E_s . A primeira medida é usada como referência e as demais são normalizadas pelo valor de referência. Desta forma, um índice de cobertura de nuvens é gerado para cada medida ao longo do tempo. Este índice de normalização é posteriormente aplicado a cada medida de todos os sensores, e assim, as medidas radiométricas permitem a comparação entre as medidas obtidas ao longo do tempo.

3) AOPs: Esta etapa consiste na obtenção das AOPs a partir das medidas de quantidades radiométricas. Para este trabalho, os produtos selecionados foram o coeficiente de atenuação vertical difuso (K_d) e a reflectância de sensoriamento remoto (R_{rs}). O cálculo da R_{rs} foi feito de diferentes formas, visando selecionar a melhor abordagem para a área de estudo. Estas abordagens são descritas pelas três equações abaixo.

$$R_{rs} = \frac{L_w - \rho_{sky} L_{sky}}{E_s} (sr^{-1}) \quad 4.9$$

$$R_{rs} = \frac{L_w - \rho_{sky}^* L_{sky}}{E_s} (sr^{-1}) \quad 4.10$$

$$R_{rs} = \frac{L_u}{E_s} - glint \quad 4.11$$

A primeira abordagem consiste na razão entre a radiância ascendente a 45°, corrigindo o efeito por glint por um único fator (ρ_{sky}), e a irradiância incidente. A

segunda abordagem é semelhante a primeira, mas em vez de utilizar um valor de ρ_{sky} fixo, este varia de acordo com a velocidade do vento, latitude e hora (ρ_{sky}^*) (MOBLEY, 2015). Entretanto, esta metodologia pode não remover todo o efeito especular, e em alguns casos pode induzir erros, como valores negativos na região do azul. A última abordagem estima o efeito do *glint* por meio do ajuste de uma função potencial entre os valores de $\frac{L_u}{E_s}$ medidos na região de 350 a 380 nm e 890 a 900 nm (KUTSER, 2013), e subtraindo os valores desta função potência dos valores de $\frac{L_u}{E_s}$ medidos *in situ*. De forma complementar, este trabalho utilizou a terceira abordagem para corrigir o *glint* residual da segunda abordagem, utilizando a R_{rs} corrigida em vez de $\frac{L_u}{E_s}$, e não foi feita nenhuma correção em relação ao fator de reflectância bidirecional ou de resíduo (RUDORFF, 2013). A seleção do melhor espectro de R_{rs} foi feita a partir dos resultados obtidos durante a etapa de calibração dos algoritmos semi-analíticos.

O valor de K_d foi estimado segundo a equação 4.12 (MISHRA, 2005):

$$\ln(E_d(z)) = -K_d \cdot z + \ln(E_d(z_{ref})) \quad (W \cdot m^{-2}) \quad 4.12$$

Esta metodologia assume que o valor de E_d decai de forma exponencial entre a profundidade inicial (z_{ref}) e as demais profundidades (z) e aplica um ajuste linear a entre os valores de $\ln(E_d(z))$ e a profundidade (z), de forma que o valor de K_d se refere a inclinação da curva.

4.2.2.2 IOPs

As medidas de absorção e atenuação *in situ* foram feitas utilizando o equipamento AC-S com 10 cm de caminho óptico, obtendo medidas entre 400 e 750 nm e com resolução espectral e 3,5 nm. Já as medidas *in situ* de retroespalhamento foram feitas utilizando o equipamento HydroScat-6 para os comprimentos de onda 420, 442, 470, 510, 590 e 700 nm. Acoplado ao sensor AC-S, medidas de condutividade, temperatura e pressão foram obtidas (CTD).

A obtenção das medidas de absorção e retroespalhamento seguiram um procedimento fixo. Os equipamentos foram submersos até a profundidade final, onde permaneceram por até 10 min para a estabilização do equipamento e remoção de bolhas de ar e efeitos de turbulência. Em seguida, estes foram levantados lentamente de forma contínua, até a camada superficial da água. As medidas foram realizadas numa frequência de 4 por segundo.

4.2.2.2.1 Processamento AC-S

Como etapa preliminar a cada campo, foi realizada uma calibração de acordo com a metodologia descrita em Wetlabs (2009), utilizando água deionizada como a referência. O processamento subsequente do conjunto de dados in situ, este foi realizado em Matlab, seguindo as rotinas desenvolvidas pelo LabISA (<http://www.dpi.inpe.br/labisa/>).

Assim como no caso do TRIOS, a rotina consiste em uma série de etapas, visando verificar a integridade do dado e fazendo a correção do conjunto de dados, de forma a obter-se valores precisos de coeficiente de atenuação e absorção. A primeira etapa consistiu na remoção da absorção da água do valor medido (WETLABS, 2009), a segunda etapa consistiu na utilização de um filtro passa baixa para suavizar o conjunto de dados e reduzir os ruídos provenientes das medidas, e a terceira etapa consistiu na correção do efeito de temperatura. Dado que os lagos são de água doce o efeito por salinidade foi ignorado. Por fim, o efeito de espalhamento no tubo de absorção foi corrigido seguindo as metodologias testadas em Carvalho et al. (2015). Considerando os resultados obtidos para o Lago Grande do Curuai, assumiu-se que a correção proposta em KIRK (1992) é a mais adequada.

4.2.2.2.2 Hydroscat

Assim como no caso do AC-S, foi realizada uma calibração do Hydroscat antes de cada campo. A calibração consiste na estimativa de ganho e offset no escuro, e seguiu a metodologia proposta pelo manual do fabricante. A conversão do valor da Função de espalhamento volumétrico (β) obtido pelo

equipamento seguiu a metodologia adotada pelo fabricante e está descrita abaixo:

$$b_{bcor} = 2. \pi. X. \beta(140^\circ). \sigma(K_{bb})(m^{-1}) \quad 4.13$$

Onde b_{bcor} é o coeficiente de retroespalhamento corrigido, X é um índice que relaciona $\beta(140^\circ)$ com o coeficiente de retroespalhamento e $\sigma(K_{bb})$ é um fator de correção ($\sigma(K_{bb})$) que depende do caminho óptico e do coeficiente de atenuação. Para este trabalho X foi assumido como 1,08 (HYDRO-OPTICS, BIOLOGY AND INSTRUMENTATION LABORATORIES, 2010).

Como este campo de pesquisa ainda está em desenvolvimento, assumiu-se uma postura mais conservadora, estimando o termo $\sigma(K_{bb})$ conforme proposto pelo fabricante (HYDRO-OPTICS, BIOLOGY AND INSTRUMENTATION LABORATORIES, 2010).

4.2.3 Sensoriamento Remoto

4.2.3.1 Simulação de sensores orbitais

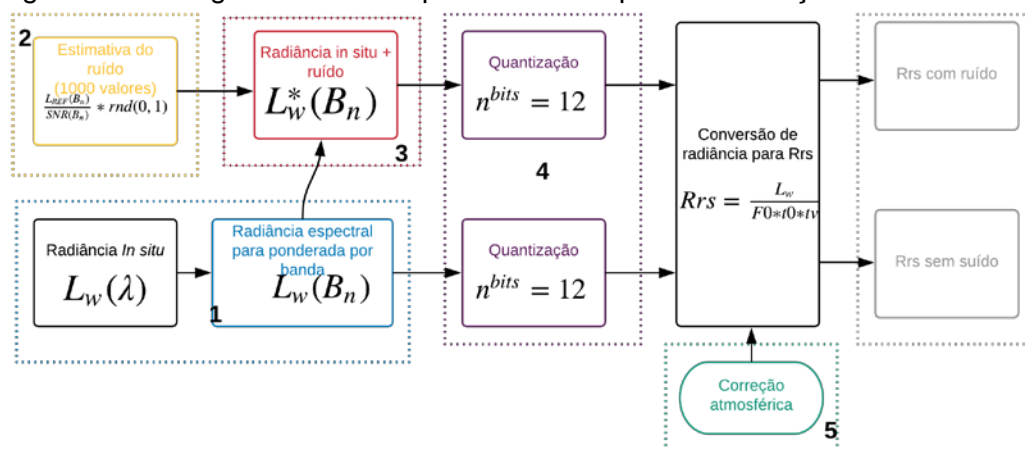
Incertezas na estimativa dos constituintes da água estão entre as maiores preocupações do sensoriamento remoto aplicado a águas interiores. Estas incertezas estão relacionadas ao projeto dos sensores, correção atmosférica, equações dos algoritmos e condições *in situ*, e para os lagos da planície de inundação da Amazônia, estas incertezas são potencializadas devido a dinâmica do pulso de inundação. Para compreender o impacto destas incertezas nas medidas feitas pelos sensores disponíveis e conseqüentemente nos resultados derivados por sensoriamento remoto, esta seção da metodologia abordará o impacto da relação sinal ruído nas medidas de R_{rs} e como este se propaga afetando as estimativas produzidas por diferentes algoritmos empíricos.

A simulação e avaliação dos sensores orbitais foi feita a partir das R_{rs} obtidos *in situ* e das especificações dos sensores. As etapas para a simulação estão descritas em seu respectivo tópico e o fluxograma geral (Figura 4.4) apresenta a ordem destas etapas. É importante destacar que para quantificar o impacto

das características dos sensores nos resultados da simulação, assumiu-se correção atmosférica e medidas *in situ* ideais.

A simulação resultou em 1000 espectros de R_{rs} gerados para cada um dos 102 pontos de amostragem, e para cada dos sensores (MSI/Sentinel-2, OLCI/Sentinel-3 e OLI/Landsat 8), baseados nas suas características. O fluxograma da simulação consiste de cinco etapas (Figura 4.4): 1) Reamostragem dos espectros *in situ* para a resolução das bandas (em inglês band-weighted) de cada sensor; 2) Cálculo do ruído para cada sensor a partir da especificação da relação sinal/ruído (SNR) de cada banda do sensor; 3) Adição do ruído ao espectro simulado; 4) Quantização do espectro; 5) Conversão de irradiância no topo da atmosfera (TOA) para irradiância de superfície.

Figura 4.4 Fluxograma das 5 etapas realizadas para a simulação dos sensores



Fonte: Produção do autor.

- 1) Reamostragem dos espectros *in situ* para as bandas espectrais dos sensores

A primeira etapa da simulação é a reamostragem dos dados *in situ* de modo a simular as bandas dos sensores de interesse. A reamostragem dos dados espectrais de radiação para as bandas de cada sensor, foi baseada na função

resposta entre 400 e 900 nm (Tabela 4.1, Tabela 4.2, e Tabela 4.3) segundo a Equação 4.14:

$$L_w(Bn) = \frac{\int_{\Delta Bn} L_w(\lambda) \cdot RF_{Bn}(\lambda) d\lambda}{\int_{\Delta Bn} RF_{Bn}(\lambda) d\lambda} (W \cdot m^{-2} sr^{-1}) \quad 4.14$$

onde B se refere a banda do sensor, n é o número da banda, entre 1 e n, de acordo com as especificações do sensor, $L_w(Bn)$ é a radiância ascendente para cada banda ($W \cdot m^{-3} \cdot sr^{-1} \cdot nm^{-1}$), ΔBn é a largura da banda e RF_{Bn} é função resposta para cada banda do sensor (Tabela 4.1, Tabela 4.2 e Tabela 4.3). Nesta etapa, os dados são convertidos para o que seria medido por cada sensor orbital, na ausência de todas as fontes de incerteza.

Tabela 4.1 Configurações do sensor MSI/Sentinel-2 usadas como entrada para a simulação. CC é o comprimento de onda central (nm), LB é a largura da banda (nm), RS é a resolução espacial (m), L_{TOA} ref ($W \cdot m^{-2} \cdot sr^{-1} \cdot \mu m^{-1}$) é a radiância na qual o SNR foi calculado, Quant é a quantização e L_{TOA} MAX ($W \cdot m^{-2} sr^{-1} \cdot \mu m^{-1}$) é a radiância máxima que pode ser medida pelo sensor.

Bandas	CC	LB	RS	L_{TOA} ref	SNR	Quant	L_{TOA} MAX
B1	443	20	60	129	129	12	588
B2	490	65	10	128	154	12	615,5
B3	560	35	10	128	168	12	559
B4	665	30	10	108	142	12	484
B5	705	15	20	74,5	117	12	449,5
B6	740	15	20	68	89	12	413
B7	783	20	20	67	105	12	387

Fonte: Produção do autor.

Tabela 4.2 Configurações do sensor OLCI-Sentinel 3 usadas como entrada para a simulação. CC é o comprimento de onda central (nm), LB é a largura da banda (nm), RS é a resolução espacial (m), $L_{TOA\ ref}$ ($W.m^{-2}.sr^{-1}.\mu m^{-1}$) é a radiância na qual o SNR foi calculado, Quant é a quantização e $L_{TOA\ MAX}$ ($W.m^{-2}.sr^{-1}.\mu m^{-1}$) é a radiância máxima que pode ser medida pelo sensor.

Bandas	CC	LB	RS	$L_{TOA\ ref}$	SNR	Quant	$L_{TOA\ MAX}$
B1	400	10	300	63	2188	12	413,5
B2	412	10	300	74	2061	12	501,3
B3	442	10	300	66	1811	12	466,1
B4	490	10	300	51	1541	12	483,3
B5	510	10	300	44	1488	12	449,6
B6	560	10	300	31	1280	12	524,5
B7	620	10	300	21	997	12	397,9
B8	665	10	300	16	855	12	364,9
B9	673	7,5	300	16	707	12	443,1
B10	681	7,5	300	15	745	12	350,3
B11	708	10	300	13	785	12	332,4
B12	753	7,5	300	10	605	12	377,7
B13	778	15	300	9	812	12	277,5
B14	865	20	300	6	666	12	229,5
B15	885	10	300	6	395	12	281

Fonte: Produção do autor.

Tabela 4.3 Configurações do sensor OLI/Landsat 8 usadas como entrada para a simulação. CC é o comprimento de onda central (nm), LB é a largura da banda (nm), RS é a resolução espacial (m), $L_{TOA\ ref}$ ($W.m^{-2}.sr^{-1}.\mu m^{-1}$) é a radiância na qual o SNR foi calculado, Quant é a quantização e $L_{TOA\ MAX}$ ($W.m^{-2}.sr^{-1}.\mu m^{-1}$) é a radiância máxima que pode ser medida pelo sensor.

Bandas	CC	LB	RS	$L_{TOA\ ref}$	SNR	Quant	$L_{TOA\ MAX}$
B1	443	20	30	190	232	12	782
B2	482	65	30	190	355	12	800
B3	565	75	30	194	296	12	738
B4	660	50	30	150	222	12	622
B5	867	40	30	150	199	12	381

Fonte: Produção do autor.

2) Cálculo do ruído específico para cada sensor

O ruído atua como fonte de incerteza para todos os tipos de medidas radiométricas, seja ela *in situ*, laboratorial ou orbital, e para os sensores selecionados, corresponde a uma pequena percentagem do total (entre 0,05% e 1% - Tabela 4.1, Tabela 4.2 e Tabela 4.3). Entretanto, quando consideramos que a informação proveniente dos corpos d'água é de até 5% do total medido pelo sensor (MOSES et al., 2012; GIARDINO et al., 2014; PAHLEVAN et al., 2014) o impacto do ruído fica evidente, sendo uma parcela significativa do sinal. A radiância do TOA foi convertida para o ruído equivalente utilizando a radiância do TOA de referência para cada banda de cada sensor (Tabela 4.1, Tabela 4.2 e Tabela 4.3), e sua SNR específica (MOSES et al, 2012) (Equações 4.15).

$$\text{Ruido}(B_n) = \frac{L_{TOA\ ref}(B_n)}{SNR(B_n)} \text{ rnd } (W.m^{-2}.sr^{-1}) \quad 4.15$$

onde $L_{TOA\ ref}(B_n)$ é a radiância de referência utilizada para gerar a SNR específica, SNR é a razão sinal ruído para cada banda e rnd é um número

aleatório obtido a partir de uma distribuição normal padrão (média igual a 0 e desvio padrão igual a 1, $N(0,1)$). Para cada sensor, 1000 valores de $Ruido(B_n)$ foram gerados a partir dos 1000 valores de rnd . Essa distribuição normal foi selecionada para simular uma condição real de ruído, e desta forma, os 1000 ruídos representariam possíveis valores durante o imageamento.

3) Adição do ruído aos espectros simulados no passo 1

Os 1000 $Ruido(B_n)$ aleatórios foram adicionados diretamente a $L_w(B_n)$ de cada espectro (Equação 4.16). Para excluir o impacto da propagação de erros devido à correção atmosférica no ruído, assumiu-se que a correção atmosférica foi ideal.

$$L_w^*(B_n) = L_w(B_n) \pm Ruido(B_n) \quad (W.m^{-2}sr^{-1}) \quad 4.16$$

onde $L_w^*(B_n)$ é radiância ascendente com ruído para cada banda do sensor.

4) Quantização radiométrica

A última etapa referente às especificações de cada sensor é a quantização radiométrica. Cada sensor é configurado para medir um valor mínimo e máximo de radiância, e dentro desse intervalo, o número de medidas diferentes se dá pelo número de bits de um sensor. Assim, dependendo do número de bits de um sensor, este pode ser incapaz de detectar pequenas variações na radiância. Considerando que os 3 sensores possuem 12 bits, os dados da simulação foram aproximados para se adequar as 4096 medidas possíveis (Equação 4.17).

$$L_w^{*b}(B_n) = L_w^*(B_n) / \frac{L_{TOAmax}(B_n)}{2^{nbit}} \quad (W.m^{-2}sr^{-1}) \quad 4.17$$

onde $L_w^{*b}(B_n)$ é a radiância ascendente quantizada e com ruído para cada banda, $L_{TOAmax}(B_n)$ é a radiância máxima medida para o sensor para cada banda e $nbit$ é o número de bits de cada sensor (12 bits).

5) Conversão do espectro solar para irradiância de superfície

Esta etapa é feita para converter valores de radiância em valores de reflectância. A conversão de radiância ascendente (L_w) para reflectância (ρ) segue a Equação 4.18:

$$\rho = \frac{\pi \cdot L_w \cdot d^2}{F0 \cdot \cos \theta_0} \quad 4.18$$

onde d é a distância Terra-Sol em unidades astronômicas, θ_0 é o ângulo zenital solar, $F0$ é a irradiância solar e ρ a reflectância. Esse trabalho assumiu um valor de 1 para d , e $F0$ de Gueymard (2001) (VANHELLMONT; RUDICK, 2014, 2015). A propagação do espectro solar para a superfície foi baseada no algoritmo descrito em Vanhellmont e Rudick (2014, 2015) usando uma atmosfera padrão e equações derivadas de (GUEYMARD, 1995; BIRD; RIORDAN, 1984; LECKNER, 1978).

$$F0_{wl} = t_0 \cdot t_v \cdot (F0_{TOA}) \quad (W \cdot m^{-2}) \quad 4.19$$

onde t_0 e t_v são a transmitância difusa do sol/água e água-sensor, $F0_{wl}$ a irradiância solar no nível da água e $F0_{TOA}$ é a radiância solar no TOA. O ângulo θ_0 é o ângulo zenital solar e θ_v , o ângulo zenital de visada. Para cada banda, a transmitância difusa t_0 e t_v foi calculada substituindo θ por θ_0 e θ_v na Equação 4.20.

$$t = \exp \left[-\left(\frac{\tau_r}{2} + \tau_{OZ} \right) / \cos \theta \right] \quad 4.20$$

onde τ_r e τ_{OZ} são a espessura óptica do Rayleigh e do Ozônio para uma determinada composição atmosférica. Para simplificar a metodologia, os impactos da absorção pela água e do aerossol na transmitância da atmosfera foram ignorados (VANHELLEMONT; RUDDICK 2014).

A espessura óptica Rayleigh (τ_r) foi calculada segundo o algoritmo proposto por LECKNER (1978) e melhorado por Bird e Riordan (1984):

$$\tau_r(\lambda) = 0,008735 \left(\frac{P}{P0} \right) (\lambda)^{-4,08} \quad 4.21$$

onde λ é o comprimento de onda em micrômetros, P é a pressão atmosférica no local (1014 hPa) e P_0 é a pressão ao nível do mar referência (1013,24 hPa).

A espessura óptica do Ozônio (τ_v) foi calculado de acordo com Gueymard (1995), que foi baseado em Leckner (1978) e Bird (1984):

$$\tau_v(\lambda) = \exp(\alpha_0 \cdot \lambda \cdot O_3 \cdot M_0) \quad 4.22$$

onde α_0 é o coeficiente de absorção do ozônio, O_3 é a concentração do ozônio (atm.cm^{-1}) e M_0 é a massa do ozônio. O coeficiente de absorção do ozônio foi linearmente interpolado segundo Bird e Riordan (1984), e a massa do ozônio foi calculado segundo LECKNER (1978).

$$M_0 = (1 + h_0/6370)(\cos^2 Z + 2 h_0/6370)^{0,5} \quad 4.23$$

onde h_0 é a altura da concentração máxima do ozônio, e Z é o ângulo zenital.

Através desta etapa é possível calcular o valor real da $F_{0_{wl}}(B_n)$ que atravessa a atmosfera e atinge a superfície da água, e a conversão de $L_w^{*b}(B_n)$ para $R_{rs}(B_N)$ é feita segundo a Equação 4.24.

$$R_{rs}(B_N) = \frac{L_w^{*b}(B_n)}{F_{0_{wl}}(B_n) \cdot t_0(B_n) \cdot t_v(B_n)} \quad (\text{sr}^{-1}) \quad 4.24$$

Os parâmetros inseridos em cada etapa da simulação estão descritos nas Tabela 4.4 e Tabela 4.5, e foram utilizados para propagar o espectro solar pela atmosfera.

Tabela 4.4 Parâmetros usados durante a conversão do espectro solar no TOA para irradiância de superfície para todos os sensores.

Parâmetro	Valores
Dia do ano	01 Janeiro
Hora	12 hrs 00 min (GMT)
Latitude	0°
Elevação do solo	40 m
Ângulo Zenital do sensor	0°
Ângulo Azimutal do sensor	0°
Quantidade de Ozônio	0,3 atm cm ⁻¹
Altura de concentração máxima de Ozônio	22 km
Pressão atmosférica	1014

Fonte: Produção do autor.

Tabela 4.5 Exemplo dos parâmetros obtidos e usados durante a simulação atmosférica para o sensor MSI. $F_{0_{TOA}}$ é a irradiância solar no TOA para cada banda, τ_r é a densidade óptica de Rayleigh para uma atmosfera padrão e τ_{OZ} é a densidade óptica do ozônio para 300 DU de ozônio na atmosfera.

