



UNESP – UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE CIÊNCIAS E TECNOLOGIA
PÓS-GRADUAÇÃO EM CIÊNCIAS CARTOGRÁFICAS

MELINA BRUNELLI NUNES

**ANÁLISE DA INFLUÊNCIA DOS POIs SOBRE A ACURÁCIA DA ESTIMATIVA
DA BATIMETRIA VIA IMAGENS ORBITAIS**



Presidente Prudente - SP

2021



UNESP – UNIVERSIDADE ESTADUAL PAULISTA
FACULDADE DE CIÊNCIAS E TECNOLOGIA
PÓS-GRADUAÇÃO EM CIÊNCIAS CARTOGRÁFICAS

MELINA BRUNELLI NUNES

ORIENTADOR: ALUIR PORFÍRIO DAL POZ

CO-ORIENTADOR: ENNER HERÊNIO DE ALCÂNTARA

**ANÁLISE DA INFLUÊNCIA DOS POIs SOBRE A ACURÁCIA DA ESTIMATIVA
DA BATIMETRIA VIA IMAGENS ORBITAIS**



Dissertação apresentada ao Programa de Pós-Graduação em Ciências Cartográficas da Faculdade de Ciências e Tecnologia da Universidade Estadual Paulista, como parte do requisito para obtenção do título de Mestre em Ciências Cartográficas.

Presidente Prudente - SP

2021

N972a Nunes, Melina Brunelli
Análise da influência dos POIs sobre a acurácia da estimativa da batimetria via imagens orbitais / Melina Brunelli Nunes. -- Presidente Prudente, 2022
103 p. : il., tabs.

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências e Tecnologia, Presidente Prudente
Orientador: Aluir Porfírio Dal Poz
Coorientador: Enner Herênio de Alcântara

1. Materiais cartográficos. 2. Imagens de sensoriamento remoto. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências e Tecnologia, Presidente Prudente. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Análise das influências dos POIs sobre a acurácia da estimativa da batimetria via imagens orbitais

AUTORA: MELINA BRUNELLI NUNES

ORIENTADOR: ALUIR PORFIRIO DAL POZ

COORIENTADOR: ENNER HERENIO DE ALCÂNTARA

Aprovada como parte das exigências para obtenção do Título de Mestra em CIÊNCIAS CARTOGRÁFICAS, área: Aquisição, Análise e Representação de Informações Espaciais pela Comissão Examinadora:

Prof. Dr. ALUIR PORFIRIO DAL POZ (Participação Virtual)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente

VIDEOCONFERÊNCIA

Prof. Dr. LUIZ HENRIQUE DA SILVA ROTA (Participação Virtual)
Polícia Científica do Paraná

VIDEOCONFERÊNCIA

Profa. Dra. FERNANDA SAYURI YOSHINO WATANABE (Participação Virtual)
Departamento de Cartografia / Faculdade de Ciências e Tecnologia de Presidente Prudente

Presidente Prudente, 26 de fevereiro de 2021

*Aos meus pais e familiares por todo amor,
apoio e carinho.*

Aos meus amigos, pelo companheirismo.

AGRADECIMENTO

Desejo expressar meu imenso agradecimento a todos que contribuíram para a realização desta pesquisa, direta ou indiretamente. Como não é possível citar todas as pessoas que estiveram envolvidas na minha vida neste tempo, deixo um agradecimento especial:

Aos meus pais, Laerte e Leni, que sempre me apoiaram em todos os momentos e são minha eterna fonte de inspiração. A minha querida irmã Mariana, que sempre me ensinou a ser uma pessoa melhor. Aos tios e primos que sempre me ajudaram e me apoiaram durante a graduação e a pós-graduação.

Ao meu amor, Lucas, pela amizade, companheirismo, força e carinho que me proporcionou ao longo dos anos.

Ao meu orientador Aluir, que me orienta a 5 anos, me ajudando a escolher sempre o melhor caminho. E ao meu coorientador Enner, por me ajudar na busca pelo conhecimento. Sem eles essa pesquisa jamais seria possível.

Aos professores da pós-graduação, que sempre passam o seu conhecimento e experiência com toda paciência.

Aos membros da banca da qualificação Luiz Rotta e Erivaldo, e aos membros da defesa Luiz Rotta e Fernanda Watanabe, que contribuíram com ótimas ideias e sugestões.

À minha “best roomie ever”, Leticia Ferrari, pelas conversas amigáveis no café da manhã, discussões filosóficas, fofocas e almoços. Sem sua companhia essa pós-graduação seria intragável.

Aos amigos da graduação e da pós-graduação: Mariana Santos, Raquel Takahashi, José Pedro Araújo, Leticia Rosim, Gabriel Jerez, Ana Lucia Cristovam, Luis Eduardo, Caio Fontoura, Gabriela Takahashi, Rafael Destro, pelo companheirismo, festas, conversas na cozinha, discussões e aprendizado intelectual.

À UNESP e ao Programa de Pós-Graduação em Ciências Cartográficas, pela estrutura e auxílio.

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

EPÍGRAFE

*“Reserve o seu direito a pensar, mesmo
pensar errado é melhor do que não
pensar.”*

Hipátia de Alexandria

RESUMO

O objetivo desta pesquisa foi explicar os erros na estimaco da batimetria realizada via imagens orbitais relacionando-os com as propriedades pticas inerentes (POI) das guas da Usina Hidreltrica de Tucuru. Primeiramente, corrigiu-se os efeitos atmosfricos da imagem orbital mediante o uso da correo ACOLITE, ento foram estimados os coeficientes de absoro total, (a_t), de retroespalhamento (b_b), o algoritmo quase-analtico (QAA) e a batimetria por modelos estatsticos. Realizou-se, ento a anlise de erro da estimativa da batimetria e sua relao com a_t e b_b . O estudo mostrou que o erro subestimado tem relao com os altos valores de a_t e b_b , ao passo que os sobrestimados podem ser explicados pelos baixos valores de a_t e b_b . Os erros subestimados, portanto, devem-se a maior concentrao de material particulado em suspenso e os erros sobrestimados decorrem da presena de macrfitas submersas em regies mais rasas.

Palavras-chave: Landsat-8; QAA; batimetria; sensoriamento remoto.

ABSTRACT

The aim of this work was to explain the errors of bathymetric retrieval using orbital images and relate them with the inherent optical properties (IOPs) on the water in a dam located in the Amazon region (Tucuruí reservoir). First, the orbital image was corrected from the atmospheric influence using the ACOLITE correction and then estimated the total absorption coefficient (a_t) and the backscattering coefficient (b_b) using the quasi-analytical algorithm (QAA) and the bathymetry using a statistical model. The error analyses correlating a_t and b_b with the bathymetry were realized. The results showed that the underestimation error is related with the highest values of a_t and b_b , while the overestimation error is related to lowest values of a_t and b_b . The underestimation error is related to total suspended matter concentration and the overestimation error is related to the presence of submerged macrophytes on shallower regions.

Keywords: Landsat-8, QAA, bathymetry, remote sensing.

LISTA DE FIGURA

Figura 1 - Esquematização das radiâncias utilizadas, onde L_s é a radiância incidente, L_r é a parte refletida de L_s , L_u é a radiância proveniente do fundo e L_w é a parte transmitida de L_u	23
Figura 2 - Algoritmo DSF aplicado ao satélite Sentinel-2: (a) RMSD do modelo continental e (b) RMSD do modelo marinho	30
Figura 3 - Exemplo de modelo de semivariograma com patamar, alcance e efeito pepita	34
Figura 4 - Interação entre o fluxo incidente da radiação com a água para explicar a geometria utilizada na definição dos POI - Φ_i é o fluxo radiante incidente, Φ_t é o fluxo radiante transmitido, $\Delta\Omega$ é o ângulo solido, ΔX uma distância infinitesimal da coluna d'água, $b(\lambda)$ é o coeficiente de espalhamento e $a(\lambda)$ o coeficiente de absorção	39
Figura 5 - Ângulo zenital do sensor (θ_v), ângulo zenital solar (θ_0), ângulos azimutais (ϕ) reto ao plano de incidência solar.....	41
Figura 6 - Curvas espectrais do coeficiente de absorção da água pura	44
Figura 7 - Coeficiente de absorção do CDOM.....	45
Figura 8 - Coeficiente de absorção de alguns tipos de clorofila encontradas nos fitoplânctons	47
Figura 9 - Coeficiente de absorção NAP	48
Figura 10 - Área de estudo em Tucuruí (PA): (A) Área de estudo no reservatório da Usina Hidrelétrica de Tucuruí e (B) dados de batimetria.	53
Figura 11 - Fluxograma da metodologia empregada.....	55
Figura 12 - Pontos de análise.....	57
Figura 13 - Área que será realizada a batimetria óptica por modelos estatísticos.....	63
Figura 14 - Comparação entre a reflectância de sensoriamento remoto da LaSRC com a ACOLITE RED-NIR.....	64
Figura 15 - Comparação entre a reflectância de sensoriamento remoto da LaSRC com a ACOLITE SWIR1-SWIR2.....	64
Figura 16 - Comparação entre a reflectância de sensoriamento remoto da LaSRC com a ACOLITE DSF.....	65
Figura 17 - Coeficiente de absorção total (a_t) estimado pelo QAA	67
Figura 18 - Coeficiente de retroespalhamento (b_b) estimado pelo QAA.....	68
Figura 19 - Reflectância de sensoriamento (R_{sr}) remoto para cada ponto.....	68
Figura 20 - Resultados do QAA da absorção total (I) e do retroespalhamento (II) aplicada as bandas: (a) Azul costal; (b) Azul; (c) Verde e (d) Vermelha	69

Figura 21 - K_d (482) estimado	70
Figura 22 - Batimetria obtida por krigagem ordinária: (a) gaussiana; (b) exponencial; (c) esférica e (d) circular	73
Figura 23 - Validação cruzada dos dados de krigagem (K.O.): (a) gaussiana; (b) exponencial; (c) esférica e (d) circular.....	74
Figura 24 - Transecto A: comparação entre valores originais e interpolados	75
Figura 25 - Transecto B: comparação entre valores originais e interpolados	75
Figura 26 - Outliers presentes no modelo de Lyzenga (1978) para a área aplicada.....	78
Figura 27 - Outliers presentes no modelo de Stumpf et al. (2003) para a área aplicada	79
Figura 28 - Outliers presentes no modelo de Diersen et al. (2003) para a área aplicada	79
Figura 29 - Distribuição dos pontos DFFITS e distância de Cook para os modelos de: (a) Lyzenga (1978); (b) Stumpf et al. (2003) e (c) Diersen et al. (2003).....	80
Figura 30 - Análise do erro ao estimar a batimetria: (a) Batimetria coletada pelo Sonar e interpolada por krigagem Ordinária Exponencial; (b) Batimetria estimada pelo método de Lyzenga (1978) e (c) diferença entre batimetria de campo e estimada	81
Figura 31 - Gráfico do viés de cada profundidade	82
Figura 32 - Reflectância de sensoriamento remoto para as bandas: (a) azul costal; (b) azul; (c) verde e (d) vermelho.....	85
Figura 33 - Resultados aplicado para área de batimetria viável: (a) erro entre a batimetria estimada e verdadeira; (b) composição colorida da área em 1984; ; (c) K_d (490); (d) $at(443)$; (e) at (482); (f) at (562); (g) at (655); (h) $b_b(443)$; (i) $b_b(482)$; (j) $b_b(562)$; e (k) $b_b(655)$	86
Figura 34 - Absorção total (at) de lugares que possuem erros subestimado e sobrestimado ..	88
Figura 35 - Retroespalhamento (bb) de lugares que possuem erros subestimado e sobrestimado	88

LISTA DE TABELA

Tabela 1 - Algumas bandas do Landsat-8 com os seus respectivos intervalos de comprimento de onda (λ), comprimento de onda central, irradiância solar média (F_0), média da espessura óptica associada ao espalhamento de Rayleigh em uma atmosfera padrão (τ_r) e média da espessura óptica associada ao espalhamento de ozônio em uma atmosfera padrão (τ_{oz})	22
Tabela 2 - Relação entre a correção ACOLITE e o produto LaSRC	66
Tabela 3 - K_d (490), a_t e b_b estimados e profundidade coletada para os nove pontos.....	71
Tabela 4 - Parâmetros do semivariograma utilizado na interpolação da batimetria.....	72
Tabela 5 - Dados de RMSE dos transectos para cada tipo de interpolador.....	76
Tabela 6 - Análise de batimetria estimada por modelos estatísticos	77

LISTA DE QUADRO

Quadro 1 - Equações dos principais semivariogramas e suas respectivas condições.....	34
Quadro 2 - Algoritmo do QAA para bandas do sensor OLI.....	58

LISTA DE SIGLAS E ACRÔNIMOS

ACOLITE - *Atmospheric Correction for OLI 'lite'*
AIC - *Aikaike Information Criteria* - Critério de Informação de Akaike
BIC - *Bayesian Information Criterion* - critério de informação Bayseano
CDOM - matéria orgânica dissolvida colorida
COA - componentes opticamente ativas
DOS - *Dark-Object Subtraction*
DSF - *dark spectrum fitting*
INPE - Instituto Nacional de Pesquisas Espaciais
LabISA - Laboratório de Instrumentação de Sistemas Aquáticos
LaSRC - *Landsat Surface Reflectance Code*
LEADAPS - *Landsat Ecosystem Disturbance Adaptive Processing System*
LiDAR - *Light Detection and Ranging*
MOD - matéria orgânica dissolvida
MODTRAN - *Moderate resolution atmospheric transmission*
NAP - *non-algal particles* - partículas não algais
NASA - *National Aeronautics and Space Administration*
ND - Número Digital
NIR - infravermelho próximo
OLI - *Operational Land Imager*
POA - Propriedade Óptica Aparente
POI - Propriedades Ópticas Inerentes
QAA - *Quasi-Analytical Algorithm* - algoritmo quase-analítico
RBINS - *Royal Belgian Institute of Natural Sciences*
RMSD - *Root mean square difference*
RMSE - *Root Mean Square Error*
Sonar - *Sound Navigation and Ranging*
SWIR - infravermelho de ondas curtas
TIRS - *Thermal Infrared Sensor*
TOA - topo da atmosfera
TSS - total de sólidos em suspensão
USGS - *United States Geological Survey*

LISTA DE SÍMBOLOS

a - patamar

A_L - valor aditivo

a_{ph} - coeficiente de absorção de fitoplâncton

a_t - coeficiente de absorção total

a_w - coeficiente de absorção da água pura

$b(\lambda)$ - coeficiente de espalhamento

b_b - coeficiente retroespalhamento total

b_{bp} - coeficiente de retroespalhamento de partículas suspensas

b_{bw} - coeficiente de espalhamento da água pura

b_f - espalhamento para frente

$b_{bw}(\lambda)$ - coeficiente de retroespalhamento da água pura

$\beta(\psi, \lambda)$ - função de espalhamento volumétrico

λ - comprimento de onda

C_o - efeito pepita

C - alcance

d - distância Terra-Sol

$\Delta\Omega$ - ângulo sólido

ΔX - distância infinitesimal da coluna d'água

$\Delta\phi$ - ângulo azimutal relativo entre o Sol e o sensor

E_{dz} - irradiância descendente na profundidade Z

$E_{d0(z=0^-)}$ - irradiância descendente logo abaixo da superfície

E_d - irradiância descendente

E_s - irradiância incidente

ζ - parâmetro que está relacionado a absorção pelo fitoplâncton

ξ - parâmetro que está relacionado a absorção da matéria orgânica absorvida

ε - tipo de aerossol

F_0 - irradiância solar média

θ - ângulo incidente

θ_0 - ângulo zenital solar

θ_- - ângulo de espalhamento dos fótons que não interagiram com a superfície da água

θ_+ - ângulo de espalhamento dos fótons que são refletidos pela superfície da água antes ou depois de sofrerem o espalhamento

θ_t - ângulo de transmitância

θ_v - ângulo zenital do sensor

h - distância

K_d - coeficiente de atenuação da irradiância difusa descendente

L_p - função de máxima verossimilhança do modelo

L_r - parte da radiância difusa do céu que é refletida pela água

L_s - radiância incidente

$L_{sky}(\theta', \phi', \lambda')$ - radiância difusa do céu medida por ângulos opostos ao $\theta\epsilon\phi$

L_{TOA} - radiância no topo da atmosfera

L_u - radiância proveniente do fundo e

L_w - radiância que deixa a água

M_L - fator multiplicativo

n - número de observações

n_w - índice de refração da água

p - número de parâmetros

p_i - pesos associados a $Z(x_i)$

$P_r(\theta)$ - função de fase para o espalhamento de Rayleigh para um ângulo de espalhamento θ

ρ - fator de proporcionalidade

ρ_a - reflectância de aerossóis

ρ_{am} - reflectância do espalhamento múltiplo do aerossol

ρ_c - correção da reflectância de Rayleigh

ρ_{dark} - espectro escuro

ρ_g - refletância da cintilação

ρ_{path} - reflectância da trajetória atmosférica

ρ_{pc} - reflectancia corrigida da trajetória atmosférica

ρ_r - reflectância de Rayleigh

ρ_s - reflectância de superfície

ρ_{sky} - estimativa da radiação proveniente do céu na interface ar-água

ρ_{TOA} - reflectância no topo da atmosfera

ρ_w - reflectância da água

$\Phi_a(\lambda)$ - fluxo radiante absorvido

$\Phi_i(\lambda)$ - fluxo radiante incidente de um feixe paralelo e monocromático