Banda	$F_{0_{TOA}}$ (Wm ⁻² μm ⁻¹)	τ_r	τ_{OZ}
B1 (443)	1938,2	0,2405	0,0004
B2 (490)	1916,5	0,1543	0,0087
B3 (560)	1845,9	0,0934	0,0309
B4 (665)	1524,7	0,0464	0,0167
B5 (705)	1402,5	0,0366	0,0063
B6 (740)	1290	0,0298	0,0030
B7 (783)	1184,8	0,0238	0,0002

Fonte: Produção do autor.

4.2.3.2 Impacto das especificações dos sensores nos algoritmos de Chl-a e TSS

Os dois conjuntos de dados simulados (com e sem ruído) foram utilizados para avaliar o impacto das configurações ópticas dos sensores em algoritmos para a estimativa de Chl-a e TSS. O conjunto de algoritmos selecionados foi aplicado a diferentes ambientes e sensores (BINDING et al., 2003; MOSES et al., 2009; MATTHEWS et al., 2012; MISHRA; MISHRA et al., 2012; CHEN et al., 2015; LOBO et al., 2015), com alguns ajustes nos comprimentos de onda centrais, baseados na disponibilidade de banda. Estes algoritmos foram selecionados baseados na diversidade de bandas e operações matemáticas, para englobar diversas estruturas de equações. Para simplificar o entendimento, o conjunto de algoritmos foi classificado como aditivo (adição ou subtração), multiplicativo (divisão e multiplicação) e exponencial.

Foram testados três algoritmos empíricos para TSS (denominados como TSS_linear, TSS_exp e TSS_NSSI) e quatro algoritmos empíricos para Chl-a (denominados como CLH, 2B, 3B, NDCI) (Tabela 4.6). Cada algoritmo foi calibrado usando o conjunto de dados sem ruído e as medidas *in situ* de TSS ou Chl-a. Para remover a incerteza atribuída a calibração dos algoritmos, os algoritmos calibrados foram aplicados ao conjunto de dados sem ruído, ao invés dos dados *in situ*, e comparados com os resultados obtidos ao aplicar o algoritmo no conjunto de dados com ruído. Esse método parte de dois pressupostos: (i) a concentração proveniente do conjunto de dados sem ruído é a concentração de referência (“verdade terrestre”), e os resultados do conjunto de dados com ruído serão comparados às concentrações de referência; (ii) a incerteza entre os resultados com e sem ruído se devem apenas a mudanças na SNR. A concentração estimada a partir do conjunto de dados com ruído é comparada a “verdade terrestre”, de forma que as mudanças na magnitude se devem a apenas dois aspectos: as constantes dos algoritmos (e.g., a, b, c e d (Tabela 4.6)) e R_{rs} .

Tabela 4.6 Algoritmos para a estimativa de Chl-a e TSS. O comprimento de onda exato foi adaptado a cada sensor testado. CLH é um algoritmo de linha de altura de Chl-a (MATTHEWS et al., 2012), 2B é um algoritmo de razão de banda para 2 bandas (MOSES et al., 2009), 3B é um algoritmo de razão de bandas para 3 bandas (MOSES et al., 2009), NDCI é um algoritmo de razão de bandas para 2 bandas (MISHRA; MISHRA et al., 2012), TSS_linear é um algoritmo linear a partir da banda do vermelho (BINDING et al., 2003), TSS_exp é um algoritmo exponencial (CHEN et al., 2015) e TSS_NSSI é um algoritmo exponencial baseado em uma razão de bandas (LOBO et al., 2015).

Nome	Algoritmo Linear ($a \cdot x + b$)
<i>CLH</i>	$x = Rrs(708) - (Rrs(665) + Rrs(740))/2$
<i>2B</i>	$x = Rrs(665) \cdot Rrs(708)^{-1}$
<i>3B</i>	$x = (Rrs(665)^{-1} - Rrs(708)^{-1}) \cdot Rrs(753)$
<i>NDCI</i>	$x = \frac{Rrs(red) - Rrs(NIR)}{Rrs(red) + Rrs(NIR)}$
<i>TSS_linear</i>	$x = Rrs(red)$
Algoritmo Não Linear	
<i>TSS_exp</i>	$TSS = \left(\frac{aRrs(red)}{b} \right)^c + d$
<i>TSS_NSSI</i>	$NSSI = \frac{Rrs(green) - Rrs(red)}{Rrs(green) + Rrs(red)}$ $TSS = a \cdot e^{-b \cdot NSSI}$

Fonte: Produção do autor.

4.3 Caracterização bio-óptica

Antes do desenvolvimento e da implementação dos algoritmos, foi realizada uma análise estatística preliminar (ANOVA) do conjunto de dados utilizando o ano, o pulso hidrológico, estágio do pulso e distância dos rios principais como fatores. O conjunto de dados foi inicialmente tratado por uma análise ANOVA, utilizando o ano, estágio do pulso e distância dos rios principais como fatores. O objetivo desta análise é compreender como os lagos se comportam ao longo

do tempo e espaço, identificando os principais fatores que condicionam as características ópticas deste meio, para uma posterior definição de como estes dados serão agrupados durante o desenvolvimento dos algoritmos. Deve-se destacar que esta etapa resultou em uma visão sinóptica de um ambiente ainda não estudado para estes parâmetros bio-ópticos, sendo de vital importância para o entendimento preliminar dos processos biológicos, físicos e químicos.

4.4 Desenvolvimento e implementação do algoritmo semi-analítico

Para o desenvolvimento dos algoritmos propostos, o trabalho correlacionou as medidas radiométricas obtidas *in situ* com as medidas de coeficientes de absorção e retroespalhamento obtidas em laboratório e *in situ*. Esta metodologia parte de dois pressupostos:

- A magnitude da R_{rs} varia exclusivamente em função dos OACs presentes na água.
- Conhecendo o comportamento dos coeficientes de absorção e espalhamento de cada OAC medidos *in situ* e como estes variam em função de sua concentração, é possível estimar as IOPs a partir do espectro de R_{rs} .

Para águas oceânicas ou caso I, esta abordagem tem sido amplamente utilizada por diversos grupos de pesquisa, através de algoritmos semi-analíticos com diferentes abordagens, como SOA com os algoritmos GSM (GARVER; SIEGEL, 1997; MARITORENA et al. 2002) e HOPE (LEE, 1994; LEE et al., 1999), LMI (HOGE; LYON, 1996) e OCLMI - Over Constrained Linear Matrix Inversion (BOSS; ROESLER, 2006), QAA (LEE et al., 2002; LEE et al., 2007) e PML (SMYTH et al., 2006). Entretanto, para águas interiores, os algoritmos apresentados não podem ser aplicados diretamente uma vez que as relações empíricas tendem a ser diferentes, sendo necessário calibrá-los de acordo com as propriedades ópticas da área de estudo.

A seleção dos algoritmos aqui testados baseou-se em dois critérios: i) ampla revisão de literatura e análise do desempenho destes em diferentes ambientes aquáticos; ii) existência de estudos prévios em outros ambientes que permitissem a comparação. Assim sendo, o presente trabalho buscou implementar, calibrar e validar duas abordagens distintas (QAA e SOA) para a área de estudo.

Para a calibração dos algoritmos QAA e SOA, os valores de referência para $a_t(\lambda)$ foram medidos pelo AC-S, enquanto $a_{phy}(\lambda)$ foi medido em laboratório e $a_{dg}(\lambda)$ foi estimado subtraindo $a_{phy}(\lambda)$ (medido em laboratório) de $a_t(\lambda)$ (medido pelo AC-S). De forma semelhante, os valores de inclinação da curva $b_b(\lambda)$ foram estimados a partir dos valores de $b(\lambda)$ medidos pelo AC-S e convertidos para $b_b(\lambda)$, assumindo um valor espectralmente constante de 0,05 para a razão $\frac{b_b(\lambda)}{b(\lambda)}$. Tanto os valores de $b_b(\lambda)$ medidos pelo Hydrosat quanto os valores de $b_b(\lambda)$ estimados pelo AC-S foram testados, entretanto, durante a etapa de calibração, verificou-se que os valores de $b_b(\lambda)$ estimados pelo AC-S estavam mais condizentes com os obtidos pelos algoritmos, e desta forma, foram utilizadas as medidas obtidas pelo AC-S neste trabalho.

O processo de otimização foi feito utilizando Monte Carlo no software Matlab, estabelecendo os limiares aceitáveis para cada ajuste e buscando minimizar os erros. Para o QAA, esta otimização foi feita em três etapas

Durante a primeira etapa, é necessário calibrar os valores de R_{rs} com $a(\lambda_0)$. Esta etapa é feita de duas formas: 1) seleção do comprimento de onda de referência; 2) Otimização para determinação das constantes da equação. Em geral, λ_0 depende da área de estudo, podendo usar valores mais próximos de 555 nm para águas caso I, e valores na região do vermelho (640 nm) e infravermelho (708 nm) para águas caso II. Para esta etapa, os 3 comprimentos de onda foram testados (e.g. Equação 3.25).

Após o calibrar $a(\lambda_0)$, o valor de $b_{bp}(\lambda_0)$ é calculado e a sua estimativa para os demais comprimentos de onda ocorre pela calibração entre o parâmetro Y e a

R_{rs} em dois comprimentos de onda (Equação 3.33). Assim como na Etapa 1, foram testados 3 comprimentos de onda de referência. Por fim, a última etapa da calibração do algoritmo QAA é a decomposição de $a(\lambda)$ em $a_{phy}(\lambda)$ e $a_{dg}(\lambda)$ (Equações, 3.36 e 3.37 respectivamente). Esta é feita em função das variáveis ξ e ζ . Basicamente, estas variáveis correlacionam $a_{phy}(\lambda)$ e $a_{dg}(\lambda)$ em dois comprimentos de ondas distintos. No caso de $a_{dg}(\lambda)$, ξ representa a taxa de decaimento do a_{dg} entre estes comprimentos de onda, e no caso de $a_{phy}(\lambda)$ ζ representa a razão do $a_{phy}(\lambda)$ em dois comprimentos de onda, normalmente selecionados para identificar este impacto na presença e ausência de pigmentos fotossintetizantes. Com as variáveis ξ e ζ é possível isolar o a_{dg} em um único comprimento de onda, e tendo o valor de S, é possível extrapolar a sua magnitude para todo o espectro, e por fim, estimar o valor de $a_{phy}(\lambda)$. Assim como nas Etapas 1 e 2, os comprimentos de onda dependem da área de estudo, e o mesmo grupo de comprimentos de onda foi testado durante a calibração.

Assim como no caso do algoritmo QAA, o processo de otimização do algoritmo SOA foi feito no Matlab, utilizando Monte Carlo. Para os 3 parâmetros de entrada (autovalores) do algoritmo, os valores iniciais foram selecionados a partir dos valores medidos *in situ*, e mínimos e máximos esperados (Tabela 4.7). Para o estimador de erro, diferentes regiões do espectro podem ser utilizadas, ponderando de acordo com o COA de interesse. Por exemplo, para aumentar a influência do fitoplâncton no estimador de erro, é possível atribuir um peso maior para os comprimentos de onda no vermelho, e assim garantir espectros de R_{rs} mais precisos para esta região. Para este trabalho, foram testados 5 estimadores: 1) Todos os comprimentos de onda, 2) Comprimentos de onda entre 661 nm e 691 nm, 3) Comprimentos de onda acima de 500 nm, 4) Comprimentos de onda acima de 600 nm e 5) Comprimentos de onda acima de 700 nm. Foi testado um único $a_{phy}^*(440)$, e este foi calculado a partir valor médio dos valores de $a_{phy}^*(440)$ medidos em laboratório. Para os parâmetros de inclinação Y e S, foram testados 3 valores para cada um, 0,85, 1 e 1,15 para

Y e 0,013, 0,015 e 0,017 para S (baseados nas medidas *in situ*). A seleção do melhor valor de Y e S, e do melhor estimador de erro foi feita baseada nos resultados obtidos para cada combinação do algoritmo, minimizando o erro.

Tabela 4.7 Parâmetros de entrada para o algoritmo SOA

	Mínimo	Entrada	Máximo
$Chl - a (\mu g/L)$	1	10	40
$a_{dg}(440)(m^{-1})$	0,5	1	10
$b_{bp}(440)(m^{-1})$	0	0,6	15

Fonte: Produção do autor.

4.5 Estimadores de Erro

Para avaliar quantitativamente os resultados obtidos nas diferentes etapas descritas na metodologia, foram utilizados 3 estimadores de erro, RMSE (Root Mean Squared Error), NRMSE (Normalized Root Mean Squared Error) e erro relativo. O RMSE se baseia na média das diferenças entre os valores medidos e modelados, o NRMSE utiliza o RMSE, mas divide o valor estimado pelo valor medido, e por fim o erro relativo é uma simplificação do NRMSE, sendo aplicado de forma pontual para cada medida (HYNDMAN; KOEHLER, 2006).

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x - \hat{x})^2}{N}} \quad 4.25$$

Onde \hat{x} é o valor do estimador, x é o valor do parâmetro estimado e N é número de amostras.

$$NRMSE = \frac{RMSE}{\bar{x}} \quad 4.26$$

Onde \bar{x} é o valor médio do estimador.

$$Erro\ Relativo = \frac{\hat{x} - x}{\hat{x}} \quad 4.27$$

5 RESULTADOS E DISCUSSÃO

5.1 Caracterização bio-óptica

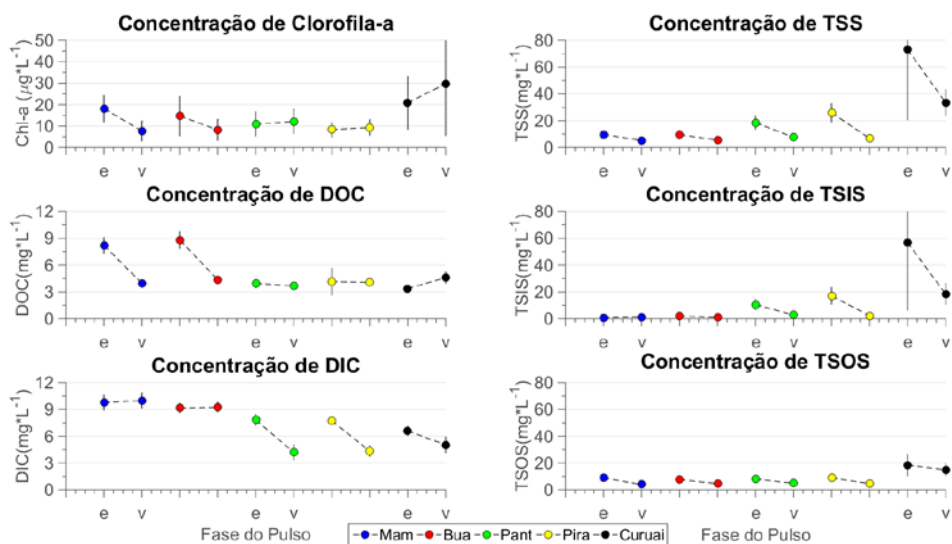
Esta sessão apresenta os resultados da caracterização bio-óptica dos lagos da RDSM. O comportamento espaço temporais das variáveis bioquímicas e ópticas serão apresentadas de acordo com a divisão proposta na metodologia.

5.1.1 Dinâmica das Variáveis Limnológicas

Os valores médios e o desvio padrão de cada variável para todo o conjunto de dados são apresentados na Figura 5.1. e Tabela 5.1. Em geral, a clorofila-a não apresentou um padrão claro ao longo do tempo e espaço, com valores relativamente semelhantes, para todos os lagos e fases do pulso, entretanto foi possível observar uma grande amplitude na magnitude, com valores entre 2 e 30 $\mu\text{g/L}$. Para o TSS nota-se um aumento da sua concentração durante o período de enchente para os 4 lagos, sendo que o aumento foi mais expressivo para os lagos Pirarara e Pantaleão (lagos claros). Entretanto, ao subdividirmos o TSS em suas frações orgânica e inorgânica, nota-se que o aumento do TSS nos lagos Bua Bua e Mamirauá (lagos escuros) foi devido ao aumento da fração orgânica, enquanto que a fração inorgânica se mantém baixa e próxima de zero. Já para os lagos Pirarara e Pantaleão, notamos um aumento semelhante, ao observado nos lagos escuros, na fração orgânica, enquanto que para a fração inorgânica, ocorre um aumento expressivo. Devido a distribuição geográfica dos 4 lagos, o aumento na carga inorgânica nos lagos claros provavelmente se deve a proximidade do rio Japurá, enquanto que a fração orgânica dos 4 lagos provavelmente é devido a floresta no entorno e decomposição das macrófitas (abundantes no período de enchente) (ARRAUT et al., 2010). Quanto à distribuição do DOC, nota-se um padrão semelhante, com o aumento do DOC nos lagos escuros durante o período de enchente, enquanto que para os demais lagos e fases do pulso, os valores são relativamente constantes. Os valores são condizentes com o esperado, uma vez que se espera uma maior entrada de matéria orgânica de origem florestal para estes dois lagos totalmente circundados por floresta e distantes dos rios

Japurá e Solimões, e uma condição mais homogênea após o período da cheia. Dois autores analisaram as propriedades limnológicas dos lagos da RDSM (Queiroz et al. 2007; Affonso et al., 2011), entretanto, esta análise não foi feita para todas as fases do pulso de inundação. Affonso et al. (2011) observaram que tanto para a clorofila-a quanto para o TSS e DOC, as maiores concentrações foram observadas durante a seca, e uma maior homogeneização durante o período de cheia. Da mesma forma, Queiroz et al. (2007) notaram um padrão semelhante quanto a variabilidade da transparência ao longo do pulso de inundação, com valores mínimos durante a seca (indicando uma maior atenuação devido ao aumento da concentração dos COAs), aumentando durante a enchente, atingindo os valores máximos durante a cheia e diminuindo novamente durante o período de vazante. Queiroz et al. (2007) observaram que para alguns lagos, uma variação expressiva na transparência da água foi encontrada, com diferenças de até 75 cm (de 70 cm durante a enchente para 145 cm durante a vazante), indicando um aumento na concentração de CDOM e/ou TSS no período de enchente e uma variabilidade espacial nas propriedades ópticas das águas. Ao compararmos com os resultados obtidos com os dados para o Lago Grande do Curuai (CARVALHO, 2016), pontos pretos na Figura 5.1, pode-se notar que as maiores diferenças se referem as concentrações de Chl-a e TSIS (Total de Sólidos Inorgânicos Suspensos), enquanto que a parcela orgânica do TSS e as parcelas orgânicas e inorgânicas do carbono são semelhantes.

Figura 5.1 Distribuição da concentração dos dados limnológicos dos lagos da RDSM e do Lago Grande do Curuai. As cores se referem aos 5 lagos, “e” e “v” se referem aos valores médios obtidos durante a enchente e vazante, respectivamente. Os dados referentes ao lago Grande do Curuai foram obtidos por Carvalho (2016).



Fonte: Produção do autor

Tabela 5.1 Distribuição da concentração dos dados limnológicos dos lagos da RDSM. Os lagos Escuros se referem aos lagos Bua Bua e Mamirauá e os lagos Claros se referem aos lagos Pantaleão e Pirarara; "E" e "V" se referem a à enchente e vazante, respectivamente. Média se refere aos valores médios, DP ao desvio padrão, CV ao coeficiente de variação, Min ao mínimo e Max ao máximo.