$\Phi_s(\lambda)$ - fluxo radiante espalhado

ϕ_v - ângulo azimutal do sensor

ϕ_0 - ângulo azimutal do Sol

R_∞ - menor refletância da água

R_{sr} - refletância de sensoriamento remoto

$r(\theta)$ - refletância de Fresnel para os raios incidentes na atmosfera em um determinado ângulo incidente θ

r_{rs} - refletância de sensoriamento remoto subsuperfície

s_a - albedo esférico da atmosfera

T_{dir} - transmitância direta da atmosfera

t_0 - transmitância difusa Sol-Mar

t_{du} - transmitância difusa da atmosfera do Sol-Mar-Sensor

t_v - transmitância difusa Mar-Sensor

τ_{oz} - média da espessura óptica associada ao espalhamento de ozônio em uma atmosfera padrão

τ_r - média da espessura óptica associada ao espalhamento de Rayleigh em uma atmosfera padrão

τ_t - espessura óptica total da atmosfera

V_i - sinal da banda i,

V_{si} - sinal de águas profundas na banda i

x_o - valor de uma variável de interesse de um ponto não amostrado

Z - profundidade

SUMÁRIO

1. INTRODUÇÃO	17
1.1. Considerações iniciais	17
1.2. Objetivo	19
2. FUNDAMENTAÇÃO TEÓRICA.....	20
2.1. Correção Atmosférica	20
2.1.1. Correção atmosférica exponencial: utilizando as bandas 4 e 5 do Landsat-8.	21
2.1.2. Correção atmosférica exponencial: utilizando as bandas 6 e 7 do Landsat-8	26
2.1.3. Dark Spectrum Fitting.....	28
2.1.3.1. Variabilidade espacial.....	31
2.1.3.2. Efeito de espalhamento.....	32
2.2. Krigagem.....	33
2.3. Recuperação da batimetria	35
2.4. Propriedades ópticas da água	37
2.4.1. Propriedades Ópticas Inerentes (POIs)	38
2.4.2. Propriedades Ópticas Aparentes (POAs)	40
2.4.2.1. Refletância de sensoriamento remoto (R_{sr}).....	40
2.4.2.2. Coeficiente de atenuação difusa (K_d).....	42
2.5. Componentes Opticamente Ativos (COA).....	43
2.5.1. Água pura	44
2.5.2. CDOM.....	45
2.5.3. Total de sólidos em suspensão	46
2.5.3.1. Fitoplânctons	46
2.5.3.2. NAP.....	47
2.6. Algoritmos bio-ópticos.....	48
2.6.1. QAA	49
3. MATERIAIS E MÉTODOS.....	53
3.1. Área de estudo	53
3.2. Dados.....	54
3.3. Métodos	54
3.3.1. Correção atmosférica.....	56

3.3.2.	Estimação de $ate\ b_b$	58
3.3.3.	Coeficiente de atenuação difusa	59
3.3.4.	Interpolação de dados do sonar	60
3.3.5.	Modelos batimétricos	60
4.	RESULTADOS	64
4.1.	Correção atmosférica.....	64
4.2.	Estimação dos POI	67
4.3.	Coeficiente de atenuação difusa da luz	70
4.4.	Interpolação dos dados de batimetria	71
4.5.	Batimetria óptica	76
5.	DISCUSSÃO	83
6.	CONCLUSÕES E RECOMENDAÇÕES	91

1. INTRODUÇÃO

1.1.Considerações iniciais

A construção de grandes reservatórios de usinas hidrelétricas traz vários impactos negativos para o ecossistema, como a perda da biodiversidade aquática e biológica, emissão de gases do efeito estufa e deterioração da qualidade da água (WCD, 2000), além de causar a modificação da dinâmica natural do próprio rio alterando sua forma, largura, comprimento e profundidade. Devido a essas alterações, a atualização de mapas batimétricos dos reservatórios é de grande importância para a sociedade, entretanto, os reservatórios da região Amazônica raramente possuem informação batimétrica.

Um levantamento batimétrico acurado é o dado mais importante para as atualizações das cartas batimétricas. As técnicas mais utilizada atualmente para a realização desse tipo de levantamento é o sonar (*Sound Navigation and Ranging*) e o LiDAR (*Light Detection and Ranging*) (PACHECO *et al.*, 2015). As grandes desvantagem dessas técnicas são o tempo e o custo necessários para realizar esses levantamentos (DIERSEN; THEBERGE, 2014). Uma solução rápida e eficaz para a atualização de cartas que vem ganhando espaço são os modelos batimétricos derivados de imagens, principalmente de imagens de satélite (NIROUMAND-JADIDI; VITTI; LYZENGA, 2018; PACHECO *et al.*, 2015).

Para a estimativa de batimetria via imagens orbitais, há duas abordagens principais. Uma é baseada em modelos estatísticos que utilizam regressões que correlacionam informações da imagem com dados de profundidade coletados a campo (LYZENGA, 1978; STUMPF *et al.*, 2003; DIERSEN *et al.*, 2003). A outra abordagem é baseada em princípios físicos que utilizam somente a imagem para determinação da profundidade (LEE *et al.*, 1999; KERR; PURKIS, 2018).

A dificuldade apresentada na recuperação da batimetria para ambas as abordagens é a baixa acurácia na estimativa de águas mais profundas ou turbidas. Estudos mostram uma limitação de profundidade em que é possível a recuperação batimétrica com uma acurácia aceitável, essa limitação está entre 9 m a 20 m (ALCÂNTARA *et al.*, 2010; KERR; PURKIS, 2018; LEGLEITER; FOSNESS, 2019; PACHECO *et al.*, 2015). Esse limite é estabelecido, pois há uma atenuação da luz na água que varia de acordo com a quantidade de materiais dissolvidos e suspensos.

Muitos estudos são capazes de estimar as concentrações dos elementos que minimizam a radiação solar incidente na água (FAN, 2014; QU, 2014; WATANABE, 2016). As substâncias

presentes na água que interagem com a luz são chamadas de componentes opticamente ativos (COAs), sendo as principais: água pura, matéria orgânica colorida dissolvida (CDOM) e total de sólidos em suspensão (RUDORFF *et al.*, 2007). Esses componentes são responsáveis pela absorção e pelo espalhamento da radiação solar na coluna d'água.

Os coeficientes de absorção e espalhamento são propriedades ópticas inerentes (POIs), ou seja, são propriedades da água que não variam por intervenções do meio, como a geometria do campo de luz. Esses parâmetros necessitam ser medidos mediante sensores ativos, porém há alguns algoritmos capazes de inferir esses parâmetros a partir de imagens de satélite. Tais algoritmos são classificados em empíricos, semianalíticos ou analíticos (FAN, 2014; LEE, 2002, LEE, 2009; QU, 2014). Um dos algoritmos semianalíticos muito utilizado por sua fácil implementação é o denominado algoritmo quase-analítico (QAA – *Quasi-Analytical Algorithm*), introduzido por Lee *et al.* (2002), que envolve algumas etapas analíticas e outras empíricas.

O referido algoritmo é capaz de estimar o coeficiente de absorção total (a_t) e o retroespalhamento (b_b). Inicialmente, o QAA foi implementado para águas oceânicas, contudo, na literatura, há artigos que apresentam bons resultados utilizando o QAA para outros ambientes aquáticos (WATANABE *et al.*, 2018; ANDRADE *et al.*, 2019).

Para a região Amazônica, poucos estudos são realizados devido à dificuldade em se fazer o levantamento de campo e obter imagens orbitais livres de nuvens. Reservatórios situados nessa região mostram alta complexidade em suas águas, com alto conteúdo de matéria orgânica dissolvida por conta da decomposição da vegetação anteriormente dominante nesse espaço. Outro problema característico dessa região seriam os troncos de árvores que atingem a superfície da água, dificultando a mobilidade (CURTARELLI *et al.*, 2015).

Apesar de existir vários estudos em ambientes aquáticos, poucos correlacionam o erro da estimativa da batimetria com os POIs. Tendo isso em vista, esta pesquisa procura assimilar os erros estimados da batimetria com os coeficientes de absorção total (a_t) e de retroespalhamento (b_b) para cada pixel da imagem. Este estudo será desenvolvido no reservatório da Usina Hidrelétrica de Tucuruí, localizada na região Amazônica do Brasil, utilizando dados multiespectrais do sensor OLI (*Operational Land Imager*) embarcado no satélite Landsat – 8. Para a recuperação da batimetria, serão utilizados algoritmos baseados em métodos estatísticos e para o cálculo de a_t e b_b será utilizado o QAA.

1.2.Objetivo

O objetivo principal desta pesquisa é identificar como os POIs influenciam na estimativa da batimetria a partir do sensoriamento remoto.

Os objetivos específicos deste trabalho são:

1. Avaliar o desempenho dos modelos de correção atmosférica ACOLITE existentes, comparando este modelo com o *Land Surface Reflectance Code* (LaSRC);
2. Aplicar método de interpolação espacial mais adequado para os dados de batimetria de campo;
3. Ajustar e validar uma função empírica para estimar a batimetria óptica;
4. Estimar as POI por meio do QAA;
5. Analisar os valores de a_t e b_b comparando-os com os erros da estimativa de batimetria óptica e explicar o significado dessa análise correlacionando com as características do reservatório.

2. FUNDAMENTAÇÃO TEÓRICA

Esta seção aprofunda o conhecimento em algumas técnicas e conceitos de sensoriamento remoto e recuperação de batimetria. A Seção 2.1 introduz conceitos sobre a Correção Atmosférica e explica a correção que será aplicada neste trabalho. A Seção 2.2 explica sobre a interpolação por krigagem. Já a Seção 2.3 intitulado Recuperação da Batimetria apresenta alguns estudos relacionados ao tema como Lyzenga (1974), Diersen *et al.* (2003) e Stumpf *et al.* (2003). Na Seção 2.4, são explicadas as propriedades ópticas da água, enquanto que, na Seção 2.5, há o esclarecimento dos componentes opticamente ativos. Por fim, na Seção 2.6, é introduzido o conceito de algoritmos bio-ópticos.

2.1. Correção Atmosférica

Ao tratar imagens de satélite que utilizam alvos com características físico-químicas ou biológicas é necessário realizar a correção atmosférica na imagem, com o objetivo de minimizar os efeitos causados pelos componentes presentes na atmosfera, estimando a reflectância de superfície de cada alvo. Essas correções realizam a transformação do número digital (ND) em radiância do sensor e, então, em reflectância de superfície (HAMM; ATKINSON; MILTON, 2012).

Algumas técnicas são muito utilizadas nessa correção: o modelo de transferência radiativa como *Moderate resolution atmospheric transmission* – MODTRAN (BERK *et al.*, 1999); os modelos baseados na imagem como *Dark-Object Subtraction* – DOS (PACHECO *et al.*, 2015), *Atmospheric Correction for OLI 'lite'* – ACOLITE (VANHELLEMONT; RUDDICK, 2015); e modelos empíricos (HAMM; ATKINSON; MILTON, 2012).

Além dessas correções, há também a correção Level-2 utilizada pelos satélites Landsat, que disponibiliza para o usuário a imagem com a reflectância de superfície. Para os satélites da série Landsat 4, 5 e 7, utiliza-se a correção *Landsat Ecosystem Disturbance Adaptive Processing System* (LEADAPS), enquanto que, para o satélite Landsat 8, é utilizado a *Landsat Surface Reflectance Code* (LaSRC).

Dentre os métodos citados, o ACOLITE é uma das mais utilizadas em áreas com corpos d'água, pois apresenta bom desempenho em alvos terrestres e aquáticos (VANHELLEMONT; RUDDICK, 2015). Há, na literatura, três modelos de correções ACOLITE. Um deles utiliza a banda do vermelho (banda 4 do Landsat-8 de comprimento de onda 630 a 680nm) e da banda do infravermelho próximo (NIR - banda 5 do Landsat-8 de comprimento de onda 845 a 885nm)

(VANHELLEMONT; RUDDICK, 2014). Outro modelo utiliza as bandas do infravermelho de ondas curtas (SWIR – banda 6 e 7 do Landsat-8 de 1560 a 1660 nm e 2100 a 2300 nm, respectivamente) (VANHELLEMONT; RUDDICK, 2015). Os dois primeiros modelos são chamados de correção atmosférica exponencial, ao passo que o terceiro modelo é chamado de *dark spectrum fitting* (DSF), sendo inteiramente baseado na imagem, não necessitando de fatores externos como parâmetro de entrada.

2.1.1. Correção atmosférica exponencial: utilizando as bandas 4 e 5 do Landsat-8

O algoritmo utilizado para as bandas do vermelho e do infravermelho próximo (banda 4 e 5 do Landsat-8), tem como primeiro passo transformar o número digital em radiância, como mostra a Equação 1:

$$L_{TOA} = M_L \times ND + A_L \quad (1)$$

Onde L_{TOA} é a radiância no topo da atmosfera (TOA), M_L é o fator multiplicativo e A_L o valor aditivo, ambos são disponibilizados no arquivo metadado disponibilizados juntamente com as imagens do Landsat-8. A próxima etapa consiste em transformar a radiância encontrada em reflectância no topo da atmosfera (ρ_{TOA}) segundo a Equação 2:

$$\rho_{TOA} = \frac{\pi \times L_{TOA} \times d^2}{F_0 \times \cos(\theta_0)} \quad (2)$$

Onde d é a distância Terra-Sol em unidades astronômicas, θ_0 é o ângulo zenital solar e F_0 é a irradiância solar média (Tabela 1).

Tabela 1 - Algumas bandas do Landsat-8 com os seus respectivos intervalos de comprimento de onda (λ), comprimento de onda central, irradiância solar média (F_0), média da espessura óptica associada ao espalhamento de Rayleigh em uma atmosfera padrão (τ_r) e média da espessura óptica associada ao espalhamento de ozônio em uma atmosfera padrão (τ_{oz})

Banda	λ (nm)	$\lambda_{\text{médio}}$ (nm)	F_0 ($\text{W m}^{-2} \mu\text{m}^{-1}$)	τ_r	τ_{oz}
1 – Azul Costal	433-453	443	1895,6	$2,35 \cdot 10^{-1}$	$8,79 \cdot 10^{-4}$
2 – Azul	450-515	482	2004,6	$1,69 \cdot 10^{-1}$	$5,87 \cdot 10^{-3}$
3 – Verde	525-600	562	1820,7	$9,02 \cdot 10^{-2}$	$3,14 \cdot 10^{-2}$
4 – Vermelho	630-680	655	1549,4	$4,79 \cdot 10^{-2}$	$1,82 \cdot 10^{-2}$
5-Infravermelho próximo	845-885	865	951,2	$1,55 \cdot 10^{-2}$	$6,43 \cdot 10^{-4}$
6 – Infravermelho de ondas curtas 1	1560-1660	1610	247,6	$1,28 \cdot 10^{-3}$	0
7 – Infravermelho de ondas curtas 2	2100-2300	2200	85,5	$3,70 \cdot 10^{-4}$	0

Fonte: adaptada de Vanhellemont e Ruddick (2014), calculada pela tabela de Brian Franz.¹


Ainda é necessário transformar a reflectância do topo da atmosfera em reflectância de superfície e, como se trata de uma superfície de água, faz-se necessário encontrar a reflectância da água, que é definida pela Equação 3:

$$\rho_w = \pi \times \frac{L_w}{E_d} \quad (3)$$

¹ Disponível em: <http://oceancolor.gfsc.nasa.gov/DOCS/RSR_tables.html> Acesso em: 12 agosto de 2019

Onde L_w é a radiância que deixa a água (observado pela Figura 1), E_d é a irradiância descendente e π a Constante de Arquimedes. Como essas dimensões não são identificadas pelo sensor, ρ_w deve ser obtida de outro modo.

Figura 1 - Esquematização das radiâncias utilizadas, onde L_s é a radiância incidente, L_r é a parte refletida de L_s , L_u é a radiância proveniente do fundo e L_w é a parte transmitida de L_u .



Fonte: Adaptado de Mobley (1999)

Sabe-se que a reflectância no topo da atmosfera também pode ser representada pela soma das reflectâncias observadas pelo sensor, como mostra a Equação 4.

$$\rho_{TOA} = \rho_a + \rho_r + t_0 \times t_v \times \rho_w \quad (4)$$

Deve-se entender que ρ_a é a reflectância de aerossóis, ρ_r a reflectância de Rayleigh, ρ_w a reflectância que sai da água (reflectância da água), t_0 a transmitância difusa Sol-Mar e t_v a transmitância difusa Mar-Sensor. A reflectância da água é o parâmetro de interesse na Equação 4. Uma vez que se sabe o valor da reflectância no topo da atmosfera dado pela Equação 2, é preciso encontrar os parâmetros ρ_a, ρ_r, t_0 e t_v .

As transmitâncias difusas são estimadas pela Equação 5, onde t_0 se utiliza de θ_0 e t_v se utiliza de θ_v (VANHELLEMONT; RUDDICK, 2014).

$$t_{0,v} = e^{-\frac{\frac{\tau_r + \tau_{oz}}{2}}{\cos \theta_{0,v}}} \quad (5)$$

Onde τ_r é a média das espessuras óptica associada ao espalhamento de Rayleigh das bandas (Tabela 1), τ_{oz} é a média da espessura óptica de ozônio das bandas do Landsat-8 (Tabela 1), θ_0 é o ângulo zenital solar e θ_v o ângulo zenital do sensor.