Parâmetros	Lagos/Fase	Escuros (51 pontos)		Claros (51 pontos)	
		V (30)	E (21)	V (27)	E (24)
Clorofila-a	Média	6,43	16,64	8,61	9,65
	DP	5,19	7,60	6,21	4,75
	CV	0,81	0,46	0,72	0,49
	Min	0,30	3,42	0,23	2,68
	Max	18,64	35,01	22,20	22,33
Totais Sólidos em Suspensão	Média	4,85	9,62	7,03	22,22
	DP	2,03	2,84	2,14	6,89
	CV	0,42	0,29	0,30	0,31
	Min	1,60	5,60	14,00	10,67
	Max	12,71	16,00	3,00	37,00
Totais Sólidos Orgânicos em Suspensão	Média	3,86	8,36	4,67	8,47
	DP	1,43	2,59	1,94	2,54
	CV	0,37	0,31	0,42	0,30
	Min	1,30	3,90	1,60	3,80
	Max	7,43	13,00	11,90	14,40
Totais Sólidos Inorgânicos em Suspensão	Média	1,17	1,26	2,36	13,75
	DP	0,65	1,48	1,08	6,04
	CV	0,55	1,17	0,46	0,44
	Min	0,17	0,20	0,89	3,60
	Max	2,57	5,60	4,60	27,60
Carbono Orgânico Dissolvido	Média	4,15	8,54	3,85	4,05
	DP	0,30	0,94	0,42	1,09
	CV	0,07	0,11	0,11	0,27
	Min	3,69	7,19	3,13	3,37
	Max	4,90	10,08	4,78	8,68
Carbono Inorganico Dissovido	Média	9,63	9,42	4,25	7,79
	DP	0,79	0,73	0,73	0,52
	CV	0,08	0,08	0,17	0,07
	Min	8,61	8,12	3,29	6,83
	Max	11,72	11,71	5,60	8,73

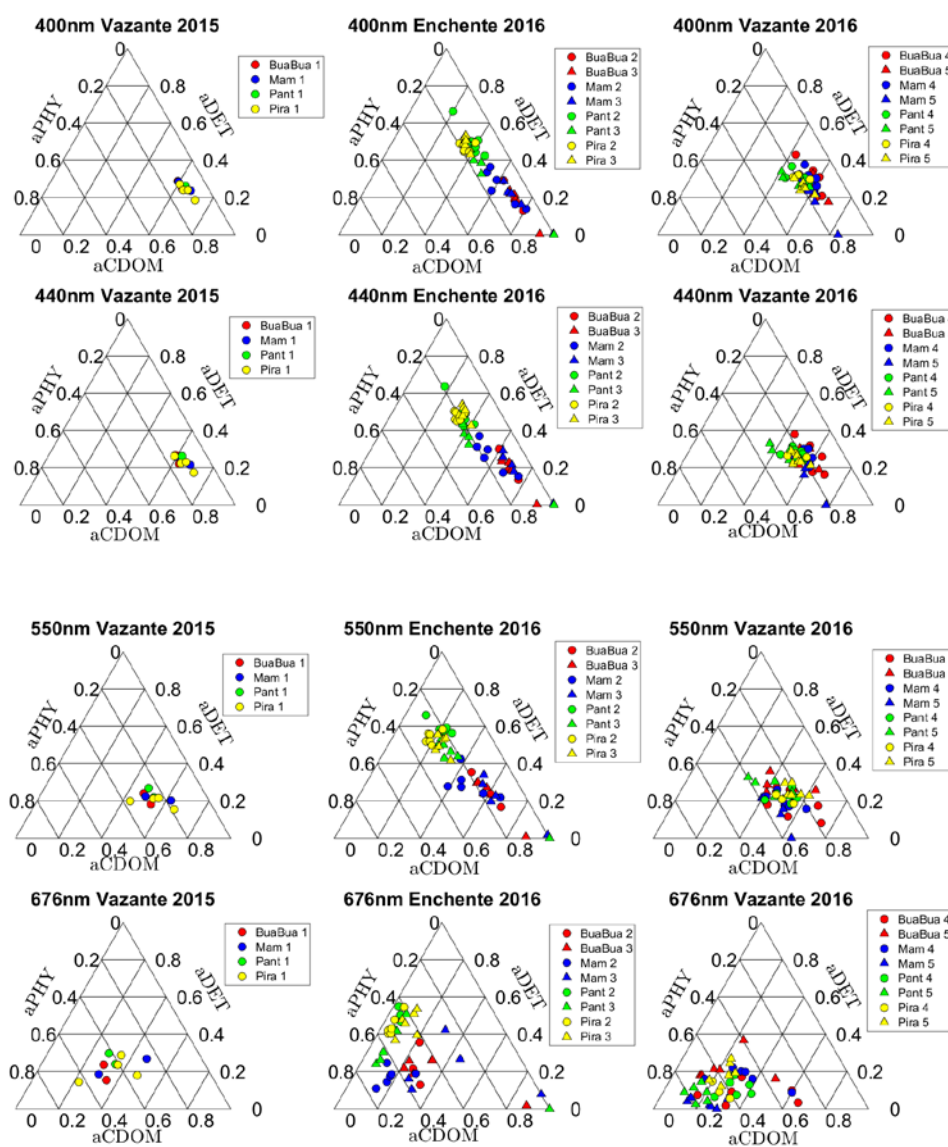
Fonte: Produção do autor

5.1.2 IOPs – Absorção

5.1.2.1 IOPs medidas em laboratório

A análise do conjunto de dados medidos em laboratório mostrou que o COA dominante variou ao longo do tempo e espaço, com uma maior variabilidade durante o período de enchente, enquanto que durante a vazante, os lagos podem ser considerados opticamente homogêneos. Para indicar a contribuição de cada COA, a Figura 5.2 apresenta um ternário contendo as absorções por CDOM, fitoplâncton e detrito como eixos, para quatro comprimentos de onda de referência (400 nm, 440 nm, 550 nm e 676 nm). Os comprimentos de onda foram selecionados de forma a avaliar a contribuição dos COAs em diferentes regiões do espectro. 400 nm é caracteristicamente dominado por uma alta absorção de CDOM e detrito, e baixa absorção de fitoplâncton. 440 nm é caracterizado pelo primeiro pico de absorção da clorofila-a, assim como alta contribuição de CDOM e detrito. 550 nm é caracterizado pela ausência de um componente dominante, com valores mais baixos de absorção para os 3 COAs. Por fim, 676 nm é caracterizado por um domínio por fitoplâncton devido ao segundo pico de absorção da clorofila-a.

Figura 5.2 Ternário do coeficiente de absorção para os COAs presentes na água para 4 comprimentos de onda (400, 440 550 e 676 nm) e para as 3 fases coletadas. A numeração na legenda se refere as missões em que cada ponto foi coletado. As missões 2 e 3 se referem ao período de enchente, enquanto que as missões 1, 4 e 5 se referem ao período de vazante. A distribuição de cores se refere aos 4 lagos analisados. Os círculos representam a primeira missão durante a fase do pulso, e os triângulos representam a segunda missão.



Fonte: Produção do autor.

Durante o período de vazante a contribuição dos COAs foi semelhante para os 4 lagos. Em geral, em 400 e 440 nm, a a_{CDOM} e a_{det} contribuíram com 40%

cada, enquanto que o a_{phy} contribuiu <20%. Em 550 nm, os 3 componentes contribuíram de forma semelhante, enquanto que em 676 nm, o a_{phy} foi responsável por >40%, enquanto que o a_{det} e o a_{CDOM} contribuíram <40%. Apesar da semelhança na distribuição da contribuição dos três COAs, em 676 nm, a_{phy} atingiu picos de contribuição entre 60 e 80%, indicando a dominância por a_{phy} , como esperado.

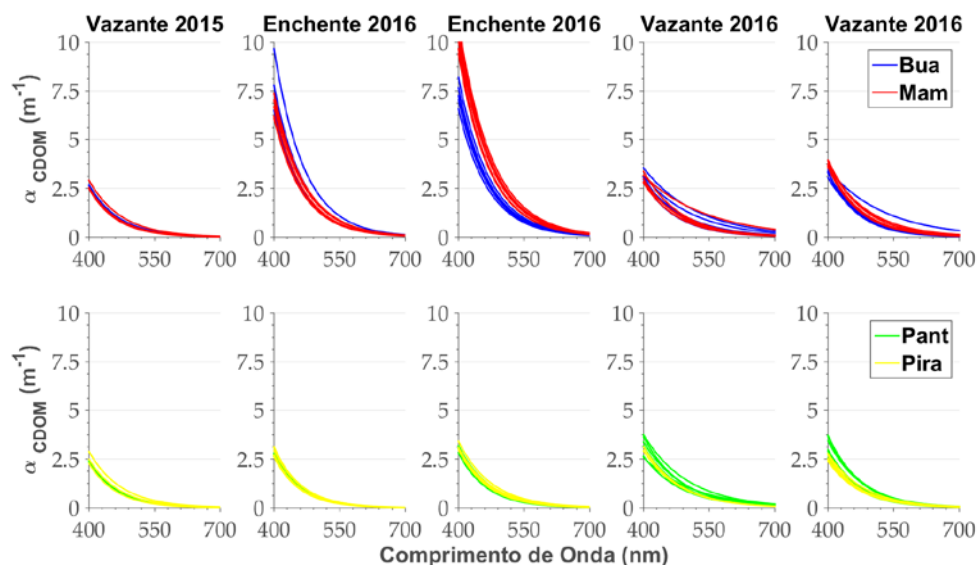
Para o período de enchente, o padrão de contribuição foi distinto entre os lagos claros e escuros. Em 400 e 440 nm, nos lagos claros (verde e amarelo), as contribuições foram a_{det} >40%, a_{CDOM} <40% e a_{phy} <20%. Comparando com os valores obtidos na vazante, a contribuição de a_{det} foi maior, atingindo valores acima de 80% para estes comprimentos de onda. Para os lagos escuros (vermelho e azul), as contribuições foram a_{CDOM} >60%, a_{det} <30% e a_{phy} <20%, indicando uma inversão no padrão observado nos lagos claros, com o domínio da componente CDOM. Para os 4 lagos, a contribuição de a_{phy} foi abaixo de 20% e relativamente estável, de forma que a absorção pela componente a_{dg} é constante nos 4 lagos durante este período, e o que varia é o domínio por CDOM ou detrito. Em 550 nm, o padrão se mantém, com um pequeno aumento na contribuição pelo a_{phy} . Por fim, em 676 nm, nota-se uma grande variabilidade na contribuição, com a manutenção dos 2 grupos de lagos, e dominância por a_{phy} . Apesar do a_{CDOM} e do a_{det} possuírem equações exponenciais e a tendência de valores próximos de zero na região do vermelho, os resultados indicam que estes ainda possuem uma contribuição significativa nesta região, o que pode impactar a obtenção de valores de a_{phy} derivados de algoritmos semi analíticos.

A primeira parte da análise de caracterização bio-óptica do ambiente mostrou a variação entre os componentes, enquanto a segunda parte da análise visa quantificar a variação intra componentes, averiguando se as variações observadas são significativas ou não. Para a_{CDOM} (Figura 5.3), a análise ANOVA mostrou que em geral, os lagos são opticamente semelhantes durante

o todo o ano ($p < 0,01$), com exceção dos lagos Bua Bua e Mamirauá durante a enchente (missões 2 e 3). Para o a_{det} (Figura 5.4), observa-se um padrão semelhante, com águas opticamente semelhantes durante todo o ano ($p > 0,01$), com exceção dos lagos Pirarara e Pantaleão (amarelo e verde) durante o período de enchente. Já para o a_{phy} , não é possível identificar um padrão claro (Figura 5.5). Os resultados mostram que durante o período de vazante, os 4 lagos são opticamente semelhantes, mas durante o período de enchente, a posição em relação a floresta e ao Rio Japurá impacta de forma significativa. Para os lagos Pirarara e Pantaleão, localizados próximos ao Japurá e com conexão direta, ocorre um aumento no aporte de material inorgânico provenientes dos Rios Solimões e Japurá. Para os lagos Bua Bua e Mamirauá, a floresta atua como um filtro, retendo os compostos de maior diâmetro (detrito) enquanto que os menores (CDOM) são carregados para os lagos, o que pode explicar as diferenças nos espectros de absorção do a_{det} e a_{CDOM} . Os resultados estão condizentes com os parâmetros limnológicos. Hestir et al., 2015 descrevem a correlação direta entre DOC e a_{CDOM} , a qual pode ser observada para a RDSM, com o aumento de DOC e a_{CDOM} durante o período de enchente (Figura 5.1 e Figura 5.3). Pode-se observar um aumento no a_{det} durante o período de enchente para os 4 lagos, sendo este mais evidente nos lagos claros, condizendo com os valores de TSS. Comparando o $a_{CDOM}(\lambda)$ obtidos na RDSM com outras áreas de estudo, pode-se notar que eles estão condizentes com o observado em ambientes opticamente complexos. Na revisão apresentada em Brezonik et al. (2015), pode-se notar uma grande variabilidade nos valores de $a_{CDOM}(440)$ para os lagos de Minnesota e Wisconsin, com mínimos abaixo de 1 m^{-1} , e atingindo até valores acima de 25 m^{-1} . Já para a Amazônia, Martinez et al. (2015) observou grande variabilidade no valor de $a_{CDOM}(440)$ em função no tipo de água, com valores mais altos em ambientes de água preta, seguidos por lagos dentro da planície de inundação, água brancas e por fim águas claras, com valores de $7,9 \text{ m}^{-1}$, $4,8 \text{ m}^{-1}$, $3,3 \text{ m}^{-1}$ e $1,8 \text{ m}^{-1}$, respectivamente. Para o Lago Grande do Curuai, Carvalho (2016) observou valores entre 1 m^{-1} e $2,5 \text{ m}^{-1}$, amplitude semelhante à dos lagos

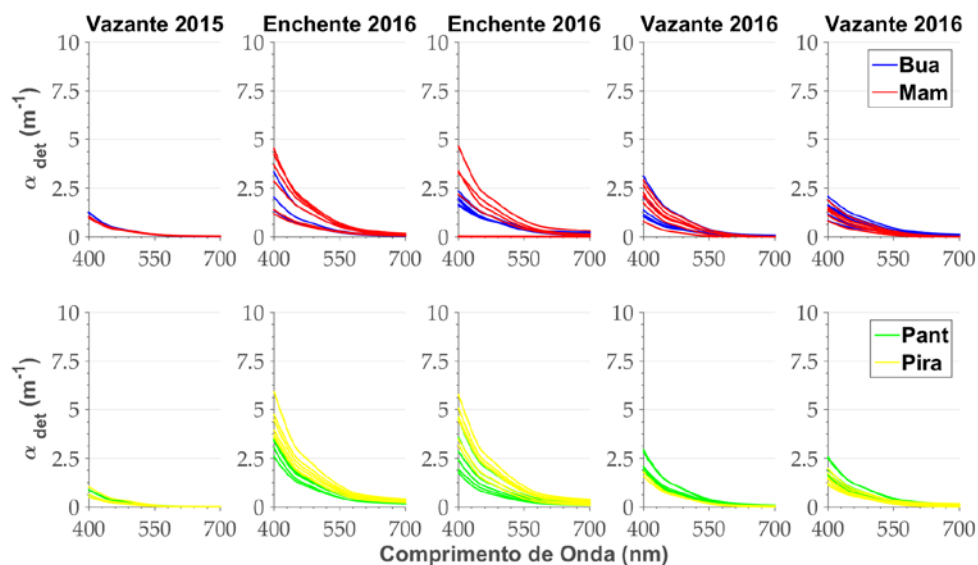
claros da RDSM. Quanto a distribuição de a_{det} (440) os valores encontrados em Curuai são superiores aos observados na RDSM, condizente com os valores de TSS obtidos para cada área de estudo (Figura 5.1). Comparando os valores de a_{det} (440) medidos na RDSM com os obtidos para o lago Taihu (Zhang et al., 2007), é possível encontrar semelhanças nos valores obtidos durante o verão. Entretanto, o autor observou valores médios de $50,6 \mu g/L$ de Chl-a, de forma que o espectro de absorção do material particulado é dominado por a_{phy} . Já para o inverno, pode-se notar que os espectros são dominados por a_{det} , por conta da alta concentração de TSS (média = $130 mg/L$) e relativa baixa concentração de Chl-a (média = $16,5 \mu g/L$), como também observado para a RDSM.

Figura 5.3 Coeficiente de absorção do CDOM para as 5 missões e 4 lagos analisados. As missões 2 e 3 se referem ao período de enchente de 2016, enquanto que as missões 1, 4 e 5 se referem ao período de vazante de 2015 e 2016. A distribuição de cores se refere aos 4 lagos analisados.




Fonte: Produção do autor.

Figura 5.4 Coeficiente de absorção do detrito para as 5 missões e 4 lagos analisados. As missões 2 e 3 se referem ao período de enchente de 2016, enquanto que as missões 1, 4 e 5 se referem ao período de vazante de 2015 e 2016. A distribuição de cores se refere aos 4 lagos analisados.



Fonte: Produção do autor.

Figura 5.5 Coeficiente de absorção do fitoplâncton para as 5 missões e 4 lagos analisados. As missões 2 e 3 se referem ao período de enchente de 2016, enquanto que as missões 1, 4 e 5 se referem ao período de vazante de 2015 e 2016. A distribuição de cores se refere aos 4 lagos analisados.

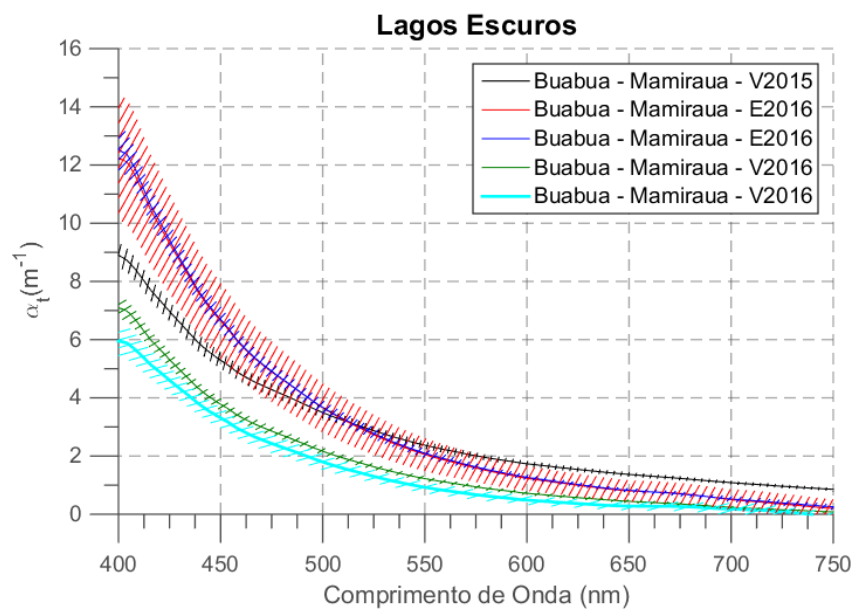


Fonte: Produção do autor.

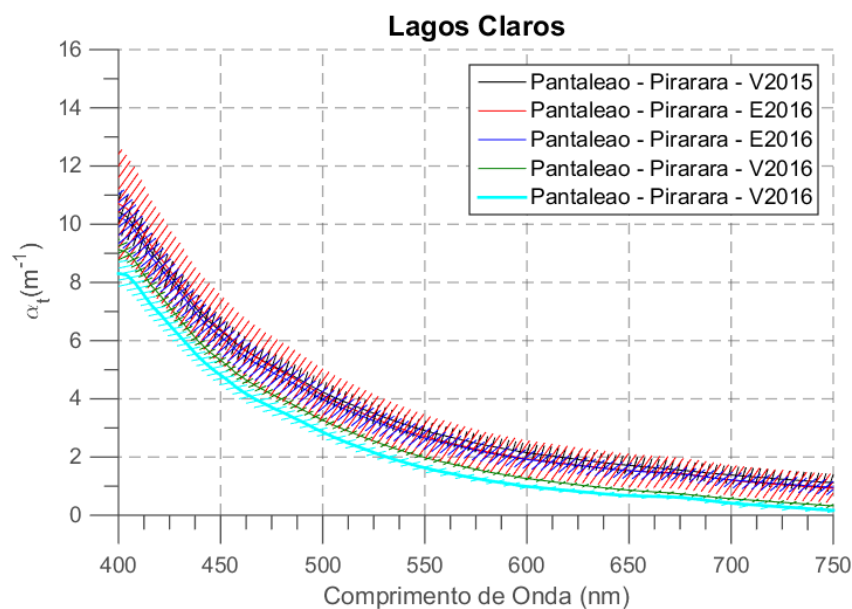
5.1.2.2 IOPs medidas *in situ*

Os valores médios de a_t medidos com o AC-S e corrigidos pela absorção da água podem ser observados nas Figura 5.6 a e Figura 5.6 b. A Figura 5.6 a apresenta as medidas para os lagos escuros, enquanto que a Figura 5.6 b apresenta para os lagos claros. Em geral, os espectros apresentam um comportamento exponencial em todos os casos, e não é possível identificar picos de absorção por fitoplâncton, indicando o domínio do a_{dg} . Especificamente, a_t em 400 nm variou entre 6 e 14 m^{-1} (~1,05 de desvio padrão durante a enchente e ~0,46 durante a vazante) para os lagos escuros, e pode-se observar valores mais altos durante a enchente (M2 e M3). Para os lagos claros a variou entre 8 e 12 m^{-1} , com maior amplitude no desvio padrão durante o período de enchente (~1,08 de desvio padrão durante a enchente e ~0,39 durante a vazante). Os valores são condizentes com o observado em laboratório (concentração de DOC e TSIS), onde os maiores valores se referem as missões 2 e 3.

Figura 5.6 Valores médios dos coeficientes de absorção total medidos pelo AC-S para os lagos escuros (a) e claros (b). A distribuição de cores se refere as 5 missões. A linha contínua representa os valores médios e a barra de erro se refere ao desvio padrão. “E” se refere a enchente e “V” se refere a vazante.



(a)

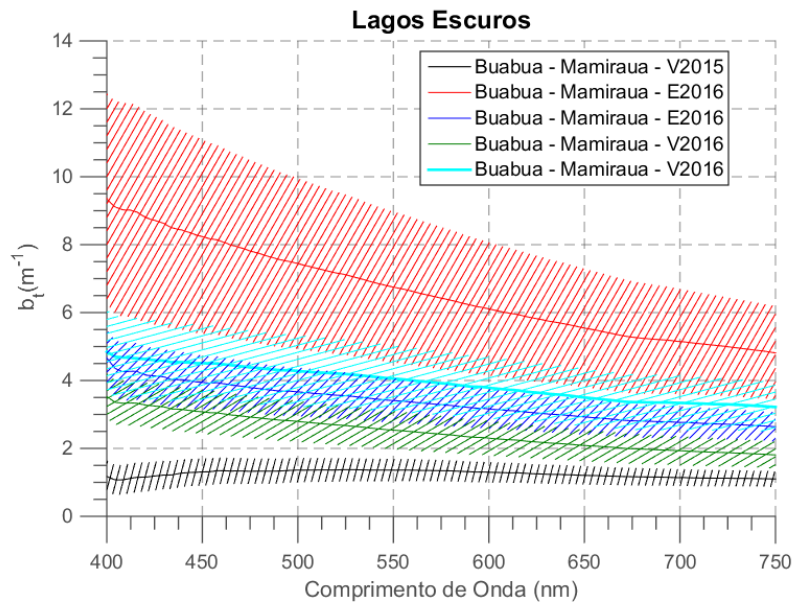


(b)


Fonte: Produção do autor.

Todavia, ao analisarmos os valores de espalhamento estimados a partir da atenuação medida pelo ACS (Figura 5.7 a), nota-se uma grande variação no valor de b para os lagos claros (Figura 5.7b). Durante o período de vazante, os valores variaram entre 2,5 e 8 m^{-1} em 400 nm, enquanto que durante o período de enchente este variou entre 14 e 31 m^{-1} em 400 nm. O retroespalhamento, e consequentemente o espalhamento é influenciado pela variação na composição e concentração dos COAs, como tamanho de partícula e proporção entre as frações orgânicas e inorgânicas, e dentre estas, as partículas inorgânicas possuem o maior impacto em b_b , sugerindo que os lagos claros, como por exemplo o Pantaleão, possuem uma maior concentração de partículas inorgânicas. Comparando com os valores de concentração de TSIS medidos *in situ*, os resultados condizem com o observado, uma vez que durante o período de enchente, ocorre um aumento expressivo na concentração do TSIS (Figura 5.1). Para os lagos escuros, observa-se valores similares aos lagos claros durante o período de vazante (1 – 6 m^{-1}), além de um aumento durante o período de enchente (3 – 12 m^{-1}). Considerando que o b_b foi estimada a partir de b ($\frac{b_b}{b} = 0,05$), os valores de b_b nos lagos escuros da RDSM ficaram entre 0,15 e 0,6 m^{-1} e para os lagos claros entre 0,35 e 1,5 m^{-1} . Ao comparar a amplitude observada para a RDSM com a amplitude observada em Carvalho et al. (2015), pode-se notar que estas são semelhantes. Para o Lago Grande do Curuai, os autores observaram mínimos em torno de 0,5 m^{-1} e máximos em torno de 1,6 m^{-1} , indicando que os resultados encontrados condizem com o esperado.