A reflectância de Rayleigh é estimada conforme a Equação 6:

$$\rho_r = \tau_r \times p_r(\theta_0, \theta_v, \Delta\phi) \times (4 * \cos\theta_0 \times \cos\theta_v)^{-1} \quad (6)$$

Onde $\Delta\phi$ é o ângulo azimutal relativo entre o Sol e o sensor, o valor de τ_r é apresentado pela Tabela 1. θ_0 é o ângulo zenital solar, θ_v o ângulo zenital do sensor e $p_r(\theta_0, \theta_v, \Delta\phi)$ é dado pela Equação 7:

$$p_r(\theta_0, \theta_v, \Delta\phi) = P_r(\theta_-) + [r(\theta_v) + r(\theta_0)] \times P_r(\theta_+) \quad (7)$$

Em que:

$$P_r(\theta) = 0,75 \times (1 + \cos^2 \theta) \quad (8)$$

$$r(\theta) = 0,5 \times \left\{ \frac{\sin^2(\theta - \theta_t)}{\sin^2(\theta + \theta_t)} + \frac{\tan^2(\theta - \theta_t)}{\tan^2(\theta + \theta_t)} \right\} \quad (9)$$

$$\theta_t = \sin^{-1}(n_w \times \sin\theta) \quad (10)$$

$$\cos \theta_{\pm} = \pm \cos\theta_0 \times \cos\theta_v - \sin\theta_0 \times \sin\theta_v \times \cos |\phi_0 - \phi_v| \quad (11)$$

Onde $P_r(\theta)$ é a função de fase para o espalhamento de Rayleigh² para um ângulo de espalhamento θ ; θ_- é o ângulo de espalhamento dos fótons³ que não interagiram com a superfície da água (calculado pela Equação 11); θ_+ é o ângulo de espalhamento dos fótons que são refletidos pela superfície da água antes ou depois de sofrerem o espalhamento (calculado pela Equação 11); $r(\theta)$ é a reflectância de Fresnel para os raios incidentes na atmosfera em um

² Função de fase calcula a distribuição angular da intensidade da luz espalhada por uma partícula em um determinado comprimento de onda.

³ Fótons são partículas que compõe a luz.

determinado ângulo incidente θ ; θ_t é o ângulo de transmitância; n_w é o índice de refração ar-água (1,34); e ϕ_0, ϕ_v são os ângulos azimutais do Sol e do sensor, respectivamente. Sabendo que a correção da reflectância de Rayleigh (ρ_c) é a subtração da reflectância de Rayleigh na reflectância no topo da atmosfera, e utilizando a Equação 4, tem-se que a correção da reflectância de Rayleigh é dada pela Equação 12:

$$\rho_c = \rho_{TOA} - \rho_r = \rho_a + t_0 \times t_v \times \rho_w \quad (12)$$

A correção ACOLITE assume que a taxa da reflectância da água entre duas bandas é uma constante (α), como mostra a Equação 13 (VANHELLEMONT; RUDDICK, 2015):

$$\alpha = \frac{\rho_w^{(4)}}{\rho_w^{(5)}} = \frac{\rho_{w(780)}^{655}}{\rho_{w(780)}^{865}} = \frac{4,734}{0,544} = 8,702 \quad (13)$$

Os sobrescritos (4) e (5) indicam as bandas 4 e 5 do sensor. Os valores de $\rho_{w(780)}^{655}$ e $\rho_{w(780)}^{865}$ são encontrados em Ruddick *et al.* (2006), que explica que são valores de reflectância da água normalizada, onde o valor de reflectância da água da banda em questão é dividida pela reflectância da água na banda 780 nm pois nesta banda a absorção da água é independente da temperatura. Para as bandas 4 e 5 utiliza-se os valores correspondentes ao comprimento de onda médio de cada banda (655 e 865 respectivamente).

A taxa da reflectância do espalhamento do aerossol entre duas bandas também é uma constante dada pela Equação 14:

$$\varepsilon = \frac{\rho_a^{(4)}}{\rho_a^{(5)}} = 1 \quad (14)$$

Segundo Ruddick *et. al* (2000), manipulando as equações 4, 5, 6, 12, 13 e 14, a reflectância da água é dada pela Equação 15:

$$\rho_w = \frac{\alpha}{t_0^{(5)} \times t_v^{(5)}} \times \left[\frac{\rho_c^{(4)} - \rho_c^{(5)}}{\alpha \times \gamma - \varepsilon} \right] \quad (15)$$

Onde:

$$\gamma = \frac{t_0^{(4)} \times t_v^{(4)}}{t_0^{(5)} \times t_v^{(5)}} \quad (16)$$

Portanto, é possível calcular a reflectância da superfície que deixa a água. Essa correção mostra bons resultados para ambientes de águas mais claras (VANHELLEMONT; RUDDICK, 2014).

2.1.2. Correção atmosférica exponencial: utilizando as bandas 6 e 7 do Landsat-8

A correção ACOLITE quando utiliza as bandas do SWIR consegue um resultado acurado para águas túrbidas (VANHELLEMONT; RUDDICK, 2015) e águas rasas (WEI *et al.*, 2018) se comparado a outros modelos de correção atmosférica existentes. Uma das vantagens desse modelo em relação ao anterior é que a reflectância da água das bandas do SWIR (ρ_w^6 e ρ_w^7 para as bandas 6 e 7 respectivamente) são consideradas iguais a zero.

O algoritmo desse modelo tem grande similaridade com o do modelo anterior, utilizando-se das equações 1 a 12. Manipulando a Equação 12 e sabendo que a reflectância da água nas bandas do SWIR é nula, tem-se a Equação 17:

$$\rho_c = \rho_{am} \quad (17)$$

Importante destacar que a Equação 17 é válida somente para as bandas do SWIR, onde ρ_c é a correção da reflectância de Rayleigh e ρ_{am} é a reflectância do espalhamento múltiplo⁴ do aerossol.

Nesse modelo, os pixels são classificados como sendo de água ou não. Para tanto, é estipulado um limiar com $\rho_c^{(6)} > 0,0215$. Esse limiar consegue diferenciar a água de outros alvos, como objetos flutuantes, construções na área costeira, nuvens e alvos terrestres.

O tipo de aerossol ε pode ser calculado como na Equação 14, com uma pequena mudança, como mostra a Equação 18:

$$\varepsilon = \frac{\rho_a^{(6)}}{\rho_a^{(7)}} = 1 \quad (18)$$

É possível, também, calcular ε para todos os comprimentos de onda utilizando a Equação 19:

$$\varepsilon^{i,7} = \varepsilon^{\delta i} \quad (19)$$

Onde i é a banda que será aplicada à correção e δi é dado pela Equação 20:

$$\delta i = \frac{\lambda_7 - \lambda_i}{\lambda_7 - \lambda_6} \quad (20)$$

Onde λ_6 e λ_7 são os comprimentos de onda centrais da banda 6 e 7, respectivamente, e λ_i é o comprimento de onda da banda que está sendo aplicada a correção. Portanto, para o cálculo da reflectância da água em outras bandas, utilizando-se dessa correção atmosférica, tem-se a Equação 21:

$$\rho_w^i = \frac{1}{t_0^{(i)} \times t_v^{(i)}} \times (\rho_c^{(i)} - \varepsilon^{i,7} \times \rho_{am}^7) \quad (21)$$

⁴ Espalhamento múltiplo é quando a luz incidente em uma partícula se espalha atingindo outra partícula, a qual se espalha e atinge o sensor ou outra partícula (Liou, 2002).

2.1.3. Dark Spectrum Fitting

O *dark spectrum fitting* (DSF) foi inicialmente implementado para imagens com alta resolução espacial e adaptado para os sensores com uma resolução espacial média, como os embarcados no Landsat-8 e no Sentinel-2. Esse modelo leva em consideração a reflectância da trajetória atmosférica (ρ_{path}) e pressupõe que a atmosfera seja homogênea em uma determinada área e que pelo menos uma das bandas do sensor tenha a reflectância de superfície⁵ nula ($\rho_s \approx 0$) (VANHELLEMONT, 2019).

Para realizar o cálculo desse modelo de correção atmosférica, é necessário encontrar os parâmetros mais apropriados para a cena (reflectância da trajetória atmosférica ρ_{path} , a transmitância difusa da atmosfera do Sol-Mar-Sensor $t_{du} = t_0 \times t_v$ e o albedo esférico⁶ da atmosfera s_a). Por essa razão, deve-se determinar a melhor combinação de bandas e o melhor modelo de aerossol (continental ou marinho).