Figura 5.7 Valores médios dos coeficientes de espalhamento total medidos pelo AC-S para os lagos escuros (a) e claros (b). A distribuição de cores se refere as 5 missões. A linha contínua representa os valores médios e a barra de erro se refere ao desvio padrão. “E” se refere a enchente e “V” se refere a vazante.



(a)



(b)

Fonte: Produção do autor.

Tabela 5.2 Distribuição das IOPs dos lagos da RDSM. Os lagos Escuros se referem aos lagos Bua Bua e Mamirauá e os lagos Claros se referem aos lagos Pantaleão e Pirarara. Média se refere aos valores médios, DP ao desvio padrão, CV ao coeficiente de variação, Min ao mínimo e Max ao máximo. c (m^{-1}) se refere ao coeficiente de atenuação, a (m^{-1}) ao coeficiente de absorção e b (m^{-1}) ao coeficiente de retroespalhamento.

Lagos/Fase	Parâmetros	c (m^{-1}) 443	c (m^{-1}) 670	a (m^{-1}) 443	a (m^{-1}) 670	b (m^{-1}) 443	b (m^{-1}) 670
Escuros Enchente	Média	14,10	5,06	7,55	0,79	5,55	3,62
	DP	4,05	2,20	0,89	0,25	3,14	1,83
	CV	0,29	0,43	0,12	0,32	0,57	0,51
	Min	10,93	2,84	5,98	0,41	2,80	1,91
	Max	25,91	11,48	9,23	1,57	14,48	8,79
Escuros Vazante	Média	7,88	3,16	4,13	0,51	3,18	2,24
	DP	1,10	0,79	0,92	0,40	1,28	0,86
	CV	0,14	0,25	0,22	0,80	0,40	0,38
	Min	5,92	1,71	2,87	0,10	0,81	0,84
	Max	10,58	5,03	6,07	1,35	5,60	3,85
claros enchente	Média	31,78	16,88	6,86	1,48	21,11	13,05
	DP	10,65	6,44	1,09	0,41	8,20	5,25
	CV	0,34	0,38	0,16	0,28	0,39	0,40
	Min	15,67	6,88	4,93	0,81	8,48	4,82
	Max	57,54	31,84	9,98	2,64	40,30	24,75
claros vazante	Média	12,94	5,74	5,80	0,89	6,05	4,11
	DP	2,28	1,31	0,70	0,41	2,18	1,32
	CV	0,18	0,23	0,12	0,46	0,36	0,32
	Min	8,37	3,46	4,69	0,52	1,99	1,88
	Max	17,47	8,61	7,26	2,26	9,94	6,71

Fonte: Produção do autor.

Tabela 5.3 Distribuição das IOPs dos lagos da RDSM. Os lagos Escuros se referem aos lagos Bua Bua e Mamirauá e os lagos Claros se referem aos lagos Pantaleão e Pirarara. Média se refere aos valores médios, DP ao desvio padrão, CV ao coeficiente de variação, Min ao mínimo e Max ao máximo. $acdom(m^{-1})$ se refere ao coeficiente de absorção do CDOM, $adet(m^{-1})$ ao coeficiente de absorção do detrito, $aphy(m^{-1})$ ao coeficiente de absorção do fitoplâncton e $bb(m^{-1})$ ao coeficiente de retroespalhamento.

Lagos/Fase	Parâmetros	$acdom$ (m^{-1}) 443	$adet$ (m^{-1}) 443	$aphy$ (m^{-1}) 667	bb (m^{-1}) 442
Escuros Enchente	Média	4,36	1,46	0,76	0,19
	DP	0,95	0,68	0,35	0,18
	CV	0,22	0,47	0,46	0,93
	Min	3,17	0,03	0,26	0,06
	Max	6,23	2,62	1,57	0,80
Escuros Vazante	Média	1,85	0,86	0,64	0,12
	DP	0,35	0,35	0,27	0,07
	CV	0,19	0,41	0,42	0,59
	Min	1,25	0,36	0,24	0,05
	Max	2,50	1,67	1,28	0,30
Claros Enchente	Média	1,46	1,92	0,66	2,52
	DP	0,20	0,85	0,25	2,46
	CV	0,13	0,44	0,38	0,97
	Min	1,13	0,24	0,10	0,55
	Max	1,92	3,32	0,98	11,68
Claros Vazante	Média	1,68	1,11	0,70	0,30
	DP	0,30	0,54	0,25	0,07
	CV	0,18	0,49	0,36	0,22
	Min	1,18	0,30	0,19	0,18
	Max	2,45	2,61	1,14	0,43


Fonte: Produção do autor.

5.1.3 Reflectância de Sensoriamento Remoto

Considerando que os lagos da RDSM se encontram circundados por floresta, e são relativamente estreitos, a velocidade do vento é baixa, não havendo cisalhamento, e conseqüentemente não formando ondas. Este efeito é ainda

mais evidente nos lagos Bua Bua e Mamirauá, uma vez que se situam na área mais densa da floresta. Como foi observado em campo e está exemplificado na Figura 5.8 e Figura 5.9 a superfície da água se assemelha a um espelho, e conseqüentemente, a radiância ascendente contém tanto o espectro da água quanto do céu. Este efeito é comumente observado, e diferentes metodologias foram propostas para a redução deste (MOBLEY, 1999; KUTSER, 2013). Como primeira etapa da análise dos dados obtidos e que serão utilizados como parâmetro de entrada dos algoritmos semi-analíticos, esta seção apresenta os resultados obtidos para os dois métodos de correção.

Figura 5.8 Exemplo do efeito do glint para uma estação amostral do lago Mamirauá.



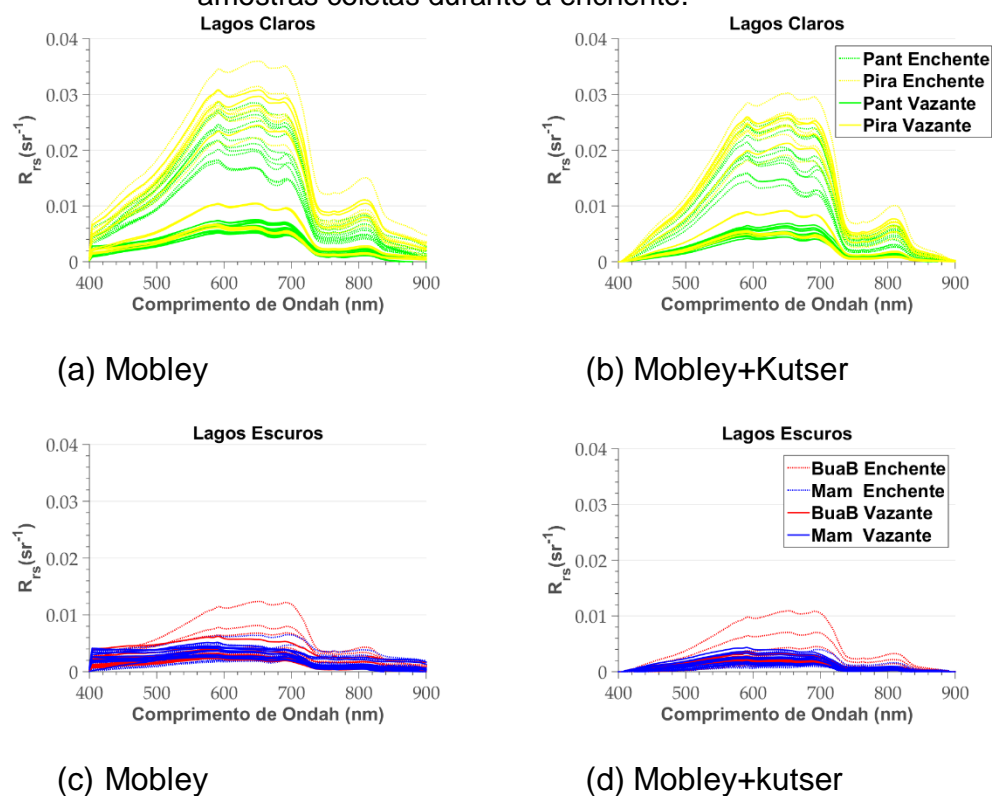
Fonte: Produção do autor.

Tanto o método de correção proposto por MOBLEY quanto o proposto por KUTSER visam diminuir o impacto dos efeitos de glint do sol e do céu. MOBLEY assume que durante a medição, parte da radiância ascendente da água é devido ao glint, e que esta pode ser removida por meio da medição da radiância descendente do céu e o uso de um índice, que depende da geometria de

aquisição do dado (latitude, longitude e hora) e condições de medição (velocidade do vento).

Para o conjunto de espectros de R_{rs} obtidos *in situ* (Figura 5.9), é evidente a diferença de magnitude entre os 4 lagos, com valores até 4 vezes maiores para os lagos claros. Ao comparar os 2 métodos de correção, a maior diferença está atribuída aos menores comprimentos de onda, devido a correção pelo ajuste exponencial feita pelo método Kutser (2013).

Figura 5.9 R_{rs} estimada pelas metodologias Mobley e Mobley+Kutser. As cores se referem aos 4 lagos analisados. As linhas contínuas se referem as amostras coletadas durante a vazante e a linha pontilhada se refere as amostras coletas durante a enchente.



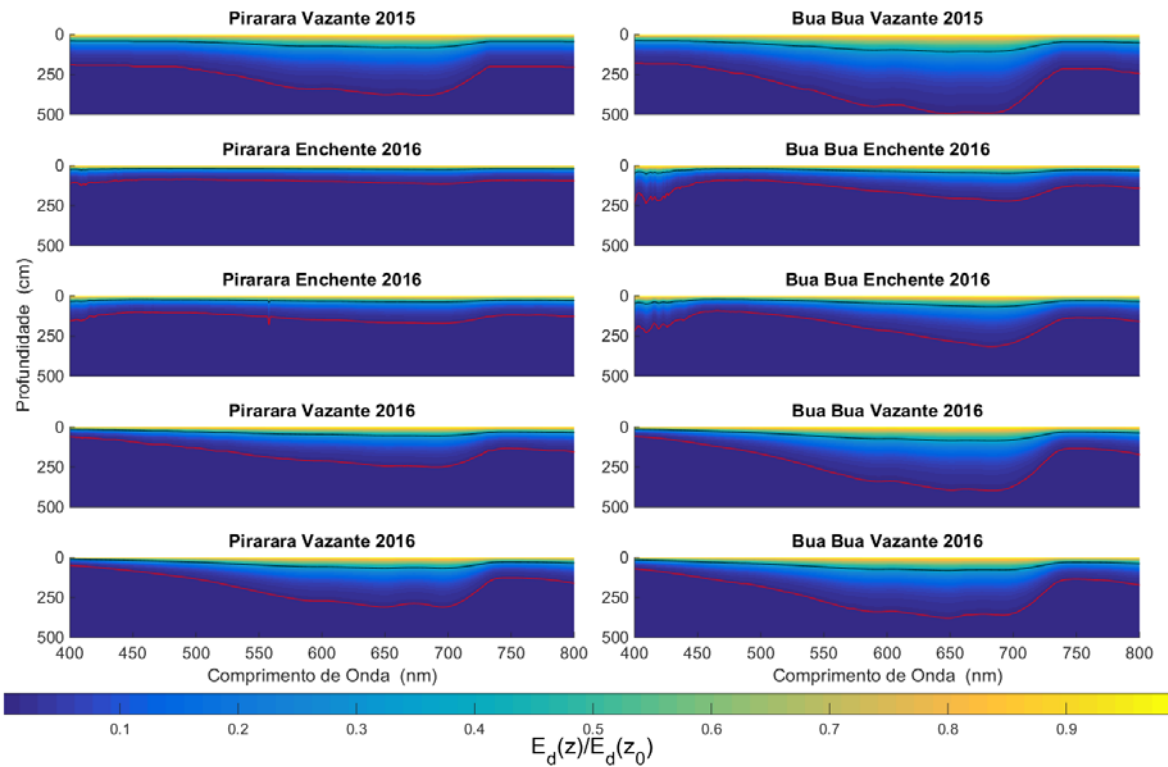
Fonte: Produção do autor.

Considerando os algoritmos semi-analíticos propostos, os dois métodos de correção foram utilizados, visando identificar qual é o mais adequado em cada situação e identificar possíveis fontes de incerteza.

5.1.4 Coeficiente de Atenuação Vertical Difuso K_D da luz

Para exemplificar a distribuição do campo de luz subaquático calculado a partir do K_D ao longo do tempo e espaço, a Figura 5.10 mostra a disponibilidade de luz ao longo da profundidade e do espectro para uma única estação amostral dos lagos Pirarara e Bua Bua. Deve-se levar em conta que para a profundidade de interesse, equivalente a $\frac{1}{\text{secchi}}$ as águas da RDSM não possuem estratificação vertical e desta forma, um único valor de K_D é representativo para toda a coluna d'água. A linha preta representa $\frac{1}{K_D}$ e a linha vermelha representa 1% da zona eufótica (Z_{eu}). Pode-se notar que a maior variabilidade está atribuída às missões 2 e 3 na qual as linhas vermelha e preta estão mais próximas da superfície, indicando uma maior atenuação, resultado condizente com o observado pelos dados limnológicos e de coeficiente de absorção (Figura 5.1, Figura 5.2, Figura 5.3 e Figura 5.4). Além disso, ao comparar o lago Bua Bua com o Pirarara, os valores de K_D são menores para as 5 missões, provavelmente devido a menor contribuição de TSIM no valor de b_b , como foi evidenciado na Figura 5.4.

Figura 5.10 Distribuição do campo de luz subaquático para um único ponto dos lagos Pirarara e Bua Bua em cada missão de campo. A distribuição de cores se refere ao valor de E_d estimado a partir do K_D para cada profundidade e comprimento de onda, e normalizado pelo valor em superfície. A linha preta representa $\frac{1}{K_D}$ e a linha vermelha representa 1% da zona eufótica (Z_{eu}).



Fonte: Produção do autor.

5.2 Avaliação do impacto das características dos sensores OLI, OLCI e MSI nos algoritmos bio-ópticos

5.2.1 Simulação do Dataset

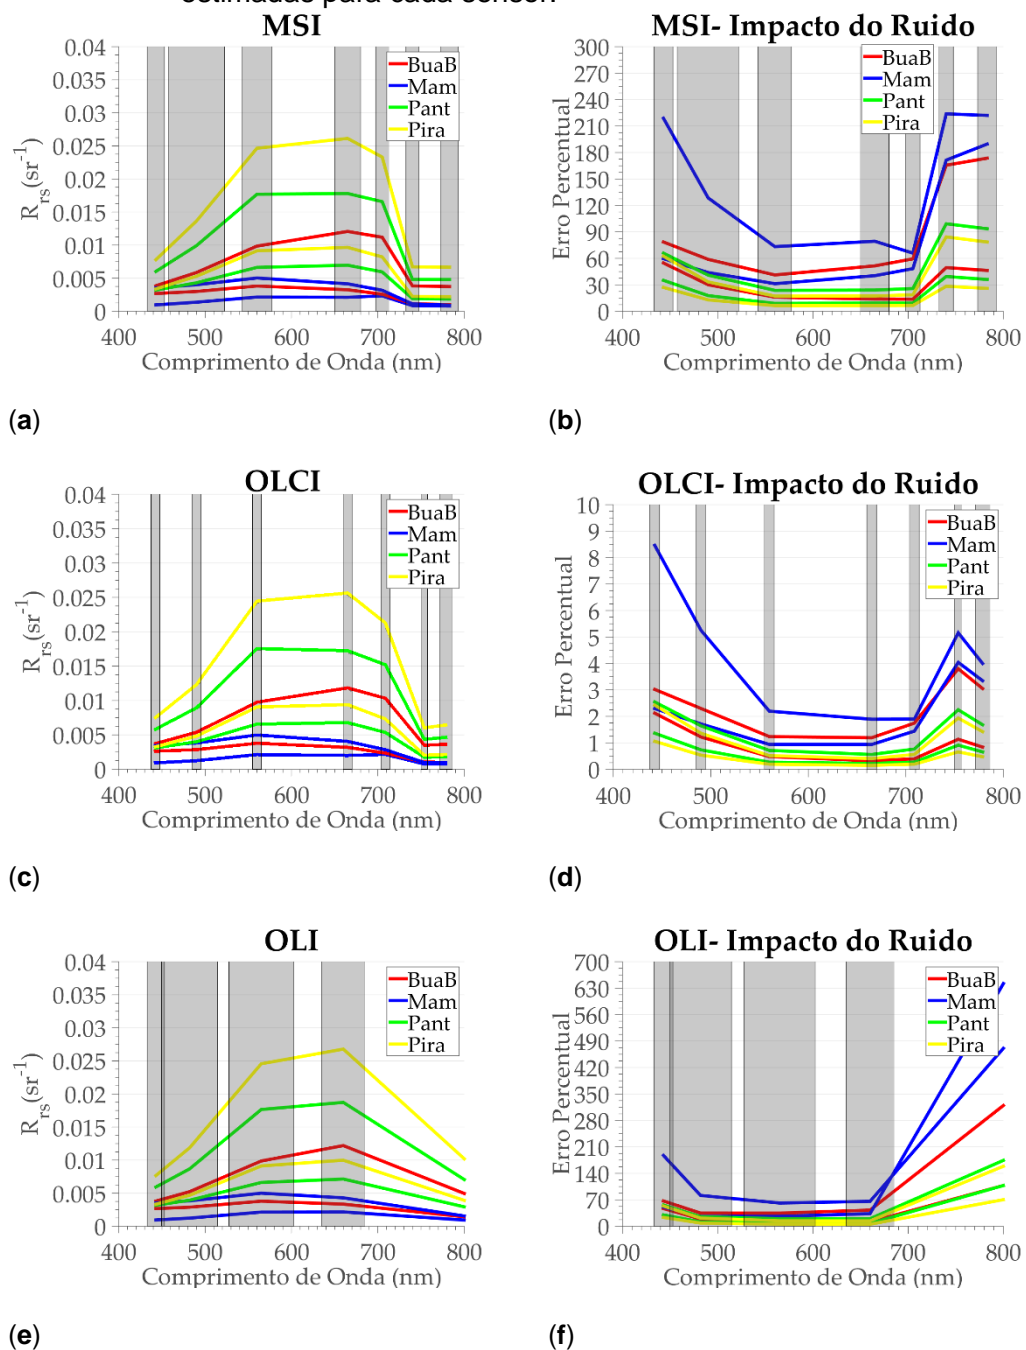
Considerando que o foco desta etapa foi identificar o impacto das características dos sensores disponíveis nos algoritmos bio-ópticos, foram selecionados sensores com diferentes combinações de SNR, e resoluções radiométricas e espaciais. Adicionalmente, a seleção dos diferentes algoritmos empíricos permitiu verificar se a estrutura e equação do algoritmo contribui para a propagação das incertezas provenientes das características dos sensores.

Apesar da resolução radiométrica do sensor OLCI não ser ideal para os lagos da RDSM, o propósito desta análise é avaliar as diferentes características dos sensores, e neste caso, avaliar como os diferentes valores de SNR impactam dos resultados dos algoritmos bio-ópticos.

Os valores simulados de R_{rs} para os sensores OLI, OLCI e MSI a partir da correção de Mobley, e os seus erros relativos podem ser observados na Figura 5.11. Considerando as características ópticas dos sensores, OLCI apresenta a melhor resolução espectral e número de bandas, permitindo uma descrição mais acurada do espectro de R_{rs} . Em contrapartida, sua resolução espacial (300 m) limita suas aplicações no estudo de lagos pequenos e estreitos, ao contrário dos sensores OLI e MSI com resolução de até 30m.

Desconsiderando as características ópticas dos sensores, a percentagem de erro devido ao ruído é maior nas bandas do azul e NIR do que nas demais (Figura 5.11 b,d e f). O alto impacto relativo nas bandas do azul é devido ao maior sinal proveniente da atmosfera em relação aos comprimentos de onda mais longos. Entretanto, no NIR, o erro relativo é devido a menor SNR (Tabela 4.1, Tabela 4.2 e Tabela 4.3). O sensor OLI possui o maior impacto devido ao ruído relativo, atingindo 700% no NIR (Figura 5.11f), enquanto que para o sensor MSI, o valor máximo é 250% (Figura 5.11b), e para o OLCI o valor máximo é 10% (Figura 5.11d) no azul. Considerando estes resultados, os algoritmos para a obtenção de medidas ópticas devem incluir bandas entre 550 e 700 nm, onde os erros relativos são abaixo de 50% para todos os casos. Um outro aspecto importante é o erro relativo para cada lago, como uma função da transparência da água. Os maiores erros foram observados no Mamirauá e no Bua Buá (lagos escuros), enquanto que os erros no Pirarara e Pantaleão (lagos claros) estão abaixo de 50% para todas as bandas (Figura 5.11). Os resultados indicam que antes de selecionar um sensor, é crucial considerar a amplitude da R_{rs} , desde que a resolução espacial esteja adequada as limitações de tamanho e forma dos lagos.

Figura 5.11 R_{rs} espectral simulada para os sensores MSI, OLCI e OLI. A primeira coluna se refere aos valores de R_{rs} sem ruído e a segunda coluna se refere ao erro percentual na R_{rs} devido ao ruído. A distribuição de cores se refere aos 4 lagos e as barras em cinza se referem as bandas estimadas para cada sensor.



Fonte: Produção do autor.

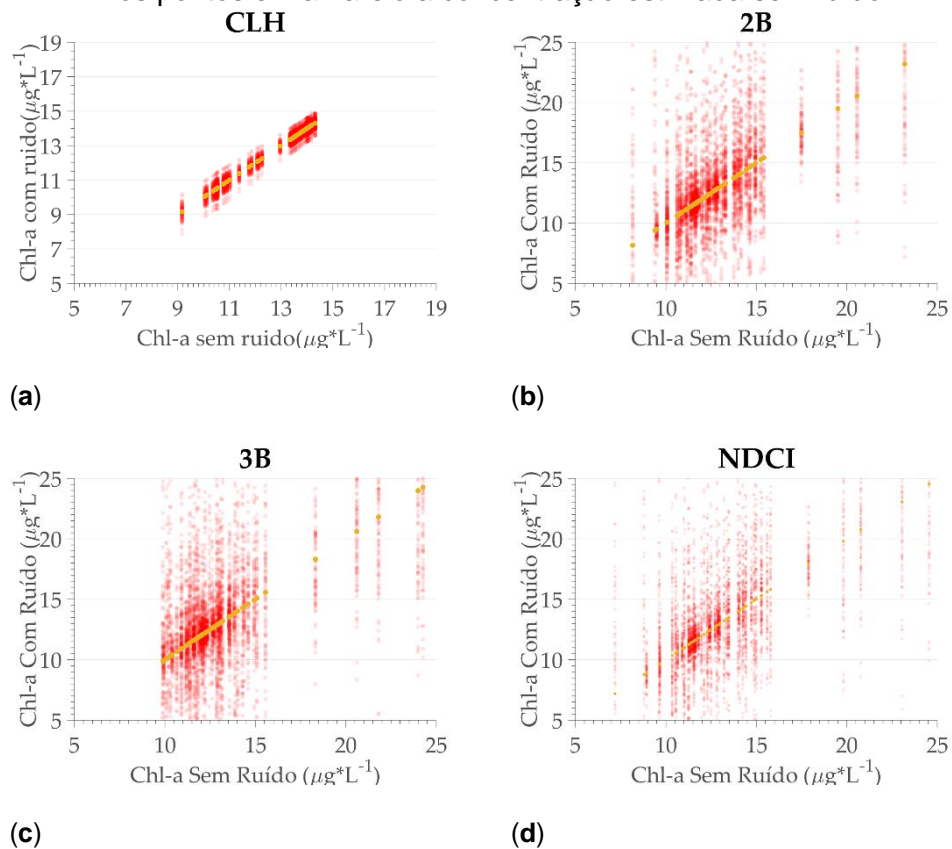
5.2.2 Avaliação dos algoritmos

Um total de $306 \cdot 10^3$ espectros foram utilizados nesta avaliação, os quais foram simulados para cada sensor (3) a partir 102 espectros medidos *in situ*. Para cada espectro simulado foram gerados 1000 espectros com ruídos aleatórios (seção 4.2.3) e 1 espectro sem ruído (“verdade terrestre”). Os algoritmos avaliados foram apresentados na Tabela 4.6. Vale ressaltar que nesta avaliação, apesar da largura e posição das bandas serem fontes de incerteza, assume-se que a amplitude do erro depende apenas do SNR de cada sensor.

5.2.2.1 Clorofila-a


Os resultados demonstram que a acurácia relativa na estimativa de Chl-a é altamente dependente da equação do algoritmo da magnitude da R_{rs} . Em geral, o erro na concentração aumenta de algoritmos baseados em adição (CLH - Tabela 4.6 Figura 5.12a e Figura 5.13a) para algoritmos baseados em razão de banda (2B, 3C, NDCI - Tabela 4.6 Figura 5.12b,c,d e Figura 5.13 b,c,d). Adicionalmente, o maior erro foi observado para o sensor MSI (Figura 5.12). Apesar da largura e posição das bandas serem fontes de incerteza para os algoritmos, esse método compara os conjuntos de dados com e sem ruído para cada sensor, assumindo que a amplitude do erro depende apenas do SNR de cada sensor.

Figura 5.12 Performance de cada algoritmo utilizado para estimar a concentração de Chl-a para o sensor MSI. (a) CLH; (b) 2B; (c) 3B; (d) NDCI. Os pontos em vermelho representam a concentração estimada incluindo o ruído e os pontos em amarelo a concentração estimada sem ruído.



Fonte: Produção do autor.

Figura 5.13 Performance de cada algoritmo utilizado para estimar a concentração de Chl-a para o sensor OLCI. (a) CLH; (b) 2B; (c) 3B; (d) NDCI. Os pontos em vermelho representam a concentração estimada incluindo o ruído e os pontos em amarelo a concentração estimada sem ruído.



Fonte: Produção do autor.

No algoritmo *CLH* (Figura 5.12a e Figura 5.13a), a relação entre bandas é aditiva, logo o impacto do ruído é reduzido quando comparado a algoritmos multiplicativos (Figura 5.12b-d e Figura 5.13b-d). O erro na concentração é afetado pela inclinação do algoritmo, enquanto que a contribuição pelo intercepto é constante para todas as concentrações; logo, um erro relativo maior é esperado para concentrações baixas, devido à incerteza atribuída ao intercepto. Para este algoritmo, o impacto do ruído na estimativa de concentração não depende da amplitude da R_{rs} , como pode ser observado na Figura 5.13a onde uma variação na R_{rs} não afeta a amplitude do erro.

Um padrão distinto é observado para os algoritmos de razão de banda (2B, 3B e NDCI, Figura 5.12b-d e Figura 5.13b-d). Neste caso, a interferência pelo ruído pode ter um impacto construtivo ou destrutivo. Quando comparado ao algoritmo aditivo (*CLH*), um aumento na amplitude de erro foi observado para todas as concentrações. Os maiores erros relativos foram observados em concentrações mais baixas.

O impacto da SNR na estimativa da concentração de Chl-a mudou de acordo com as equações do algoritmo (Figura 5.12 e Figura 5.13). A maioria dos métodos para quantificar o impacto da SNR em algoritmos bio-ópticos utiliza o RMSE ou o NRMSE (4.25 e 4.26). Por exemplo, MOSES et al (2000) observou erros relativos de até 40% para o algoritmo OC4 e de 25% para algoritmos de duas bandas no vermelho e no NIR para o HICO. Gerace et al. (2000) usou um algoritmo de otimização para o OLI e MERIS e observou erros de 35% para a clorofila-a. Esses erros, entretanto, foram computados assumindo que a magnitude da R_{rs} , equações do algoritmo e ruído são independentes. Baseado nos resultados deste estudo, e considerando que o OCx (HU et al., 2012) é um polinomial de quarta ordem (não testado no trabalho), espera-se uma maior amplitude no erro durante a estimativa de Chl-a, devido ao SNR.

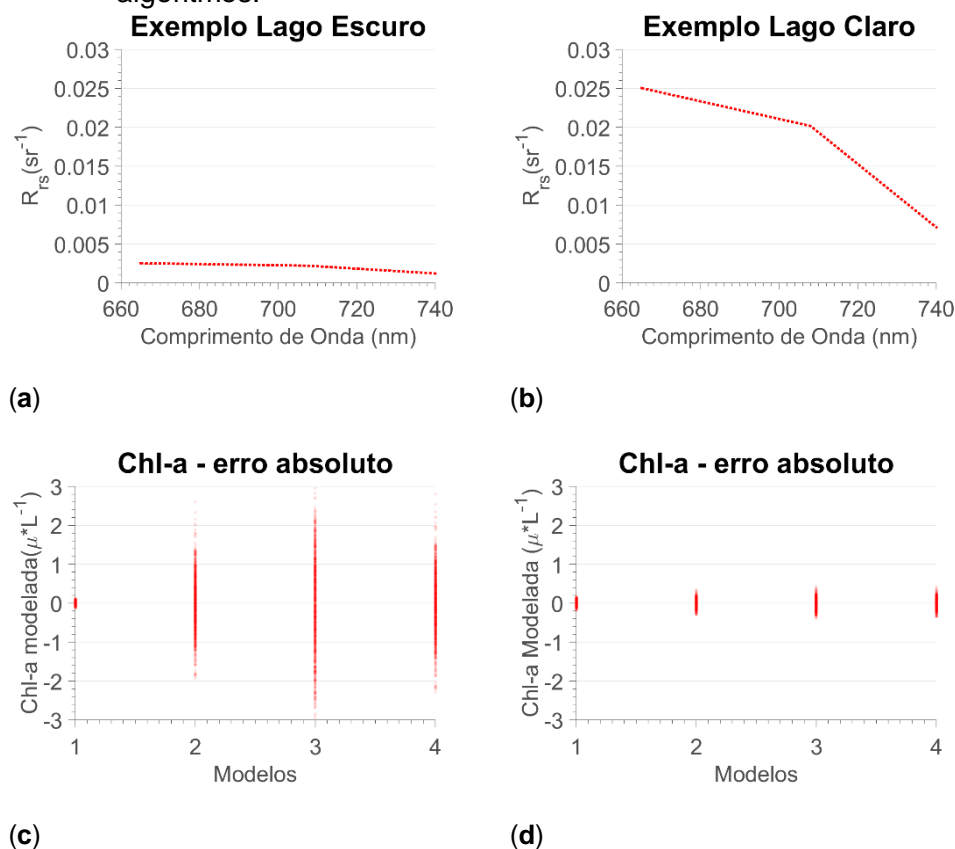
Para o algoritmo *CLH*, a amplitude do erro mudou para cada sensor, mas a forma da distribuição se manteve. A amplitude do erro é constante para todas as concentrações, com valores de até 2 $\mu\text{g/L}$ para o MSI e 0,1 $\mu\text{g/L}$ para o OLCI. O erro relativo é maior para baixas concentrações (até 11%) e diminui pela metade em concentrações mais altas (Figura 5.12 e Figura 5.13).

Para os algoritmos 2B, 3B e NDCI, a forma da distribuição do conjunto de dados com ruído aparenta ser errática (sem um padrão), com diferentes amplitudes para concentrações semelhantes nos 3 algoritmos (Figura 5.12 e Figura 5.13). Como o padrão errático não depende do tipo de algoritmo aplicado nem da concentração de clorofila-a (Figura 5.12 e Figura 5.13), avaliou-se o impacto da magnitude de R_{rs} no padrão do erro. Com este

propósito, a Figura 5.14 exemplifica esta análise a partir de dois pontos com amplitude extremas.

A análise mostrou que para os espectros *in situ* com R_{rs} de baixa magnitude ($<0,005 \text{ sr}^{-1}$) (Figura 5.14a e Figura 5.14c) a amplitude do erro é maior para os algoritmos 2B, 3B e NDCI do que para o algoritmo CLH. Em contrapartida, para espectros com R_{rs} maior ($>0,01 \text{ sr}^{-1}$) (Figura 5.14b e Figura 5.14d), a amplitude é similar ao do algoritmo CLH. Baseado nesses resultados, o impacto da SNR na estimativa de Chl-a é maior para lagos escuros como o Mamirauá e Bua Bua (erros de até $2 \mu\text{g/L}$) (Figura 5.14c) para o OLCI. Para o MSI, os 3 algoritmos apresentaram um impacto maior do que para o OLCI, devido a pior SNR, com erros acima de $10 \mu\text{g/L}$ (Resultados não apresentados).

Figura 5.14 Exemplo pontual do impacto da magnitude de R_{rs} para o sensor OLCI na estimativa de concentração de Chl-a utilizando os quatro algoritmos. (a) e (c) se referem a uma estação amostral para o Lago Bua Bua e (b) e (d) para o Lago Pirarara. (a) e (b) apresentam a magnitude de R_{rs} e (c) e (d) o erro absoluto na concentração de clorofila-a para os 4 algoritmos.



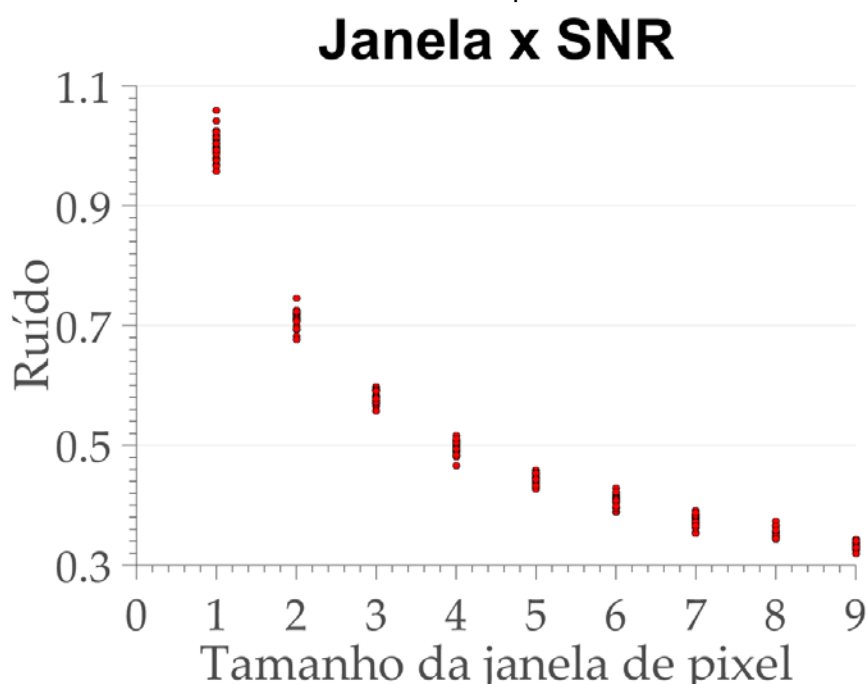
Fonte: Produção do autor.

Para espectros com baixa R_{rs} , a amplitude da distribuição de erro absoluto foi maior do que aqueles com maior R_{rs} . Logo, especificações de futuros sensores voltados para aplicações de imageamento de águas interiores devem requerer tanto um aumento no valor mínimo de SNR quanto uma resolução espacial que se adeque a lagos pequenos e estreitos. Outro aspecto a ser considerado é a equação dos algoritmos. De acordo com Luck (2014), algoritmos de maior ordem aumentam a acurácia e precisão das estimativas. Entretanto, estes algoritmos propagam incertezas na estimativa de Chl-a devido a SNR, particularmente em casos de baixa R_{rs} , diminuindo a acurácia do algoritmo.

Logo, o balanço entre esses dois aspectos deve ser considerado ao aplicar algoritmos de qualidade de água, como foi mostrado neste estudo.

Como o algoritmo *CLH* utiliza operações aditivas, ele pode ser aplicado aos quatros lagos usando os sensores MSI e OLCI, sem nenhum pré-processamento. Entretanto, para algoritmos multiplicativos, pode ser necessário uma reamostragem espacial para aumentar o SNR matematicamente. Por exemplo, com janelas de pixels de 2x2 e 3x3, é possível aumentar o SNR duas e três vezes, respectivamente. Esses incrementos no SNR podem ser calculados pela raiz quadrada da janela de pixels vezes o SNR original (LUCK, 2014) (Figura 5.15). No caso do MSI, a resolução espacial das bandas selecionadas é de 30 m, então a reamostragem pode aumentar o SNR sem comprometer o resultado, para lagos de tamanho adequado. Entretanto, a reamostragem não é adequada devido a resolução espacial de 300m do OLCI para a maior parte dos lagos pequenos, devido a mistura espectral. Logo, ao comparar as características ópticas de sensores para aplicações em águas interiores, é imperativo avaliar a adequabilidade do sensor para cada área de estudo, assim como a possibilidade de pós processamento.

Figura 5.15 Exemplo da relação entre o ruído e o tamanho da janela de pixels, variando de 1x1 até 3x3 pixels.



Fonte: Produção do autor.


5.2.2.2 TSS

Similarmente aos algoritmos para Chl-a, a acurácia relativa durante a obtenção do TSS depende da equação do algoritmo, SNR e magnitude da R_{rs} . Em geral, o erro na concentração do TSS aumenta de algoritmos aditivos (Figura 5.16) para multiplicativos (Figura 5.17) e de algoritmos lineares para exponenciais (Figura 5.18).

Para o algoritmo *TSS_linear* (Tabela 4.6 e Figura 5.16), o impacto do ruído é linear para todos os sensores e intervalos de concentração. O maior erro foi observado para o sensor MSI (~5 mg/L), seguido pelo OLI (~3mg/L) e OLCI (<0,16 mg/L). Considerando que o impacto absoluto do erro é constante para todas as concentrações, o erro relativo será menor para concentrações mais altas. Para o algoritmo *TSS_exp* (Tabela 4.6 e Figura 5.17), observa-se um padrão distinto; em baixas concentrações, o erro é maior, e sua distribuição segue uma curva exponencial em direção as concentrações mais altas. O erro


máximo para o algoritmo TSS_exp atingiu 3 mg/L e 1mg/L para os sensores MSI (Figura 5.16a) e OLI (Figura 5.16c), respectivamente. Por fim, o algoritmo TSS_NSSI (Tabela 4.6 e Figura 5.18) mostrou um padrão errático, similar ao observado nos algoritmos multiplicativos de Chl-a, sugerindo uma dependência da magnitude da R_{rs} , devido à abordagem por razão e banda.

Figura 5.16 Performance do algoritmo TSS_linear para estimativa de concentração de TSS para os 3 sensores selecionados, onde: (a) sensor MSI. (b) sensor OLCI, (c) sensor OLI. Pontos em vermelhos se referem a estimativa de concentração de TSS com ruído e pontos em amarelo ao dado sem ruído.




Fonte: Produção do autor.

Figura 5.17 Performance do algoritmo TSS_exp para estimativa de concentração de TSS para os 3 sensores selecionados, onde: (a) sensor MSI. (b) sensor OLCI, (c) sensor OLI. Pontos em vermelhos se referem a estimativa de concentração de TSS com ruído e pontos em amarelo ao dado sem ruído.



Fonte: Produção do autor.

Figura 5.18 Performance do algoritmo TSS_NSSI para estimativa de concentração de TSS para os 3 sensores selecionados, onde: (a) sensor MSI, (b) sensor OLCI, (c) sensor OLI. Pontos em vermelhos se referem a estimativa de concentração de TSS com ruído e pontos em amarelo ao dado sem ruído.



Fonte: Produção do autor.

Moses et al. (2012) encontrou resultados similares para o HICO, com erros de até 40% para concentrações abaixo de 3 mg/L, e até 5% para concentrações acima de 5 mg/L. Apesar dos autores utilizarem a abordagem “optimized error minimization”, os resultados possuem um padrão similar ao observado para os lagos da RDSM. Gerace et al. (2013) encontrou erros médios de até 15% na concentração de TSS, devido ao impacto do SNR.

A incerteza na obtenção de TSS devido ao SNR é altamente dependente do algoritmo. A equação do algoritmo e o intervalo de concentração determinam a necessidade de reamostragem da imagem em reduzir o impacto do ruído. Os pixels do sensor MSI e OLI possuem 30 m, e são adequados para a maior parte dos lagos, entretanto a SNR pode ser uma limitação. Algoritmos de uma banda costumam ser suficientes para a estimativa de TSS, então a resolução espectral do OLI não é uma restrição, entretanto a SNR, em alguns casos, deve ser matematicamente aumentada, de forma similar aos algoritmos de Chl-a. Apesar da coerência nas estimativas do sensor OLCI, a resolução espacial de 300 m é uma limitação para o estudo de lagos pequenos, como é o caso de alguns lagos da RDSM.

5.3 Algoritmos semi analíticos

As seguintes versões do algoritmo QAA foram testadas: i) QAA v1 (LEE 2002); ii) QAA v4 (LEE et al., 2007); iii) QAA v5 (LEE et al., 2009); iv) QAA v6 (LEE et

al., 2014); v) QAA Li (LI et al., 2016); vi) QAA Mishra (MISHRA et al., 2014) e vii) QAA Watanabe (WATANABE et al., 2016). Entretanto os resultados mostrados se referem a uma versão adaptada e calibrada para a área de estudo, uma vez que as versões anteriores não apresentaram resultados satisfatórios. As modificações feitas nas duas versões do QAA estão descritas nas equações abaixo (Equações 5.1 a 5.5):

$$\chi = \log \left(r_{rs}(443) + \frac{r_{rs}(620)}{r_{rs}(708) + 0,5 \frac{r_{rs}(620)}{r_{rs}(555)} r_{rs}(620)} \right); \quad 5.1$$

Lagos
Escuros

$$a_t(708) = a_w(708) + 10^{-0,8762 - 0,3082\chi + 4,1447\chi^2} (m^{-1})$$

$$\chi = \log \left(r_{rs}(443) + \frac{r_{rs}(665)}{r_{rs}(708) + 15 \frac{r_{rs}(620)}{r_{rs}(555)} r_{rs}(620)} \right); \quad 5.2$$

Lagos
Claros

$$a_t(708) = a_w(708) + 10^{66,8284 + 111,5816\chi + 45,9832\chi^2} (m^{-1})$$

$$Y = 2 \left(1 - 1,2 e^{\left(-0,9 \frac{rrs(443)}{rrs(555)} \right)} \right) \quad 5.3$$

$$S = 0,01 + \left(\frac{0,006}{\left(0,6 + \frac{rrs(665)}{rrs(708)} \right)} \right) \quad 5.4$$

$$a_{dg}(\lambda) = a_t(443) e^{(-S(\lambda-443))}$$

Como não foi possível observar uma correlação para ζ na equação 3.36, e devido ao domínio de $a_{dg}(443)$ em $a_t(443)$, o algoritmo parte do pressuposto de que toda a absorção em 443 nm é devido a componente detrito+CDOM, e

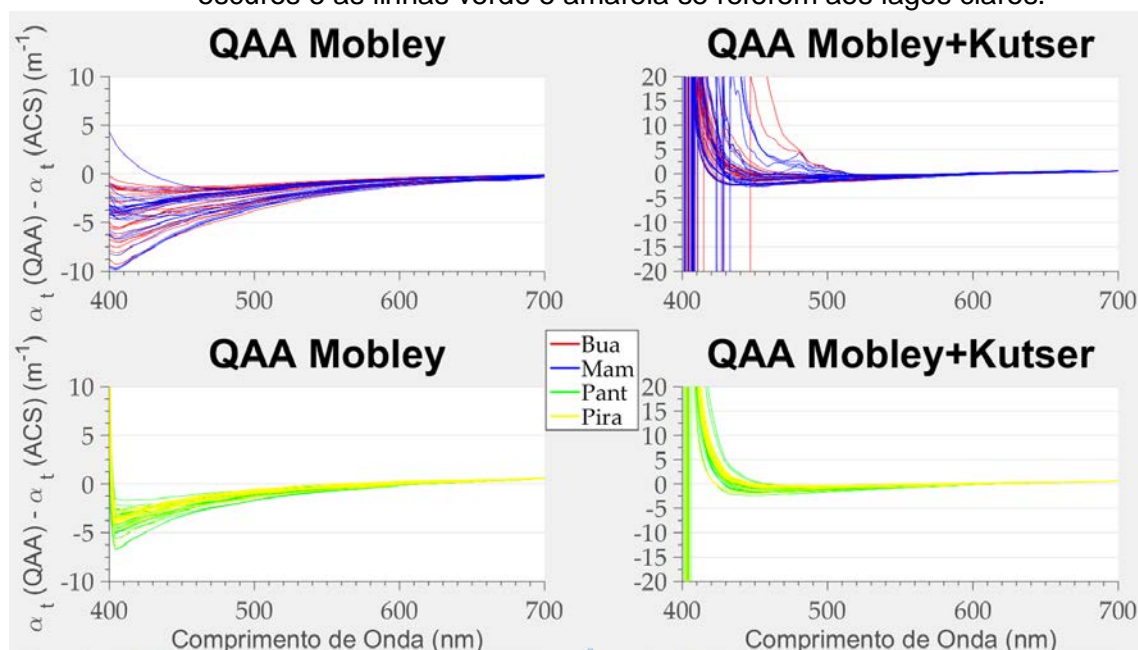
desta forma, é possível extrapolar o valor de $a_{dg}(\lambda)$. Como último passo do algoritmo, o valor de $a_{phy}(\lambda)$ é obtido algebricamente.

$$a_{phy}(\lambda) = a_t(\lambda) - a_{dg}(\lambda) \quad 5.5$$

Considerando as alterações propostas para o algoritmo, os valores de a_{dg} foram analisados em função da sua resposta em 443 nm e 555 nm, enquanto que os valores de a_{phy} foram analisados para 670 nm

Devido a diversidade óptica do conjunto de dados, os resultados serão descritos considerando os 4 conjuntos de dados (Lagos claros vs lagos escuros; Correção Mobley vs Correção Mobley+Kutser), quando possível. Inicialmente, o algoritmo QAA foi implementado a partir da R_{rs} obtida pelo método de correção Mobley, entretanto, como os resultados não se mostraram satisfatórios, indicando a presença residual de efeito de glint, utilizou-se a R_{rs} obtida pelo método de correção Mobley+Kutser. A diferença absoluta entre os valores de absorção estimados pela versão adaptada e calibrada do QAA (Para os dois métodos de correção) e o valor de referência, derivados de medidas *in situ* com o AC-S, podem ser observados na Figura 5.19.