Para isso, é necessário encontrar um valor representativo como sendo o espectro escuro (ρ_{dark}). Esse ρ_{dark} seleciona o menor valor significativo⁷ de ρ_{TOA} de cada banda. O ρ_{dark} é utilizado para encontrar a melhor combinação de bandas e o melhor modelo de aerossol em três passos (VANHELLEMONT, 2019):

- O ρ_{path} será estimado para cada modelo de aerossol e para cada espessura óptica do aerossol em um comprimento de onda 550 nm (τ_a). Na LUT, encontra-se alguns valores de τ_a e, para cada valor desses, é encontrado um ρ_{path} em cada banda para ambos os modelos de aerossóis (esse passo pode ser observado na Figura 2 nas linhas pontilhadas coloridas, onde cada cor representa um intervalo de τ_a). O ρ_{dark} de uma banda i está entre duas linhas do ρ_{path} da mesma banda i , porém, não é conhecido o τ_a desse ponto, sabe-se apenas que ele está em um intervalo. Por isso, interpola-se, linearmente, os valores de τ_a com o ρ_{dark} para cada banda e cada modelo de aerossol, sendo possível encontrar, assim, o valor mais apropriado de τ_a (os pontos em preto plotados na Figura 2 mostram os pontos ρ_{dark} e os valores apresentados próximo a esses pontos são os valores interpolados de τ_a).

⁵ Nesse caso, a reflectância de superfície não é apenas da superfície da água como também da superfície terrestre.

⁶ Albedo de um planeta, dada pelo quociente entre o fluxo refletido (integração da intensidade refletida para todo o espaço) e o fluxo incidente, ambos integrados sobre todo o espectro solar.


⁷ Encontra-se, por regressão linear, o menor valor significativo.

- Então, para cada modelo é escolhido o menor valor do τ_a interpolado e verifica-se a qual banda este valor está associado. Na Figura 2, é observado que, para o modelo continental, a banda 1 do satélite Sentinel-2 de 443 nm é escolhida por apresentar o menor τ_a de $\sim 0,24$ e, no modelo marinho, a banda 11 do satélite Sentinel 2 de 1610 nm é escolhida por apresentar o menor $\tau_a \sim 0,10$.

- Por fim, estima-se uma nova ρ_{path} em cada banda para o menor valor de τ_a em cada um dos modelos de aerossóis. Essa nova ρ_{path} é comparada com ρ_{dark} por meio da raiz da diferença media quadrática (RMSD - *root mean square difference*),⁸ calculada para cada par de banda contendo a banda selecionada no passo anterior e para cada modelo de aerossol. Destarte, o par de bandas que tem o menor RMSD será utilizado para realizar a correção atmosférica e o modelo de aerossol escolhido será o que possui o menor RMSD (na Figura 2, observa-se que, para o modelo continental, as bandas 1 e 8 do satélite Sentinel-2 de 443 nm e 833 nm, respectivamente, são as mais apropriadas, enquanto que, para o modelo marinho, a banda 11 e 12 do satélite Sentinel-2 de 1610 nm e 2190 nm, respectivamente, são melhores). Tendo-se em mente que o RMSD do par de banda 1 e 8 é $1,6 \cdot 10^{-4}$ e para o par de banda 11 e 12 é de $6,3 \cdot 10^{-4}$, a melhor escolha do modelo de aerossol é a do modelo continental.

⁸ RMSD é dado por: $RMSD = \sqrt{\frac{1}{N} \sum_{i=1}^N (\rho_{darj} - \rho_{path_{i,j}})^2}$, onde j é a banda selecionada no passo 2 e i são as bandas restantes.

Figura 2 - Algoritmo DSF aplicado ao satélite Sentinel-2: (a) RMSD do modelo continental e (b) RMSD do modelo marinho



Fonte: Adaptado de Vanhellemont (2019)

Todos os parâmetros necessários para realizar a correção atmosférica estão disponíveis na LUT para valor de τ_a encontrado para o modelo de aerossol apropriado. Portanto, é possível calcular ρ_s pela Equação 22:

$$\rho_s = \frac{\rho_{pc}}{t_{du} + s_a \times \rho_{pc}} \quad (22)$$

Onde t_{du} é a transmitância Sol-Mar-Sensor e s_a o albedo esférico da atmosfera, ambos os parâmetros são encontrados na LUT. Já ρ_{pc} é a reflectância corrigida da trajetória atmosférico dada pela Equação 23:

$$\rho_{pc} = \frac{\rho_{TOA}}{t_{gas}} - \rho_{path} - \rho_{sky} \quad (23)$$

Onde ρ_{sky} é uma estimativa da radiação proveniente do céu na interface ar-água, que é zero para alvos na terra e estimada analiticamente para pixels de água, e t_{gas} é a transmitância do gás dada pelas equações 24 e 25:

$$t_{gas} = t_{H_2O} \times t_{O_3} \quad (24)$$

$$t_{O_3} = e^{-\tau_{oz}(\frac{1}{\cos\theta_0} + \frac{1}{\cos\theta_v})} \quad (25)$$

Onde t_{H_2O} e τ_{oz} são valores tabelados, t_{O_3} é a transmitância do ozônio, θ_0 é o ângulo zenital solar e θ_v o ângulo zenital do sensor. É importante destacar que, segundo Vanhellemont (2019), a ρ_{TOA} deve ser corrigido previamente de t_{gas} e ρ_{sky} , tanto para os modelos ACOLITE exponenciais quanto para o DSF.

O ρ_{sky} é calculado de forma análoga a ρ_r apresentado na Equação 6, porém, como é nulo, o valor que não interage com a superfície da água é considerado quando o $P_r(\theta_-) = 0$ para Equação 7 e a Equação 11 utiliza apenas o valor de $\cos\theta_{\pm}$. O ângulo de transmitância (θ_t) apresentado na Equação 10 também é alterado, sendo calculado mostrado na Equação 26:

$$\theta_t = \sin^{-1}\left(\frac{1}{n_w \times \sin\theta}\right) \quad (26)$$

Onde θ é o ângulo incidente e n_w é o índice de refração da água (1,34).

Essa correção DSF ainda deve ser melhorada com a alteração da cintilação da imagem e a incorporação da variabilidade espacial do aerossol na atmosfera.

2.1.3.1. Variabilidade espacial

A variabilidade espacial calcula uma correção atmosférica a cada km^2 indicado pelo operador, dividindo a cena em várias células iguais. Após esse processo, são excluídas aquelas células em que o τ_a é muito pequeno e aquelas em que não há informações significantes, como as bordas das imagens. Por fim, os valores do centro de cada célula são interpolados com o centro da célula adjacente, assim, a correção possui uma transição suave entre a água e a terra.

2.1.3.2.Efeito de espalhamento

A cintilação presente na cena deve ser corrigida, pois ela afeta a refletância da trajetória atmosférica (ρ_{path}). Segundo Vanhellemont (2019), a refletância da cintilação (ρ_g) pode ser estimada pelo uso de um comprimento de onda de referência (λ_{ref}), cuja refletância da água é zero. Então, ρ_g pode ser dada pela Equação 27:

$$\rho_g(\lambda_{ref}) = \rho_s(\lambda_{ref}) \quad (27)$$

A ρ_g pode ser corrigida nas outras bandas utilizando a Equação 28:

$$\rho_g(\lambda_{ref}) = \rho_s(\lambda_{ref}) \times \frac{T_{dir}(\lambda)}{T_{dir}(\lambda_{ref})} \times \frac{r(\theta, \lambda)}{r(\theta, \lambda_{ref})} \quad (28)$$

Onde:

$$T_{dir} = e^{-\frac{\tau_t(\lambda)}{\cos\theta_0}} \times e^{-\frac{\tau_t(\lambda)}{\cos\theta_v}} \quad (29)$$

$$r(\theta) = 0,5 \times \left\{ \frac{\sin^2(\theta - \theta_t)}{\sin^2(\theta + \theta_t)} + \frac{\tan^2(\theta - \theta_t)}{\tan^2(\theta + \theta_t)} \right\} \quad (30)$$

$$\cos 2\theta = \cos\theta_0 \times \cos\theta_v + \sin\theta_0 \times \sin\theta_v \times \cos |\phi_0 - \phi_v| \quad (31)$$

Onde T_{dir} é a transmitância direta da atmosfera, τ_t é a espessura óptica total da atmosfera presente na LUT, θ o ângulo incidente, θ_0 o ângulo zenital solar, θ_v o ângulo zenital do sensor, ϕ_0, ϕ_v são os ângulos azimutais do Sol e do sensor, respectivamente, e θ_t é o ângulo de transmitância dado pela Equação 26, em que n_w é o índice de refração da água na banda em questão.⁹

⁹ Retirado do Water Optical Properties Processor (WOPP) by Röttgers *et al.* (2016). Harmel *et al.* (2018).

2.2.Krigagem

A krigagem é um modelo geoestatístico usado para descrever padrões espaciais e estimar valores em locais não amostrados. A geoestatística é mais utilizada do que os demais métodos de interpolação numérica. Ela depende da existência do efeito pepita, da amplitude e da presença de anisotropia que são apresentados pelo semivariograma (YAMAMOTO; LANDIN, 2015).