Figura 5.19 Coeficientes de absorção total estimados pelo algoritmo QAA para os dois métodos de correção da R_{rs} . A primeira coluna utilizou a R_{rs} estimada pelo método Mobley, e a segunda pelo método Mobley+Kutser. A terceira coluna se refere aos dados medidos *in situ* pelo AC-S, tratado como referência. As linhas em azul e vermelho se referem aos lagos escuros e as linhas verde e amarela se referem aos lagos claros.



Fonte: Produção do autor.

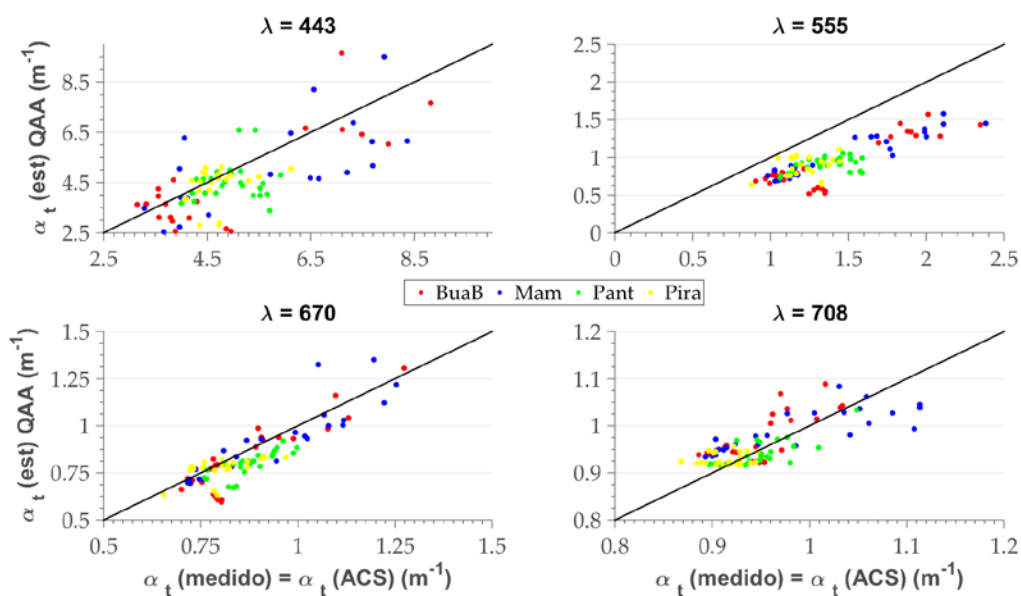
Pode-se observar que para os dois métodos de correção da R_{rs} , a diferença entre os valores medido *in situ* e os valores estimados pelo algoritmo QAA é grande para os comprimentos de onda mais curtos. Para o primeiro método, os valores foram subestimados, enquanto que para o segundo caso, os valores são superestimados. Estes resultados mostraram que considerando os valores de absorção espectrais (400 a 700 nm) para todas as amostras, não foi possível estimar valores precisos para nenhum dos casos.

Como sensores orbitais são desenvolvidos para comprimentos de onda específicos, analisaram-se os resultados em função das bandas comumente presentes nestes. Os comprimentos de onda selecionados foram 444, 555, 670 e 708. Esta etapa visou avaliar se o algoritmo proposto é adequado para regiões específicas do espectro. Como na R_{rs} obtida pelo método de correção proposto em Mobley os valores são subestimados para todo o espectro, os

resultados desta etapa foram descritos apenas para o segundo método de correção, buscando encontrar possíveis comprimentos de onda de interesse.

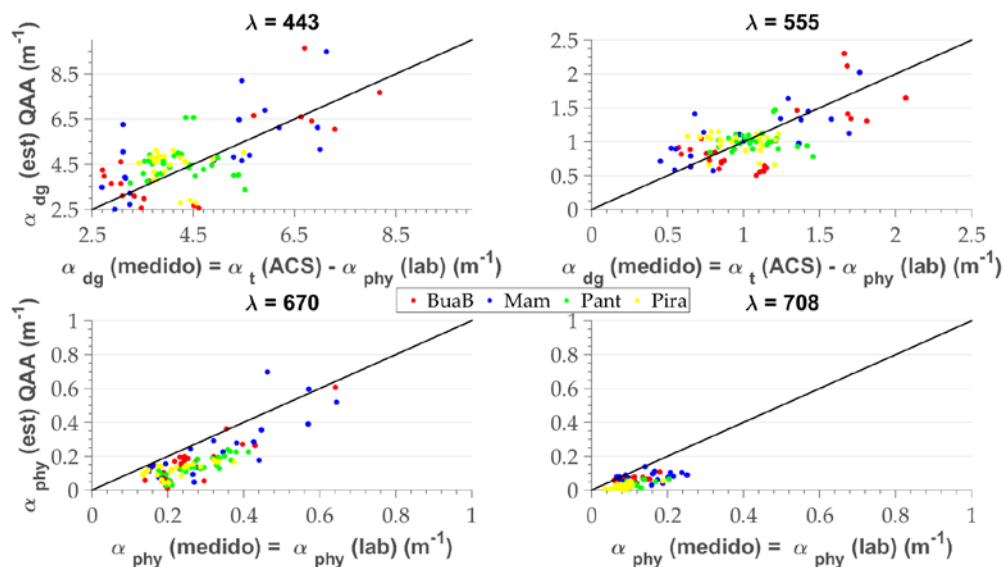
Nas Figura 5.20 e Figura 5.21 pode-se observar a comparação entre os valores medidos e modelados para os quatro comprimentos de onda para 4 lagos. A Figura 5.20 se refere à absorção total e Figura 5.21 se refere à absorção por CDOM+detrito e por fitoplâncton. Para os comprimentos de onda 670 e 708 nm, os valores estimados são semelhantes ao medido em campo, entretanto para 555 nm, todos os valores estimados estão abaixo da linha 1:1. Para 443 a dispersão é maior, apesar de apresentar um padrão claro. Quanto aos componentes fitoplâncton e dg, pode-se notar 2 comportamentos distintos, para 443 e 555 nm, a acurácia é maior na estimativa de a_{dg} , uma vez que este domina o sinal nestes comprimentos de onda, enquanto que para os demais comprimentos de onda, a acurácia é maior para o fitoplâncton.

Figura 5.20 Gráfico de dispersão entre os valores de absorção total estimados pelo QAA e medidos *in situ* para os 4 lagos. A distribuição de cores se refere aos 4 lagos.



Fonte: Produção do autor.

Figura 5.21 Gráfico de dispersão entre os valores de absorção estimados pelo QAA e medidos *in situ* para os 4 lagos. Os gráficos superiores se referem as medidas de a_{dg} , enquanto que os gráficos inferiores se referem as medidas de a_{phy} . A distribuição de cores se refere aos 4 lagos.



Fonte: Produção do autor.

A estimativa de erro para a absorção total estimada em cada comprimento de onda selecionado pode ser observada nas Tabela 5.4, Tabela 5.5 e Tabela 5.6. Considerando os 4 comprimentos de onda, a maior diferença no NRMSE para os 2 grupos de R_{rs} se dá em 443 nm para os lagos escuros, com uma diminuição no erro de 36,5% para 26% e em 555 nm, com uma diminuição de 21,3% para 12,7%. Para os demais comprimentos de onda, não foi possível identificar uma diferença significativa entre os dois métodos de correção de R_{rs} . Os resultados seguem o esperado, uma vez que a correção da R_{rs} é baseada em um ajuste exponencial, semelhante ao comportamento do espectro de absorção do detrito e da matéria orgânica, e assim, tem maior impacto nos comprimentos de onda mais curtos.

Tabela 5.4 Valor de NRMSE obtido para estimativa de a_t pelo algoritmo QAA para as duas metodologias de correção da R_{rs} (Lagos escuros) para os 4 comprimentos de onda selecionados.

NRSME		
Comprimento de onda	R_{rs} Mobley	R_{rs} Mobley+kuser
443 nm	36,56%	26,07%
555 nm	21,31%	12,71%
670 nm	8,78%	9,79%
708 nm	13,57%	2,56%

Fonte: Produção do autor.

Tabela 5.5 Valor de NRMSE obtido para estimativa de a_t pelo algoritmo QAA para as duas metodologias de correção da R_{rs} (Lagos claros) para os 4 comprimentos de onda selecionados.

NRSME		
Comprimento de onda	R_{rs} Mobley	R_{rs} Mobley+kuser
443 nm	13,81%	15,50%
555 nm	10,26%	11,71%
670 nm	4,86%	5,73%
708 nm	1,85%	1,80%

Fonte: Produção do autor.

Os resultados demonstram o potencial da aplicação do algoritmo QAA em lagos da RDSM por meio de sensoriamento remoto, entretanto é necessário ajustar a metodologia para discriminar os COAs de forma mais precisa. O NRMSE para o a_{dg} e o a_{phy} podem ser observados na Tabela 5.6. Como pode ser observado os maiores erros se referem à estimativa de a_{phy} , o qual tende a possuir valores de absorção mais baixos, e conseqüentemente potencializam as incertezas encontradas durante a execução do algoritmo. Já para o a_{dg} os

valores estão abaixo de 26% em 443 nm, indicando potencial para a estimativa deste parâmetro.

Tabela 5.6 Valor de NRMSE obtido para estimativa de a_{dg} e a_{phy} pelo algoritmo QAA para os lagos claros e escuros para os 4 comprimentos de onda selecionados.

Comprimento de onda	NRSME			
	$a_{dg}(443)$	$a_{dg}(555)$	$a_{phy}(670)$	$a_{phy}(708)$
Lagos Escuros	25,96%	23,74%	39,42%	32,20%
Lagos Claros	15,52%	14,45%	26,12%	58,24%

Fonte: Produção do autor.

Apesar da versão atual do QAA possuir opções para a aplicação em ambientes opticamente complexos (LI et al., 2013; LI et al., 2015), diversos trabalhos têm discutidos as incertezas atribuídas a estas medidas em ambientes extremamente túrbidos, como o dos lagos Chineses (WANG et al., 2009; YANG et al., 2013; LI et al., 2016). Quando inserimos os lagos Amazônicos neste contexto, estes se apresentam como um desafio para a aplicação destes algoritmos, sendo necessário adaptar e calibrar as diferentes etapas empíricas do algoritmo. De forma similar o arcabouço SOA pode ser aplicado de diferentes formas, como no caso do GSM e HOPE, entretanto, por se tratar de um algoritmo que seleciona os melhores valores por meio de um ajuste matemático, o resultado depende da forma na qual o erro é quantificado, de forma que o peso de cada comprimento de onda no estimador de erro determina a sua precisão (LEE et al., 2011). Em ambientes opticamente complexos espera-se que o sinal seja dominado por CDOM e detrito e desta forma, o estimador de erro tende a ter mais impacto na região do azul devido ao coeficiente de absorção, e na região do vermelho devido ao coeficiente de retroespalhamento, podendo mascarar a influência do fitoplâncton.

Uma etapa adicional foi implementada para discriminar o $a_{dg}(\lambda)$ nos componentes $a_{CDOM}(\lambda)$ e $a_{det}(\lambda)$, e esta consiste em um ajuste linear empírico

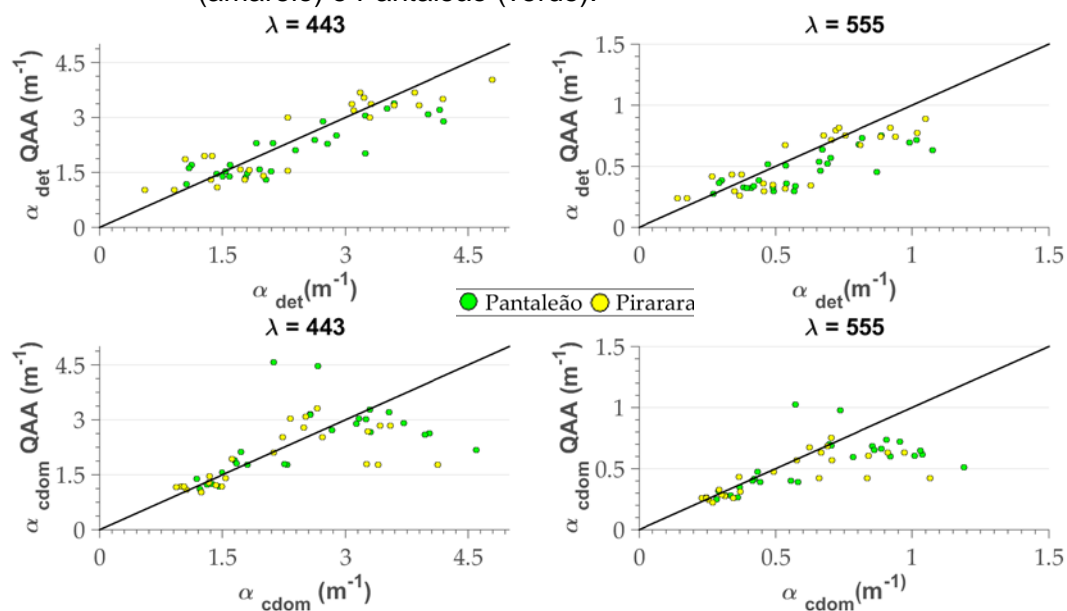
entre a $R_{rs}(555)$ e a razão entre $a_{det}(555)$ e $a_{dg}(555)$ (denominada como r_d). Basicamente, o ajuste assume que o valor de $R_{rs}(555)$ varia em função de $b_{bp}(555)$ e que este pode ser correlacionado a $a_{det}(\lambda)$. Assim, um aumento em r_d resultaria em um aumento em $R_{rs}(555)$. O ajuste também assume que esta razão se mantém constante para os comprimentos de onda mais curtos, e que desta forma, é possível utilizar $R_{rs}(555)$ para inferir a respeito da contribuição do detrito e do CDOM (conclusão feita a partir da análise dos dados laboratoriais de $a_{CDOM}(\lambda)$ e $a_{det}(\lambda)$). Entretanto, esta etapa só foi calibrada de forma satisfatória para os lagos claros, que apresentaram R^2 significativo ($R^2 > 0,7$), ao contrário dos lagos escuros ($R^2 < 0,01$). As equações utilizadas para converter $R_{rs}(555)$ em r_d são apresentadas abaixo:

$$r_d = \frac{a_{det}(555)}{a_{dg}(555)} = 0,22 + 26,17R_{rs}(555) \quad 5.6$$

$$a_{det}(\lambda) = a_{dg}(\lambda) \cdot r_d$$

Em geral, os resultados se mostraram satisfatórios para os dois comprimentos de onda analisados (443 nm e 555 nm, Figura 5.22). Entretanto, é possível identificar um aumento na incerteza na estimativa de a_{CDOM} com o aumento da sua magnitude, indicando que o ajuste empírico tende a falhar em ambientes dominados por matéria orgânica dissolvida, como é o caso dos lagos escuros.

Figura 5.22 Gráfico de dispersão entre os valores de a_{CDOM} e a_{dg} estimados pelo QAA e medidos *in situ* para os lagos claros. Os gráficos superiores se referem as medidas de a_{det} , enquanto que os gráficos inferiores se referem as medidas de a_{CDOM} . As cores representam os lagos Pirarara (amarelo) e Pantaleão (verde).



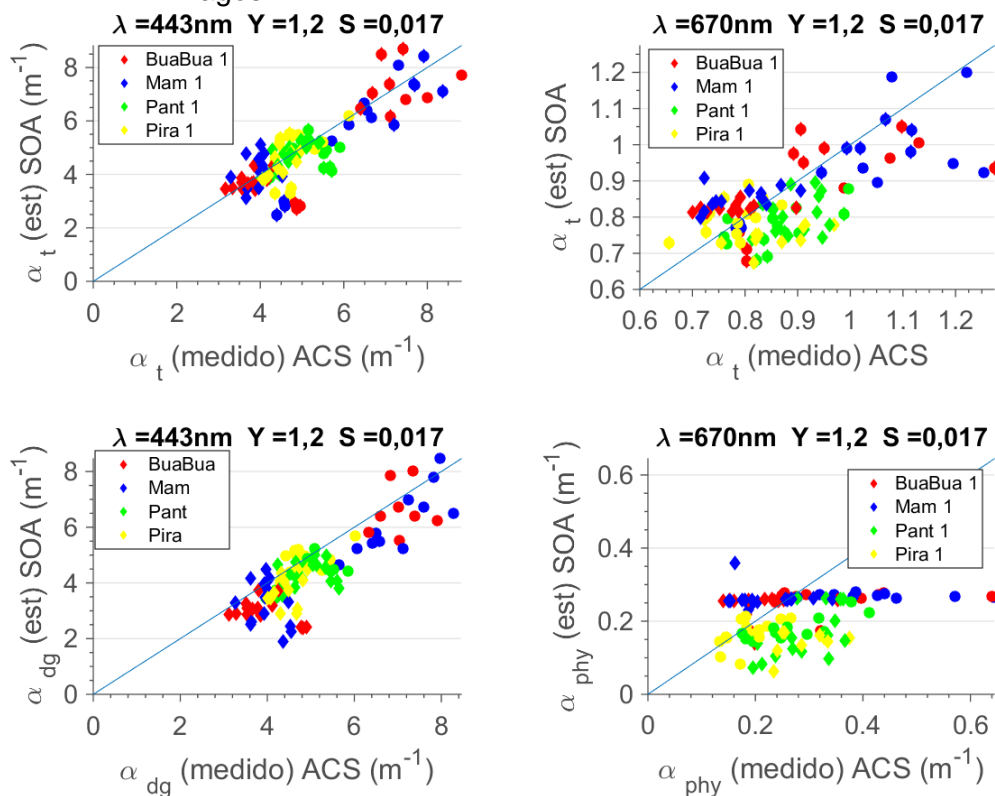
Fonte: Produção do autor.

A metodologia SOA foi aplicada aos espectros de R_{rs} corrigidos pela metodologia Mobley+Kutser, e os resultados podem ser observados na Figura 5.23. Assim como no caso do QAA, foram selecionados alguns comprimentos de onda para descrever os resultados obtidos (443 nm e 670 nm). Considerando que a metodologia utiliza espectros de absorção específicos para o a_{dg} e a_{phy} , foi selecionado um único comprimento de onda para descreve-los. Apesar do trabalho ter testado um conjunto de valores para Y e S , a Figura 5.23 se refere a melhor combinação de Y e S . Comparando os valores Y e S utilizados no algoritmo ($1,2 \text{ m}^{-1}$ e $0,017 \text{ m}^{-1}$, respectivamente) com os medidos *in situ* ($0,906 \text{ m}^{-1}$ e $0,0123 \text{ m}^{-1}$, respectivamente) pode-se notar que para a melhor combinação, os valores de Y e S são superestimados. Considerando que eles possuem um impacto inverso na R_{rs} , esta diferença é compensada na região do vermelho, permitindo a aquisição de valores

precisos. Já o valor de a_{phy}^* é o espectro mediano obtido para a área de estudo.

Para a absorção total, os resultados se mostraram satisfatórios tanto para 443 nm quanto para 670 nm, e para todo o conjunto de dados (Tabela 5.7). Entretanto, ao discriminar a absorção em a_{dg} e a_{phy} pode-se notar o efeito do tipo de água. Para o a_{dg} nos lagos escuros, nota-se 2 clusters (pontos vermelhos e azuis), com valores próximos de 4 m^{-1} e 7 m^{-1} , referentes aos períodos de vazante e enchente, respectivamente. Já no caso dos lagos claros (pontos verdes e amarelos), a distribuição é mais próxima, centrada em 5 m^{-1} . Considerando a congruência do algoritmo, ele se mostrou adequado para todo o conjunto de dados. Para o a_{phy} , nota-se que a metodologia não foi adequada para os lagos escuros, com valores semelhantes para todos os pontos. No caso dos lagos claros, pode-se observar que os valores foram subestimados em todos os casos. A técnica SOA permite ponderar o peso de cada comprimento de onda, permitindo uma maior sensibilidade a determinado COA, entretanto, para a RDSM, o aumento do peso para os comprimentos de onda próximos a 670 não causou um aumento na correlação entre os dados *in situ* e modelados. Isso provavelmente se deve aos baixos valores de R_{rs} e ao baixo impacto relativo de a_{phy} , de forma que o algoritmo não consegue discriminar esta fração. Já no caso dos lagos claros, a feição de a_{phy} em R_{rs} é mais acentuada, e desta forma, o algoritmo a discrimina de forma mais satisfatória.

Figura 5.23 Gráfico de dispersão entre os valores de absorção estimados pelo SOA e medidos *in situ* para os 4 lagos. Os gráficos superiores se referem ao a_t em dois comprimentos de onda e os gráficos inferiores se referem a a_{dg} e a_{phy} para um único comprimento de onda. As cores representam os 4 lagos.



Fonte: Produção do autor.

Tabela 5.7 Valor de NRMSE obtido para estimativa de a_t , a_{dg} e a_{phy} pelo algoritmo SOA para os lagos claros e escuros para os dois comprimentos de onda selecionados.

	NRMSE	443 nm	670 nm
a_t		14,85%	8,85%
a_{dg}		14,87%	12,44%
a_{phy}		210,6%	24,40%

Fonte: Produção do autor.

Em geral, os valores obtidos para a absorção total se mostraram satisfatórios para os comprimentos de onda selecionados, tanto para os lagos claros, quanto para os lagos escuros. Entretanto, ao decompor o coeficiente de absorção nas componentes a_{phy} e a_{dg} , pode-se observar um aumento na incerteza. Para o a_{dg} , os melhores resultados podem ser observados nas bandas do azul enquanto que para o a_{phy} , este apresentou resultados adequados apenas na banda do vermelho. Este fator está diretamente correlacionado ao comportamento destes COAs, com o domínio de a_{dg} nos comprimentos de onda mais curtos de a_{phy} no segundo pico de absorção da clorofila-a. Comparando os valores de a_{dg} dos dois algoritmos em 443 nm, o algoritmo SOA apresentou uma dispersão de erro menor, com valores mais próximos da razão 1:1, indicando um ajuste mais adequado, entretanto, para o a_{phy} em 670 nm os melhores resultados se referem ao algoritmo QAA para os dois tipos de lagos, apesar destes estarem levemente subestimados em todos os casos. Para o algoritmo SOA os melhores resultados foram observados para os lagos claros, enquanto que para os lagos escuros não foi possível identificar um padrão.

6 CONSIDERAÇÕES FINAIS

Este trabalho realizou a caracterização bio-óptica de um ambiente extremamente dinâmico, com alta variabilidade temporal (em função do pulso de inundação) e espacial (em função da posição dos lagos). Esta caracterização foi baseada nas análises de dados *in situ* e laboratoriais, para entender as variabilidades das IOPs e AOPs. Por se tratar de um ambiente relativamente pouco estudado (sob a perspectiva bio-óptica) e de difícil acesso, a caracterização é essencial para a evolução do sensoriamento remoto em águas interiores, avançando o conhecimento e conseqüentemente auxiliando no desenvolvimento de novas metodologias para a extração de informação a partir de dados radiométricos. Esta etapa é crucial para que futuramente, seja possível a extração de novas informações a partir de imagens orbitais.

Considerando os três objetivos propostos nesta tese, as considerações finais são apresentados em 3 etapas: i) Caracterização bio-óptica para compreender o ambiente e nortear a seleção de sensores de interesse e particionamento dos algoritmos propostos; ii) Simulação de sensores orbitais para entender quais sensores podem ser utilizados na RDSM e como seus resultados podem ser melhorados de forma a minimizar a incerteza em algoritmos empíricos; iii) Implementação dos algoritmos QAA e SOA baseada nos sensores selecionados previamente e na diversidade óptica observada durante a caracterização bio-óptica.

Na primeira etapa foi feita a caracterização bio-óptica de quatro lagos da RDSM e foi possível identificar que existem duas forçantes que controlam as propriedades ópticas dos lagos. A primeira se refere a componente sazonal, controlada pelo pulso de inundação. Este pulso controla o nível da água em toda a planície de inundação e é responsável pela entrada de material alóctone nos lagos, impactando a concentração de TSS e CDOM (Tabela 6.1- enchente versus vazante). A segunda se refere a componente espacial, e a posição dos lagos em relação a floresta e aos rios principais (Tabela 6.1- lagos claros versus escuros). Enquanto o pulso de inundação controla a quantidade de

material alóctone que entra nos rios, a distribuição espacial controla o tipo de material que entra nos lagos. Durante a enchente, foi possível observar um aumento na concentração de CDOM nos lagos localizados mais no interior da floresta (lagos escuros $\uparrow a_{CDOM}/DOC/DIC$), enquanto que para os lagos localizados próximos a margem do Japurá, ocorreu um aumento na concentração do TSIS (lagos claros $\uparrow a_{det}/TSS/TSIS$). Já durante a vazante, observou-se que os lagos são homogêneos, não sendo possível identificar diferenças na quantidade de matéria orgânica dissolvida e detrito. Já para a clorofila-a, não foi possível identificar um padrão claro nem no tempo nem no espaço. Durante a caracterização bio-óptica, ficou evidente que o ambiente é extremamente dinâmico e que tanto os sensores quanto os algoritmos escolhidos precisam ser capazes de se ajustar a esta variabilidade.

Tabela 6.1 Resumo geral da caracterização bio-óptica da RDSM em função das variáveis espaciais e temporais. \uparrow se refere a um aumento nos valores, \downarrow se refere a um decréscimo nos valores, \sim se refere a valores aproximadamente constantes, $\uparrow\downarrow$ se refere a valores intermediários, $\uparrow\uparrow\uparrow$ se refere a valores extremamente altos.

	LAGOS CLAROS	LAGOS ESCUROS
ENCHENTE	$\uparrow a_{det}/TSS/TSIS$ $\downarrow a_{CDOM}/DOC/DIC$ $\sim a_{phy}/Chl-a$ $\uparrow\uparrow\uparrow R_{rs}$	$\downarrow a_{det}/TSS/TSIS$ $\uparrow a_{CDOM}/DOC/DIC$ $\sim a_{phy}/Chl-a$ $\uparrow\downarrow R_{rs}$
VAZANTE	$\sim a_{det}/TSS/TSIS$ $\sim a_{CDOM}/DOC/DIC$ $\sim a_{phy}/Chl-a$ $\uparrow R_{rs}$	$\sim a_{det}/TSS/TSIS$ $\sim a_{CDOM}/DOC/DIC$ $\sim a_{phy}/Chl-a$ $\downarrow R_{rs}$

Fonte: Produção do autor

Durante a segunda etapa, avaliou-se a adequabilidade dos sensores orbitais disponíveis para a aquisição de dados nos lagos da RDSM. Esta etapa deu ênfase na simulação destes sensores, em vez da utilização das imagens disponíveis, uma vez que ainda não existe um consenso quanto aos métodos de correção atmosférica para esta região. O primeiro fator analisado foi o impacto das características destes sensores, como a SNR e o número de bits (resolução radiométrica), na R_{rs} e o segundo foi como estas incertezas se propagam nos diferentes algoritmos empíricos para a estimativa de

concentração de Chl-a e TSS. Como era esperado, as maiores incertezas na estimativa de R_{rs} se referem às bandas do azul e do infravermelho. A incerteza no azul está atribuída ao baixo sinal e a contribuição da atmosfera, enquanto que na região do infravermelho está atribuída a baixa SNR, devido ao fato do sinal ser inferior aos demais comprimentos de onda do visível.

Quanto aos algoritmos empíricos, observou-se que o tipo de algoritmo e a estrutura das equações (linear ou não linear, aditivo ou multiplicativo) possuem um impacto profundo nos resultados obtidos (Tabela 6.2). Em geral, o impacto do SNR em algoritmos lineares aditivos é constante para todas as concentrações, entretanto é proporcional ao valor de SNR, enquanto que para algoritmos lineares multiplicativos, o impacto pode ter um comportamento construtivo ou destrutivo, com um aumento na amplitude dos erros e na propagação de incertezas. Já no caso de algoritmos não lineares exponenciais, o impacto tende a ser maior nas concentrações mais baixa.

Outro fator evidenciado no trabalho foi que o impacto do SNR não depende apenas da estrutura do algoritmo. Para os algoritmos multiplicativos observou-se que o impacto do SNR apresentava um padrão errático (padrão imprevisível) em relação a concentração estimada. Entretanto, ao aprofundar as análises deste padrão, foi observado que este está diretamente relacionado a magnitude de R_{rs} . Os lagos escuros (baixa R_{rs}) apresentaram um aumento na incerteza durante as estimativas baseadas em algoritmos multiplicativos, enquanto que para os lagos claros (alta R_{rs}), as incertezas entre algoritmos aditivos e multiplicativos são similares. Durante esta etapa, foi constatado que os sensores de alta resolução espacial (OLI e MSI) apresentam as maiores incertezas devido a um menor SNR, e que dependendo da aplicação, é necessário realizar a reamostragem dos pixels selecionados.

Tabela 6.2 Resumo geral das conclusões referentes a simulação dos sensores orbitais.

$\downarrow R_{rs}$ se refere a espectros com baixa magnitude de R_{rs} , $\uparrow R_{rs}$ com alta magnitude de R_{rs} , \propto SNR significa proporcional a relação sinal ruído, Erro([]) proporcional a concentração, $\propto SNR^n$ proporcional a SNR, mas com caráter exponencial, \neq [] independente da concentração, $\text{Erro}(1/R_{rs})$ é inversamente proporcional a magnitude da R_{rs} e $\neq R_{rs}$ independente da R_{rs} .

$\downarrow R_{rs}$

$\uparrow R_{rs}$

LINEAR ADITIVO	\propto SNR	\propto SNR
N LINEAR ADITIVO	\propto SNR Erro([])	\propto SNR Erro([])
LINEAR MULTIPLICATIVO	$\propto SNR^n$ \neq [] $\text{Erro}(1/R_{rs})$	$\propto SNR^n$ \neq [] $\neq Rrs$
N LINEAR MULTIPLICATIVO	$\propto SNR^n$ Erro([]) $\text{Erro}(1/R_{rs})$	$\propto SNR^n$ Erro([]) $\neq Rrs$

Fonte: Produção do autor

A última etapa consistiu na implementação dos algoritmos QAA e SOA para a estimativa de IOPs a partir do espectro de R_{rs} (Tabela 6.3). Estratégias bottom-up e top-down têm sido utilizadas para obtenção de IOPs durante as últimas décadas, possuindo vantagens e desvantagens. No caso do SOA (bottom-up), a precisão do algoritmo está diretamente relacionada a sensibilidade do estimador de erro em distinguir o impacto de cada COA no espectro de R_{rs} . Já no caso do QAA (top-down), a precisão do algoritmo depende das diversas etapas empíricas que correlacionam a r_{rs} e as IOPs.

No caso do SOA, o algoritmo se mostrou satisfatório para a obtenção de a_t , a_{dg} e a_{phy} nos lagos claros, desde que o usuário faça a seleção dos valores de

Y e S baseada nos valores medidos *in situ*. Entretanto, para os lagos escuros, mesmo com a seleção de diferentes comprimentos de onda para o estimador de erro, o algoritmo não se mostrou capaz de estimar a_{phy} . Já no caso do QAA, o algoritmo se mostrou ineficiente para a obtenção de medidas espectrais para $a_t(\lambda)$, $a_{dg}(\lambda)$ e $a_{phy}(\lambda)$. Entretanto, ao analisar os resultados sob a perspectiva de um sensor multiespectral, as estimativas de a_t , a_{dg} e a_{phy} se mostraram satisfatórias (para os quatro comprimentos de onda selecionados), indicando o potencial do QAA, para a aquisição de medidas para os 2 grupos de lagos. Por fim, uma última etapa, no QAA, permitiu a discriminação do a_{dg} em suas frações a_{det} e a_{CDOM} nos lagos claros, entretanto, esta etapa não foi adequada para os lagos escuros.

Tabela 6.3 Resumo geral das conclusões referentes ao QAA e SOA para os Lagos Claros e Escuros da RDSM. a_t , a_{dg} , a_{phy} , a_{det} e a_{CDOM} são os coeficientes de absorção total, detrito+CDOM, fitoplâncton, detrito e CDOM, respectivamente, e δ é referente a incerteza dos resultados. $\downarrow \delta$ se refere a baixa incerteza, $\uparrow \delta$ se refere a alta incerteza, $\uparrow \uparrow \delta$ se refere a incerteza muito alta e $\delta \propto m^{-1}$ se refere a incerteza proporcional ao coeficiente de absorção.

	LAGOS CLAROS		LAGOS ESCUROS	
SOA	a_t	$\downarrow \delta$	a_t	$\downarrow \delta$
	a_{dg}	$\downarrow \delta$	a_{dg}	$\downarrow \delta$
	a_{phy}	$\downarrow \delta$	a_{phy}	$\uparrow \uparrow \delta$
QAA	a_t	$\downarrow \delta$	a_t	$\downarrow \delta$
	a_{dg}	$\downarrow \delta$	a_{dg}	$\downarrow \delta$
	a_{phy}	$\uparrow \delta$	a_{phy}	$\uparrow \delta$
	a_{det}	$\downarrow \delta$	a_{det}	-
	a_{CDOM}	$\delta \propto m^{-1}$	a_{CDOM}	-

Fonte: Produção do autor

Como recomendação final, o trabalho mostrou o potencial do SR em ambientes opticamente complexos como os lagos da RDSM, assim como as deficiências de cada sensor orbital disponível. Nesse contexto, o desenvolvimento de sensores futuros voltados ao monitoramento destes ambientes deve ser capaz de minimizar estas deficiências, visando a obtenção de resultados cada vez mais precisos. Como foi mostrado, tanto o QAA quanto o SOA se mostraram promissores, sendo necessário ampliar o estudo tanto no tempo quanto no espaço para as demais regiões da Amazônia, verificando se o padrão encontrado se mantém para os demais lagos. Trabalhos futuros voltados a modelagem das IOPs na Amazônia devem considerar as vantagens e desvantagens de cada algoritmo e fazer a seleção do algoritmo em função do comportamento óptico da área de estudo.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABBOTT, M.R.; LETELIER, R.M. **Chlorophyll fluorescence**: Corvallis: Oregon State University, 1999. (MODIS product number 20).
- AFFONSO, A.G.; QUEIROZ, H.L.D.; NOVO, E.M.L.D.M. Limnological characterization of floodplain lakes in Mamirauá Sustainable Development Reserve, Central Amazon (Amazonas State, Brazil). **Acta Limnologica Brasiliensia**, v.23, n.1, p.95-108, 2011.
- AFFONSO, A.G. **Relação entre parâmetros ambientais e a densidade de pirarucu nos lagos de várzea de Mamirauá**: uma análise multi-sensor. 147 p. 2012. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2012.
- ALVAIN, S.; MOULIN, C.; DANDONNEAU, Y. ;BRÉON, F.M. Remote sensing of phytoplankton groups in case 1 waters from global SeaWiFS imagery. **Deep Sea Research I**, n.52, p.1989-2004, 2005.
- ARAUJO-LIMA, C.A.R.M; SILVA, J.V.V; PETRY, P; OLIVEIRA, E.C; MOURA, S.M.L. Diel variation of larval fish abundance in the Amazon and Rio Negro. Brazil. **Journal of Biology**, v.61, n.3, p.357-362, 2001.
- ARRAUT, E.M.; MARMONTEL, M.; MANTOVANI, J.E.; NNOVO, E.M.L.M.; MACDONALD, D.W.; KENWARD, R.E. The lesser of two evils: seasonal migrations of Amazonian manatees in the Western Amazon. **Journal of Zoology**, v.280, n.3, p.247-256, 2010. doi: <10.1111/j.1469-7998.2009.00655.x>.
- BARBOSA, C.C.F. **Sensoriamento remoto da dinâmica de circulação da água do sistema planície de Curai/Rio Amazonas**. 2005. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005.
- BARBOSA, C. C. F.; NOVO, E. M. M. ; MELACK, J. M. ; Gatil Mary ; PEREIRA FILHO, W. Geospatial analysis of spatiotemporal patterns of pH, total

suspended sediment and chlorophyll-a on the Amazon floodplain. **Limnology**, Tokyo, v. 11, p. 155-166, 2010.

BARLOW, R. G.; AIKEN, J.; HOLLIGAN, P. M.; CUMMINGS, D. G.; MARIOTENA, S.; HOOKER, S. Phytoplankton pigment and absorption characteristics along meridional transects in the Atlantic Ocean. **Deep-Sea Research I**, v.49, p.637-660, 2002.

BINDING, C.E.; BOWERS, D.G.; MITCHELSON-JACOB, E.G. An algorithm for the retrieval of suspended sediment concentrations in the Irish Sea from SeaWiFS ocean colour satellite imagery. **International Journal of Remote Sensing**, v.24, p.3791–3806, 2003.

BIRD, R.; RIORDAN, C. Simple solar spectral model for direct and diffuse irradiance on horizontal and tilted planes at the Earth's surface for cloudless atmospheres. **Journal of Climate and Applied Meteorology**, v.25, n.1, p.87-97, 1984.

BLOUGH, N. V.; GREEN, S.A. Spectroscopic characterization and remote sensing of non-living organic matter. In: ZEPP, R. G.; SONNTAG, C. (Eds.). **The role of non-living organic matter in the Earth's carbon cycle**. New York: John Wiley, 1995. p.23-45.

BONNET, M.P.; BARROUX, G.; MARTINEZ, J.M.;SEYLER, F.; MOREIRA-TURCQ, P.; COCHONNEAU, G.; MELACK, J.M.; BOAVENTURA, G.; MAURICE-BOURGOIN, L.; LEÓN, J.G.; ROUX, E.; CALMANT, S.; KOSUTH, P.; GUYOTH, J.L.; SEYLER, P. Floodplain hydrology in an Amazon floodplain lake (Lago Grande de Curuaí). **Journal of Hydrology**, v.349, n.1/2, p.18-30, 2008.

BOSS, E.; ROESLER, C. Over constrained linear matrix inversion with statistical selection. In: Lee, Z. P. (Ed.). **Remote sensing of inherent optical properties: fundamentals, tests of algorithms, and applications**. Dartmouth, NS, Canada: IOCCG, 2006. (IOCCG Rep, 5).

BOYER, T.P.; ANTONOV, J.I.; BARANOVA, O.K.; COLEMAN, C.; GARCIA, H.E.; GRODSKY, A.; JOHNSON, D.R.; LOCARNINI, R.A.; MISHONOV, A.V.; O'BRIEN, T.D.; PAVER, C.R.; REAGAN, J.R.; SEIDOV, D.; SMOLYAR, I. V.; BRICAUD, A.; MOREL, A.; PIUEUR, L. Absorption by dissolved organic matter of the sea (yellow substance) in the UV and visible domains. **Limnology and Oceanography**, v. 26, p. 43-53, 1981.

BREZONIK, P.L.; OLMANSON, L.G.; FINLAY, J.C.; BAUER, M.E. Factors affecting the measurement of CDOM by remote sensing of optically complex inland waters. **Remote Sensing of Environment**, 157, 199-215. 2015.

BRICAUD, A.; BABIN, M.; MOREL, A.; CLAUSTRE, H. Variability in the chlorophyll-specific absorption coefficient of natural phytoplankton: analysis and parameterization. **Journal of Geophysical Research**, v.100, C7, p.13321-13332, 1995.

BRICAUD, A.; CLAUSTRE, H.; RAS, J.; OUBELKHEIR, K. Natural variability of phytoplankton absorption in oceanic waters: influence of the size structure of algal populations. **Journal of Geophysical Research**, v.109, C11010, 2004.

CARDER, K.L.; STEWARD, R.G.; HARVEY, G. R.; ORTNER, P. B. Marine humic and fulvic acids: their effects on remote sensing of ocean chlorophyll. **Limnology and Oceanography**, v. 34, p. 68-81, 1989.

CARDER, K.L. Reflectance model for quantifying chlorophyll a in the presence of productivity degradation products. **Journal of Geophysical Research**, v.96, p.20599-20611, 1991.

CARDER, K.L.; CHEN, F.R.; LEE, Z.P.; HAWES, S.K.; CANNIZZARO, J.P.; **MODIS ocean science team algorithm theoretical basis document..** St Petersburg: College of Marine Science, 2003. (Version 7).

CARVALHO, L.A.; BARBOSA, C.C.F.; NOVO, E.M.L.M., RUDORFF, C.M. Implications of scatter corrections for absorption measurements on optical closure of Amazon floodplain lakes using the Spectral Absorption and

Attenuation Meter (AC-S-WETLabs). **Remote Sensing of Environment**, v.157, p.123-137, 2015.

CARVALHO, L.A. **Bio-optical characterization of Amazon floodplain lakes and evaluation of the retrieval of optically active constituent using remote sensing**. 2016. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.

CASALI, S.; CALIJURI, M.C.; BARBARISI, B.; RENÓ, V. F.; AFFONSO, A.; BARBOSA, C.C.F.; SILVA, T. S. F.; NOVO, E.M.L.M. Impact of the 2009 extreme water level variation on phytoplankton community structure in Lower Amazon floodplain lakes. **Acta Limnologica Brasiliensia**, v.23, n.3 p.260-270, 2011.

CHEN, C.; SHI, P.; YIN, K.; PAN, Z.; ZHAN, H.; HU, C. Absorption coefficient of yellow substance in the Pearl River estuary. **Ocean Remote Sensing and Applications**v.4892, p. 215-222, 2003.

CHEN, X.; HAN, X.; FENG, L. Towards a practical remote-sensing model of suspended sediment concentrations in turbid waters using MERIS measurements. **International Journal of Remote Sensing**, v.36, p.3875–3889, 2015.

CIOTTI, A.M. **Influence of phytoplankton communities on relationships between optical properties of coastal surface waters**. 1999. Tese (Doutorado em Filosofia), Dalhousie University, Halifax, Nova Scotia, 1999.

CIOTTI, A.M.; LEWIS, M.R.; CULLEN, J.J. 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, p. 404-417, 2002.

CLARK, D. **MODIS algorithm theoretical basis document: bio-optical algorithms: case 1 waters**. 1997. Disponível em: < https://icdc.cen.uni-hamburg.de/fileadmin/user_upload/icdc_Dokumente/MODIS/modis_atbd_mod17-1_bio-optical-algorithms.pdf>.

COBLE, P.G. Marine optical biogeochemistry: the chemistry of ocean color. **Chemical Reviews**, v.107, n.2, p. 402-418, 2007.

COSTA, M.P.F.; NOVO, E.M.L.M.; TELMER, K.H. Spatial and temporal variability of light attenuation in large rivers of the Amazon. **Hydrobiologia**, v.702, n.1, p.171-190, 2013.

CULLEN, J.J.; CIOTTI, A.M.; DAVIS, R.F.; EWIS, M.R. Optical detection and assessment of algal blooms. **Limnology and Oceanography**, v. 42, p.1223-1239, 1997.

DEKKER, A.G; VOS R.J. ; PETERS, S.W.M. Analytical algorithms for lake water TSM estimation for retrospective analyses of TM and SPOT sensor data. **International Journal of Remote Sensing**, v.23, n.1, p.15-35, 2002.