A krigagem possui vários algoritmos conhecidos, como krigagem simples, média, ordinária e universal. A mais utilizada é a krigagem ordinária, devido à sua simplicidade e resultados acurados (YAMAMOTO; LANDIN, 2015). Esse método é um método local de estimativa, onde um ponto não amostrado tem como resultado um valor proveniente de uma combinação linear dos seus valores vizinhos. Ela pode ser dada pela Equação 32.

$$Z_{KO}(x_o) = \sum_{i=1}^n p_i Z(x_i) \quad (32)$$

Onde x_o é o valor de uma variável de interesse de um ponto não amostrado, $Z(x_i)$ com $i=1...n$ são os dados dos pontos vizinhos e p_i são os pesos associados a $Z(x_i)$. Há inúmeras possibilidades de pesos, no entanto, para a krigagem ordinária, é necessário que não haja viés, ou seja, a diferença entre o valor real e o calculado deve ser, em média, igual a zero. Isso implica que a soma dos pesos seja igual a 1 (YAMAMOTO; LANDIN, 2015). Os pesos são determinados a partir de uma análise espacial e seguem um semivariograma experimental.

O semivariograma é uma ferramenta de suporte que permite modelar a dependência espacial entre as amostras, porém, antes de interpolar, ajusta-se o semivariograma experimental que estima os parâmetros de efeito pepita, alcance e patamar. Esse ajuste não é algo simples, pois é bastante sensível à distribuição dos pontos e ao tipo de distribuição empregada (YAMAMOTO; LANDIN, 2015). Um exemplo de semivariograma é apresentado na Figura 3.

Figura 3 - Exemplo de modelo de semivariograma com patamar, alcance e efeito pepita



Fonte: Adaptado de Yamamoto e Landin (2015)

De acordo com Yamamoto e Landin (2015) e Bicalho (2008), alguns dos principais modelos de semivariograma são apresentados no Quadro 1.

Quadro 1 - Equações dos principais semivariogramas e suas respectivas condições

Modelo	Semivariograma	Condição	Equação
Esférico	$\begin{cases} \gamma(h) = C_o + C \left[\frac{1,5h}{a} - 0,5 \left(\frac{h}{a} \right)^3 \right] \\ \gamma(h) = C_o + C \end{cases}$	$h < a$ $h \geq a$	(33)
Exponencial	$\gamma(h) = C_o + C \left[1 - e^{-\frac{h}{a}} \right]$	$h > 0$	(34)
Gaussiano	$\gamma(h) = C_o + C \left[1 - e^{-\left(\frac{h}{a} \right)^2} \right]$	$h > 0$	(35)
Circular	$\gamma(h) = C_o + \frac{C \left[2 \left(\left(\theta \sqrt{1 - \theta^2} \right) + \sin^{-1} \sqrt{\theta} \right) \right]}{\pi}$	$\theta = \min \left(\frac{h}{a}, 1 \right)$ $h > 0$	(36)

Fonte: Adaptado de Yamamoto e Landin (2015) e Bicalho (2008)

As funções do semivariograma podem se alterar conforme a direção. Nesse caso, tem-se a chamada anisotropia. A anisotropia pode ser dividida em geométrica, zonal e mista (YAMAMOTO; LANDIN, 2015). A anisotropia geométrica possui um patamar e alcances diferentes, conforme a direção analisada. A zonal apresenta patamares diferentes e apenas um alcance. Já a mista possui tanto diferentes patamares quanto diferentes alcances.

2.3. Recuperação da batimetria

A batimetria reconstruída por meio de imagens vem se mostrando cada vez mais eficiente e, inclusive, vem sendo muito estudada, justamente por ser um método de estimativa da batimetria de forma barata e rápida (DIERSEN; THEBERGE, 2014; PACHECO *et al.*, 2015; LYZENGA 1978; DIERSEN *et al.*, 2003; STUMPF *et al.*, 2003; KABIRI, 2017; MANESSA *et al.*, 2018). Ela pode ser dividida em duas categorias, a baseada em abordagens estatísticas (LYZENGA 1978; DIERSEN *et al.*, 2003; STUMPF *et al.*, 2003) e a baseada em abordagens físicas (LEE *et al.*, 1999; LEE *et al.*, 2007; COLLINGS *et al.* 2018).

A primeira categoria utiliza profundidades conhecidas de alguns pontos para estimar a profundidade de todo o corpo d'água desejado, gerando, assim, um modelo calibrado para toda a área de estudo. Lyzenga (1978) foi um dos primeiros a utilizar esse método, tendo como premissa que existe uma relação linear entre a profundidade da água e a radiância captada pelo sensor, sendo possível realizar uma regressão linear múltipla para a calibração do modelo. As fórmulas utilizadas por ele foram as equações 37 e 38:

$$Z = a_0 + a_i x_i + a_j x_j \quad (37)$$

Onde x_i é dado por:

$$x_i = \ln(V_i - V_{si}) \quad (38)$$

Onde Z é a profundidade, V_i é o sinal da banda i , V_{si} é o sinal de águas profundas na banda i e os coeficientes a_0 , a_i e a_j são determinados por regressão linear múltipla. Originalmente, esse modelo necessita de, no mínimo, duas bandas para a determinação da profundidade, contudo, estudos recentes (KABIRI, 2017; PACHECO *et al.*, 2015) mostram

maior eficácia utilizando mais de duas bandas e utilizando a refletância de sensoriamento remoto R_{sr} (MANESSA *et al.*, 2018) ao invés da radiância.

Outro método muito utilizado é o de proporção apresentado por Stumpf *et al.* (2003). Sabendo que a profundidade é inversamente proporcional à refletância das bandas, ou seja, se a profundidade aumenta a refletância diminui, Stumpf *et al.* (2003) percebeu que ao dividir uma banda de menor comprimento de onda por uma banda com maior comprimento de onda, o valor dessa razão será diretamente proporcional ao valor da profundidade. A formulação descrita por Stumpf *et al.* (2003) é apresentada na Equação 39.

$$Z = -m_0 + m_1 \frac{\ln(n\rho_w(\lambda_i))}{\ln(n\rho_w(\lambda_j))} \quad (39)$$

Onde Z é a profundidade, ρ_w a refletância da água, n uma constante para que o logaritmo não seja negativo e m_0 e m_1 são encontrados por regressão linear múltipla. Na Equação 39, observa-se que Stumpf *et al.* (2003) utilizou apenas duas bandas espectrais, todavia, estudos recentes (KABIRI, 2017) mostram que é possível seguir esse método com mais de duas bandas, havendo uma maior chance de obtenção de resultados mais acurados.

Dierssen *et al.* (2003), em seu estudo sobre modelos de reconstrução de superfícies subaquáticas, propõe um modelo polinomial de segundo grau, utilizando as bandas do comprimento de onda do verde e vermelho, como pode ser observado pelas equações 40 e 41.

$$\log(Z) = c + bx + ax^2 \quad (40)$$

$$x = \log \frac{R_{rs}(\lambda_G)}{R_{rs}(\lambda_R)} \quad (41)$$

Onde Z é a profundidade, R_{rs} a refletância de sensoriamento remoto e a , b e c são parâmetros a serem estimados por regressão. Mishra *et al.* (2007) utilizaram o mesmo modelo com as bandas azul e verde, mostrando um resultado que explica 98% da Ilha Roatán, em Honduras, sua área de estudo, enquanto Diersen *et al.* (2003) explica 97% da Ilha Lee Stocking, nas Bahamas. Ambos mostram resultados satisfatórios.

Na literatura, vê-se comparações entre métodos já existentes e os novos métodos estatísticos que vêm sendo criados (KABIRI, 2017; TRAGANOS *et al.*, 2018). A dificuldade

dessa abordagem se deve à necessidade de obtenção de dados de batimetria para a calibração do modelo, visto que esses dados podem ser custosos e trabalhosos de obter. Com isso, vem sendo cada vez mais estudadas abordagens físicas que não precisam de dados *in situ* para a estimação da profundidade.

A abordagem baseada em modelos físicos para a recuperação da batimetria vem sendo estudada desde o final do século XX. Lee *et al.* (1999) propõe um modelo em que a R_{sr} é uma função de alguns parâmetros da coluna d'água e do fundo do corpo d'água, tais como: o coeficiente de absorção e de espalhamento; capacidade de reflexão do assoalho; profundidade do assoalho; ângulo zenital solar; e ângulo azimutal do sensor.

Apesar de a maioria dos modelos de abordagem física trabalharem com sensores hiperespectrais (LEE *et al.*, 1999; LEE *et al.*, 2007; COLLINGS *et al.* 2018), alguns modelos fazem a utilização de sensores multiespectrais, como o modelo de Kerr *et al.* (2018). Esse modelo se baseia na abordagem estatística de Stumpf *et al.* (2003), utilizando a mesma equação, porém, os parâmetros não são estimados pelos valores de profundidade coletados em campo e sim pela resposta espectral do assoalho. Sem dados coletados *in situ*, esse método se utiliza apenas dos parâmetros da imagem e de uma biblioteca que contém várias respostas espectrais do assoalho marinho.