DOERFFER, R; FISHER, J. Concentrations of chlorophyll, suspended matter, and gelbstoff in case II waters derived from satellite coastal zone color scanner data with inverse modeling methods. **Journal of Geophysical Research**, v. 99, p. 7475-7466, 1994.

D'SA, E.J.; MILLER, R.L. Bio-optical properties in waters influenced by the Mississippi River during low flow conditions. **Remote Sensing of Environment**, v.84, p.538-549, 2003.

EUROPEAN SPACE AGENCY – ESA. **Sentinel 2**: MSI. Disponível em: www.earth.esa.int/web/sentinel/user-guides/sentinel-2-msi. Acesso em : 26 fev. 2017.

EUROPEAN SPACE AGENCY - ESA Sentinel 3 OLCI. Disponível em: <https://earth.esa.int/web/sentinel/user-guides/sentinel-3-olci>. Acesso em 26 fev. 2017.

FORSBERG, B.R.; ARAUJO-LIMA, C.A.R.M.; MARTINELLI, L.A.; VICTORIA, R.L.; BONASSI, J.A. Autotrophic carbon sources for fish of the central Amazon. **Ecology**, v. 74, p. 643- 652, 1993.

- FORSBERG, B. R.; HASHIMOTO, Y. ROSENQVIST, A.; MIRANDA, F. P. Tectonic fault control of wetland distributions in the Central Amazon revealed by JERS-1 radar imagery. **Quaternary International**, v. 72, p. 61-66, 2000.
- GALLEGOS, C.L.; NEALE, P.J. Partitioning spectral absorption in case 2 waters: discrimination of dissolved and particulate components. **Applied Optics**, v.41, p.4220-4233, 2002.
- GARVER, S.A.; SIEGEL, D. Inherent optical property inversion of ocean color spectra and its biogeochemical interpretation 1: time series from the Sargasso Sea. **Journal of Geophysical Research**, v.102, p. 18607-18625. 1997.
- GERACE, A.D.; SCHOTT, J.R.; NEVINS, R. Increased potential to monitor water quality in the near-shore environment with Landsat's next-generation satellite. **Journal of Applied Remote Sensing**, v.7, e073558, 2013.
- GIARDINO, C.; BRESCIANI, M.; CAZZANIGA, I.; SCHENK, K.; RIEGER, P.; BRAGA, F.; MATTA, E.; BRANDO, V.E. Evaluation of multi-resolution satellite sensors for assessing water quality and bottom depth of Lake Garda. **Sensors**, v.14, p.24116–24131, 2014.
- GORDON, H.R.; BROWN, O.B.; EVANS, R.H.; BROWN, J.W.; SMITH, R.C.; BAKER, K.S.; CLARK, D.K. A semianalytic radiance model of ocean color. **Journal of Geophysical Research**, v.93, p.10.909-10.924, 1988.
- GORDON, H. R. Dependence of the diffuse reflectance of natural waters on the Sun angle. **Limnology and Oceanography**, v.34, p.1484–1489, 1989.
- GORDON, H.R. Absorption and scattering estimates from irradiance measurements: Monte Carlo simulations. **Limnology and Oceanography**, v.36, p.769-777, 1991.
- GOULDING, M.; SMITH, N. J. H.; MAHAR, D. J. **Floods of fortune: ecology and economy along the Amazon**. New York: Columbia University Press, 1996. 184p.

GUEYMARD, C. '**SMARTS, a simple model of the atmospheric radiative transfer of sunshine algorithms and performance assessment**'. Cocoa, FL, USA: Florida Solar Energy Center, 1995. (FSECPF- 270-93).

GUEYMARD, C. Parameterized transmittance model for direct beam and circumsolar spectral irradiance, **Solar Energy**, v.71, n. 5, p.325-346, nov. 2001.

HESS, L. L.; MELACK, J. M.; NOVO, E. M.L. M.; BARBOSA, C. C. F.; GASTIL, M. Dual season mapping of wetland inundation and vegetation for the central Amazon basin. **Remote Sensing of Environment**, v.87, p. 404-428, 2003.

HESTIR, E.L.; BRANDO, V.; CAMPBELL, G.; DEKKER, A.; MALTHUS, T. The relationship between dissolved organic matter absorption and dissolved organic carbon in reservoirs along a temperate to tropical gradient. **Remote Sensing of Environment**, 156, 395-402. 2015.

HYDRO-OPTICS, BIOLOGY AND INSTRUMENTATION LABORATORIES.
HydroScat-6 spectral backscattering sensor and fluorometer: user's manual: revision j. Bellevue, WA: HydroOptics, 2010. 63p.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International Journal of Forecasting**, v.22, n.4, p.679–688, 2006. doi:10.1016/j.ijforecast.2006.03.001.

HOEPFFNER, N.; SATHYENDRANATH, S. Effect of pigment composition on absorption properties of phytoplankton. **Marine Ecology Progress Series**, v.73, p.11 – 23, 1991.

HOGUE, F.E.; LYON, P.E. Satellite retrieval of inherent optical properties by linear matrix inversion of oceanic radiance models: an analysis of model and radiance measurement errors. **Journal of Geophysical Research**, v.101, p.16631-16648, 1996.

HU, C.; LEE, Z.; FRANZ, B. Chlorophyll algorithms for oligotrophic oceans: A novel approach based on three-band reflectance difference. **Journal of Geophysical Research: Oceans**, 117(C1). 2012.

INTERNATIONAL OCEAN COLOUR COORDINATING GROUP - IOCCG.
Minimum requirements for an operational ocean-colour sensor for the open ocean. Monterey, CA: IOCCG, 1998.

INTERNATIONAL OCEAN COLOUR COORDINATING GROUP - IOCCG.
Mission requirements for future ocean-colour sensors. , Monterey, CA: IOCCG, 2012.

JORGE, D.S.F.; BARBOSA, C.C.; SANDER DE CARVALHO, L.A.; AFFONSO, A.G.; LOBO, F.D.L.; NOVO, E.M.D.M. Snr (signal-to-noise ratio) impact on water constituent retrieval from simulated images of optically complex amazon lakes. **Remote Sensing**, 9(7), 644. 2017

JUNK, W.J.; BAYLEY, P.B.; SPARKS, R.E. The flood pulse concept in river-floodplain systems. In: DODGE, D. P. (Ed.). **Proceedings of the International Large River Symposium.** Ottawa: Canada: Canadian Special Publication of Fisheries and Aquatic Sciences, 1989. p. 110-127.

JUNK, W. J. **The central amazon floodplain:** ecology of a pulsing system. Berlin: Springer, 1997.

JUNK, W.J.; PIEDADE, M.T.F.; SCHÖNGART, J.; COHN-HAFT, M.; ADENEY, J.M.; WITTMANN, F. A Classification of major naturally-occurring amazonian lowland wetlands. **Wetlands**, v.31, p.623 – 640, 2011.

KIRK, J. T. O. Dependence of relationship between inherent and apparent optical properties of water on solar altitude. **Limnology and Oceanography**, v.29, p.350–356, 1984.

KIRK, J. T. O. Monte Carlo modeling of the performance of a reflective tube absorption meter. **Applied optics**, v. 31, n. 30, p. 6463–8, oct. 1992

KIRK, J.T.O. **Light and photosynthesis in aquatic ecosystems.** 2.ed. Cambridge: Cambridge University Press, 1994.

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

KIRKPATRICK, G.; MILLIE, D.F.; MOLINE, M.A.; SCHOFIELD, O. Optical discrimination of a phytoplankton species in natural mixed populations.

Limnology and Oceanography, v.45, n.2, p.467-471, 2000.

KUTSER, T. Quantitative detection of chlorophyll in cyanobacterial blooms by satellite remote sensing. **Limnology and Oceanography**, v.49, n.6, p. 2179-2189, 2004.

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

doi:10.1016/j.rse.2013.02.011.

LECKNER, B. The spectral distribution of solar radiation at the earth's surface elements of a model. **Solar Energy**, v.20, n.2, p.143-150, 1978.

LEE, Z.P. **Visible-infrared remote-sensing model and applications for ocean waters**. Tese (Doutorado em Ciência Marinha) - The University of South Florida, St. Petersburg, 1994.

LEE, Z.P.; CARDER, K.L.; MOBLEY, C.D.; STEWARD, R.G.; PATCH, J.S. Hyperspectral remote sensing for shallow waters: 2. deriving bottom depths and water properties by optimization. **Applied Optics**, v.38, p.3831-3843, 1999.

LEE, Z.P.; 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 – 5772, 2002.

LEE, Z.P.; WEIDEMANN, A.; KINDLE, J.; ARNONE, R.; CARDER, K. L.; DAVIS, C. Euphotic zone depth: Its derivation and implication to ocean color remote sensing. **Journal of Geophysical Research: Oceans**, v.112, n.C3, 1978-2012, 2007.

LEE, Z.; LUBAC, B.; WERDELL, J.; ARNONE, R. An update of the quasi-analytical algorithm (QAA_v5). **International Ocean Color Group Software Report**, p. 1-9, 2009.

LEE, Z.P.; FRANZ, B.; SHANG, S.; DONG, Q.; ARNONE, R. Some insights on spectral optimization in ocean color inversion. **International Society for Optics and Photonics**, v.8175, 2011.

LEE, Z. LUBAC, B., WERDELL, J. Update of the quasi-analytical algorithm (QAA_v6). **International Ocean Color Group Software Report**, p. 1-9, 2014.

LI, L.; LI, L.; SONG, K.; LI, Y.; TEDESCO, L.P.; SHI, K.; LI, Z. An inversion model for deriving inherent optical properties of inland waters: establishment, validation and application. **Remote Sensing 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 Environment**, v.157, p.9–23, 2015.

LI, S.; SONG, K.; MU, G.; ZHAO, Y.; MA, J.; REN, J. Evaluation of the quasi-analytical algorithm (QAA) for estimating total absorption coefficient of turbid inland waters in northeast china. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v.9, n.9, p.4022-4036, 2016.

LOBO, F.L.; COSTA, M.; PHILLIPIS, S.; YOUNG, E.; MCGREGOR, C. Light backscattering in turbid freshwater: a laboratory investigation. **Journal of Applied Remote Sensing**, v.8, n.1, p.083611-083611, 2014.

LUCK, S.J. **An introduction to the event-related potential technique**. Cambridge, MA: MIT Press, 2014.

MARITORENA, S.; SIEGEL, D. A.; PETERSON, A. Optimization of a semi-analytical ocean color model for global scale applications. **Applied Optics**, v.41, n.15, p.2705– 2714, 2002.

MARRA, J.; TREES, C.; OREILLY, J. Phytoplankton pigment absorption: a strong predictor of primary productivity in the surface ocean. **Deep Sea Research Part I: Oceanographic Research Papers**, v. 54, n.2, p. 155-163. 2007.

- MARTINEZ, J.M.; ESPINOZA-VILLAR, R.; AARMIJOS, E.; SILVA MOREIRA, L. The optical properties of river and floodplain waters in the Amazon River Basin: Implications for satellite-based measurements of suspended particulate matter. **Journal of Geophysical Research: Earth Surface**, 120(7), 1274-1287. 2015
- MATTHEWS, M.W.; BERNARD, S.; ROBERTSON, L. An algorithm for detecting trophic status (chlorophyll-a), cyanobacteria-dominance, surface scums and floating vegetation in inland and coastal waters. **Remote Sensing Environment**, v.124, p.637-652, 2012.
- MISHRA, D.R.; NARUMALANI, S.; RUNDQUIST, D.; LAWSON, M. Characterizing the vertical diffuse attenuation coefficient for downwelling irradiance in coastal waters: Implications for water penetration by high resolution satellite data. **ISPRS Journal of photogrammetry and remote sensing**, v.60, n.1, p.48-64, 2005.
- MISHRA, S.; MISHRA, D.R.; LEE, Z.P.; TUCKER, C.S. Quantifying cyanobacterial phycocyanin concentration in turbid productive waters: a quasi-analytical approach. **Remote Sensing 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 Environment**, v.117, p.394–406, 2012.
- MOBLEY, C. **Light and water: radiative transfer in natural waters**. San Diego, CA: Academic Press, 1994. ISBN 9780125027502.
- 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 wind-blown sea surfaces. **Applied Optics**, v.54, n.15, p.4828-4849, 2015.
- MOBLEY, C. **Light and water: radiative transfer in natural waters**. San Diego, CA: Academic Press, 1994. ISBN 9780125027502.

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 wind-blown sea surfaces. **Applied Optics**, v.54, n.15, p.4828-4849, 2015.

MOSES, W.J.; GITELSON, A. A.; BERDINIKOV, S.; POVAZHNYI, V. Satellite estimation of chlorophyll-a concentration using the red and NIR bands of MERIS-the Azov Sea case study. **IEEE. Geoscience Remote Sensing**, v.6, p.845-849, 2009.

MOSES, W.J.; BOWLES, J.H.; LUCKE, R.L.; CORSON, M.R. Impact of signal-to-noise ratio in a hyperspectral sensor on accuracy of biophysical parameter estimation in case II waters. **Optical express**, v. 20, n.4,p. 4309-4330, 2012.

MUELLER, J.L.; FARGION, G.S. **Ocean optics protocols for satellite ocean color sensor validation**. , Greenbelt, Maryland: NASA Goddard Space Flight Center, 2002. 308p. (NASA TM 2002-210004).

MUMBY, P.J.; GREEN, E.P.; EDWARDS, A.J.; CLARK, C.D. The cost-effectiveness of remote sensing for tropical coastal resources assessment and management. **Journal of Environmental Management**, v.55, n.3, p.157-166. 1999.

MOUW, C.B.; GREB, S.; AURIN, D.; DIGIACOMO, P.M.; LEE, Z.P.; TWARDOWSKI, M.; BINDING, C.; HU, C.; MA, R.; MOORE, T.; MOSES, W.; CRAIG, S.E. 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.

NEILL, C.; ELSENBEER, H.; KKRUSCHE, A. V.; LEHMANN, J.; MARKEWITZ, D.; O FIGUEIREDO, R. Hydrological and biogeochemical processes in a changing Amazon: results from small watershed studies and the large-scale biosphere-atmosphere experiment. **Hydrological Processes**, v,20, n.12, p.2467-2476, 2006.

NATIONAL RESEARCH COUNCIL. **Nutrient requirements of fish and shrimp**. Washington: National Academies Press, 2011.

O'REILLY, J. E.; MARITORENA, S.; MITCHELL, B. G.; SIEGEL, D. A.; CARDER, K. L.; GARVER, S. A.; KAHRU, M.; MCCLAIN, C. Ocean color chlorophyll algorithms for SeaWiFS. **Journal of Geophysical Research-Oceans**, v.103, p.24937-24953, 1998.

OSCAR Observing Systems Capability Analysis and Review Tool. **Instrument OLI**. Disponível em: <http://www.wmo-sat.info/oscar/instruments/view/375.%20Accessed%20on%2026/02/2017>. Acesso em: 26 fev. 2017.

PAHLEVAN, N.; LEE, Z.; WEI, J.; SCHAAF, C.B.; SCHOTT, J.R.; BERK, A. On-orbit radiometric characterization of OLI (Landsat-8) for applications in aquatic remote sensing. **Remote Sensing Environment**, v.154, p.272–284, 2014.

PAROLIN, P.; SIMONE, O DE; HAASE, K; WALDHOFF, D; HOTTENBERGER, S; KUHN, U; KESSELMEIER, J; KLEISS, B;SCHIMIDT, W; PIEDADE, M. T. F.; JUNK, W. J. Central Amazonian floodplain forests. **Botanical Review**, v. 70, n. 3, p. 357-380, 2004.

POPE, R.M.; FRY, E.S. Absorption spectrum (380-700 nm) of pure water. II. Integrating cavity measurements. **Applied Optics**, v.36, p. 8710-8723, 1997.

PREISENDORFER, R. W. **Application of radiative transfer theory to light measurements in the sea**. Saint-Mandé, France: IGN, 1961.

Queiroz, H.L. A reserva de desenvolvimento sustentável Mamirauá. **Estudos Avançados**, v.19, n.54, p.183-203, 2005.

Queiroz, H. L. Classification of water bodies based on biotic and abiotic parameters at the várzeas of Mamirauá Reserve, Central Amazon. **Uakari**, v. 3, n. 2, p. 19-34, 2007.

Ramalho, E.E.; Macedo, J.; Vieira, T.M.; Valsecchi, J.; Calvimontes, J.; Marmontel, M.; Queiroz, H. Ciclo hidrológico nos ambientes de várzea da

Reserva de Desenvolvimento Sustentável Mamirauá: Médio Rio Solimões, período de 1990 a 2008. **Uakari**, v. 5, n. 1, p. 61-87, 2009.

RICHARDSON, L.L. Remote sensing of algal bloom dynamics: new research fuses remote sensing of aquatic ecosystems with algal accessory pigment analysis. **BioScience**, v. 46, n. 7, p. 492-501, 1996.

SIEBURTH, J. MCN.; JENSEN, A. Studies on the algal substances in the sea. 2: the formation of Gelbstoff (humic material) by exudates of phaeophyta. **Journal of Experimental Marine Biology Ecology**, v.3. p.275-289, 1969.

SIEGEL, D.A.; MARITORENA, S.; NELSON, N.B.; HANSELL, D.A.; LORENZI-KAYSER, M. Global distribution and dynamics of colored dissolved and detrital organic materials. **Journal of Geophysical Research**, v.107, p.3228, 2002. doi:10.1029/2001JC000965.

SIOLI, H. Das wasser im Amazonasgebiet. **Forschungen und Fortschritte**, v.26, p. 274–280, 1950.

SIPPEL, S.J.; HAMILTON, S.K.; MELACK, J.M. Inundation area and morphometry of lakes on the Amazon River floodplain, Brazil. **Archiv fur Hydrobiologie**, Stuttgart, v.123, n.4 p.385-400, 1992.

SISWANTO, E.; ISHIZAKA, J.; TRIPATHY, S. C.; MIYAMURA, K. Detection of harmful algal blooms of *Karenia mikimotoi* using MODIS measurements: a case study of Seto-Inland Sea, Japan. **Remote Sensing of Environment**, v.129, p.185-196, 2013.

SMYTH, T.J.; MOORE, G.F.; HIRATA, T.; AIKEN, J. Semianalytical model for the derivation of ocean color inherent optical properties: description, implementation, and performance assessment. **Applied Optics**, v.45, n.31, p.8116-8131, 2006.

STUBBINS, A.; SPENCER, R. G. M.; CHEN, H.; HATCHER, P. G.; MOPPER, K.; HERNES, P. J.; MWAMBA, V. L.; MANGANGU, A. M.; WABAKANGHANZI, J. N.; SIX, J. Illuminated darkness: molecular signatures of Congo River dissolved organic matter and its photochemical alteration as revealed by

ultrahigh precision mass spectrometry. **Limnology and Oceanography**, v.55, p.1467–1477, 2010.

SUBRAMANIAM, A.; HOOD, R.R.; BROWN, C.W.; CARPENTER, E.J.; CAPONE, D.G. Detecting trichodesmium blooms in SeaWiFS imagery. **Deep-Sea Research Part II**, v.4, n.1-3, p.107-121, 2002.

TASSAN, S.; FERRARI, G.M. An alternative approach to absorption measurements of aquatic particles retained on filters. **Limnology and Oceanography**, v.40, p.1358-1368, 1995a.

TASSAN, S.; FERRARI, G.M. Measurement of the light absorption by aquatic particles retained on filters: determination of the optical pathlength amplifications by the “Transmittance-Reflectance” method. **Journal of Plankton Research**, v.20, p.1699-1709, 1998.

TASSAN, S.; FERRARI, G.M. A sensitive 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.

TILTSTONE, G.H.; MOORE, G.F.; SORENSEN, K.; DOERFFER, R.; ROTTGERS, R.; RUDDICK, K.; PASTERKAMP, R.; JORGENSEN, P.V. **Regional validation of MERIS chlorophyll products in North Sea coastal waters**. Paris: ESA, 2002. (EVGI-CT-2001-00049).

THURMAN, E.M. Amount of organic carbon in natural waters. In: _____ (Ed.). **Organic geochemistry of natural waters**. Berlin; Springer, 1985.p.7-65.

TRIOS. **Trios sensors**. 2015. Disponível em: <<http://trios-science.com/>>. 35, 39

VANHELLEMONT, Q.; RUDDICK, K. Turbid wakes associated with offshore wind turbines observed with Landsat 8. **Remote Sensing of Environment**, v.145, p.105-115, 2014.

- VANHELLEMONT, Q.; RUDDICK, K. Advantages of high quality SWIR bands for ocean color processing: examples from Landsat-8. **Remote Sensing of Environment**, v.161, p.89–106, 2015.
- WANG, W. Q.; DONG, Q.; SSHANG, S. L.; WU, J. Y.; LEE, Z. P. An evaluation of two semi-analytical ocean color algorithms for waters of the South China Sea. **Journal of Tropical Oceanography**, v.28, n.5, p.36-42, 2009.
- WANG, J.J.; TANG, D.L.; SUI, Y. Winter phytoplankton bloom induced by subsurface upwelling and mixed layer entrainment southwest of Luzon Strait. **Journal of Marine Systems**, v.83, p. 141-149, 2010.
- WATANABE, F.; MMISHRA, D. R.; ASTUTI, I.; RODRIGUES, T.; ALCÂNTARA, E.; IMAI, N. N.; BARBOSA, C. 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.
- WEAVER, E.C.; WRIGLEY, R. **Factors affecting the identification of phytoplankton groups by means of remote sensing**. Moffet Field: NASA, 1994. 121p.
- WET LABS, INC. **Spectral absorption and attenuation meter - AC-S - users guide**: revision j9. Philomath: Wet Labs, 2009. 35 p. 41, 42, 44
- WETZEL, R.G. (Ed.). **Limnology, lake and river ecosystems**. 3.ed. San Diego: Academic Press, 2001. 1006 p.
- WHITMIRE, A.L.; PEGAU, W.S.; KARP-BOSS, L.; BOSS, E.; COWLES, T.J. Spectral backscattering properties of marine phytoplankton cultures. **Optics Express**, v. 18, n. 14, p. 15073, 2010.
- YANG, W.; MATSUSHITA, B.; CHEN, J.; YOSHIMURA, K.; FUKUSHIMA, T. 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.; ZHANG, B.; WANG, X.; LI, J.; FENG, S.; ZHAO, Q.; LIU, M.; QIN, B.. A study of absorption characteristics of chromophoric dissolved organic matter and particles in Lake Taihu, China. **Hydrobiologia**, 592(1), 105-120.