Todos esses métodos, independentemente da abordagem em que foram empregados, apresentam um resultado eficiente, principalmente em águas marinhas e oceânicas de maior transparência e menor turbidez. Sendo estudos sobre sensores passivos em ambientes de águas interiores, faz-se necessária a compreensão das propriedades ópticas da água.

2.4. Propriedades ópticas da água

As propriedades ópticas da água podem ser divididas em dois grupos, o das propriedades ópticas inerentes (POIs) e das propriedades ópticas aparentes (POAs) (MOBLEY, 1994). Essas propriedades conseguem explicar a relação entre a coloração da água com constituintes presentes nela, bem como a reflectância da água e da resposta de absorção e o espalhamento da radiação que ela provoca.

2.4.1. Propriedades Ópticas Inerentes (POIs)

São chamadas de POI as propriedades ópticas da água que são independentes de intervenções do meio, como a geometria do campo de luz. Portanto, essas propriedades são características próprias da água e dos seus constituintes opticamente ativos (COAs) dissolvidos ou em suspensão nela. As POI também não sofrem grandes alterações com o passar do tempo, tendo uma grande aplicabilidade em estudos temporais. As principais POI são: coeficiente de absorção (a_t), coeficiente de espalhamento (b) e função de espalhamento volumétrico (β).

O $a(\lambda)$ é definido como a razão entre o fluxo de energia incidente absorvida por uma unidade de distância na coluna d'água considerada infinitesimal. Por conseguinte, a expressão matemática de $a(\lambda)$ é apresentado pela Equação 42 (MOBLEY, 1994)

$$a_t(\lambda) = \lim_{\Delta X \rightarrow 0} \frac{\frac{\Phi_a(\lambda)}{\Phi_i(\lambda)}}{\Delta X} \quad (42)$$

Onde $\Phi_i(\lambda)$ é o fluxo radiante incidente de um feixe paralelo e monocromático, $\Phi_a(\lambda)$ é o fluxo radiante absorvido e ΔX uma espessura da coluna d'água. A unidade de medida do coeficiente de absorção é m^{-1} . Não diferente ao $a(\lambda)$, o $b(\lambda)$ (Equação 43) é definido como a razão entre o fluxo de energia incidente espalhada ($\frac{\Phi_s(\lambda)}{\Phi_i(\lambda)}$) por uma unidade de distância da coluna d'água (ΔX).


$$b(\lambda) = \lim_{\Delta X \rightarrow 0} \frac{\frac{\Phi_s(\lambda)}{\Phi_i(\lambda)}}{\Delta X} \quad (43)$$

Onde $b(\lambda)$ é o coeficiente de espalhamento, $\Phi_i(\lambda)$ é o fluxo radiante incidente de um feixe paralelo e monocromático, $\Phi_s(\lambda)$ é o fluxo radiante espalhado e ΔX uma espessura da coluna d'água. Para descrever a distribuição do espalhamento de um corpo d'água, é calculada a função de $\beta(\psi, \lambda)$, dada pela Equação 44.

$$\beta(\psi, \lambda) = \lim_{\Delta X \rightarrow 0} \lim_{\Delta \Omega \rightarrow 0} \frac{\frac{\Phi_s(\psi, \lambda)}{\Phi_i(\lambda)}}{\Delta X \Delta \Omega} \quad (44)$$

Onde $\beta(\psi, \lambda)$ é a função de espalhamento volumétrico, $\Phi_i(\lambda)$ é o fluxo radiante incidente de um feixe paralelo e monocromático, $\Phi_s(\psi, \lambda)$ o fluxo radiante espalhado em uma direção ψ (Figura 4), ΔX uma espessura da coluna d'água e $\Delta \Omega$ o ângulo sólido (Figura 4).

Figura 4 - Interação entre o fluxo incidente da radiação com a água para explicar a geometria utilizada na definição dos POI - Φ_i é o fluxo radiante incidente, Φ_t é o fluxo radiante transmitido, $\Delta \Omega$ é o ângulo sólido, ΔX uma distância infinitesimal da coluna d'água, $b(\lambda)$ é o coeficiente de espalhamento e $a(\lambda)$ o coeficiente de absorção



Fonte: Adaptado de Mobley (1994)

Se o espalhamento está no mesmo sentido da propagação de $\Phi_i(\lambda)$, é chamado de espalhamento para frente (b_f) e, se está no sentido contrário de $\Phi_i(\lambda)$, é chamado de retroespalhamento (b_b).

As POI têm a necessidade de serem medidas por sensores ativos (emitem luz própria), visto que são parâmetros independentes de meio externo. Por isso, os sensores remotos orbitais não são capazes de quantificar essas propriedades. Todavia, existe outras propriedades ópticas

que os sensores passivos conseguem quantificar, são elas as propriedades ópticas aparentes (POAs).

2.4.2. Propriedades Ópticas Aparentes (POAs)

As POAs são feições instáveis que descrevem o corpo d'água, como a reflectância e o coeficiente de atenuação da irradiância difusa descendentes. Essas propriedades são consideradas aparentes por serem dependentes do meio, podendo variar conforme a geometria da luz incidente. Outra POA de grande importância para os estudos que envolvem corpos d'água é a reflectância de sensoriamento remoto (R_{sr}).


2.4.2.1. Reflectância de sensoriamento remoto (R_{sr})

A R_{sr} é uma das reflectâncias estudadas em ambientes aquáticos e existe diferentes maneiras de calcular essa reflectância. Todas partem da definição de que $R_{sr}(\text{sr}^{-1})$ é a razão entre a radiância que emerge da superfície da água pela irradiância incidente na água. Essa definição pode ser escrita pela Equação 45:

$$R_{sr}(\theta, \phi, \lambda) = \frac{L_w(\theta, \phi, \lambda)}{E_s(\lambda)} \quad (45)$$

Onde θ e ϕ são os ângulos zenital e azimutal, respectivamente (observado pela Figura 5), λ é o comprimento de onda, L_w é a radiância que deixa a água (observado pela Figura 1) e E_s é a irradiância incidente.

Figura 5 - Ângulo zenital do sensor (θ_v), ângulo zenital solar (θ_0), ângulos azimutais (ϕ) reto ao plano de incidência solar



Fonte: Adaptado de Mobley (1999)

Como as medidas tomadas fora da água sofrem influência da superfície da água, um valor real medido pelos sensores remotos é dado pela Equação 46 (MOBLEY, 1999).

$$L_t(\theta, \phi, \lambda) = L_w(\theta, \phi, \lambda) + L_r(\theta, \phi, \lambda) \quad (46)$$

L_t é a radiância total acima da água e $L_r(\theta, \phi, \lambda)$ é parte da radiância difusa do céu (L_{sky}) que é refletida pela água. Por essa equação pode-se estimar L_w como $L_w(\theta, \phi, \lambda) = L_t(\theta, \phi, \lambda) - L_r(\theta, \phi, \lambda)$, em que $L_r(\theta, \phi, \lambda)$ é dada pela Equação 47:

$$L_r(\theta, \phi, \lambda) = \rho \times L_{sky}(\theta', \phi', \lambda) \quad (47)$$

Onde ρ é o fator de proporcionalidade¹⁰ e $L_{sky}(\theta', \phi', \lambda')$ é a radiância difusa do céu medida por ângulos opostos ao $\theta e \phi$.

Ao retirar a influência da superfície da água da Equação 45, substituindo L_w , tem-se a Equação 48:

$$R_{rs} = \frac{L_t(\theta, \phi, \lambda) - \rho \times L_{sky}(\theta', \phi', \lambda)}{E_d(\theta, \phi, \lambda)} \quad (48)$$

Onde $E_s(\theta, \phi, \lambda)$ é a irradiância incidente.

Outro modo de encontrar a refletância de sensoriamento remoto é sabendo sua definição (Equação 45) e a definição da refletância da água dada pela Equação 3. Assim, substituindo a Equação 3 na 45 e manipulando a equação, tem-se a Equação 49:

$$R_{rs} = \frac{\rho_w}{\pi} \quad (49)$$

2.4.2.2. Coeficiente de atenuação difusa (K_d)

Outra POA muito utilizado é o coeficiente de atenuação difusa da irradiância descendente (K_d), empregue na determinação da correção da coluna d'água. O K_d é um parâmetro de uma função exponencial que explica a irradiância descendente. Em outras palavras, K_d é a taxa de decaimento da radiação conforme a profundidade da água aumenta. A irradiância descendente é dada pela Equação 50, encontrada em Mobley (1994).

$$E_{dz} = E_{d0(z=0^-)} e^{-K_d * z} \quad (50)$$

Onde E_{dz} é a irradiância descendente na profundidade Z , $E_{d0(z=0^-)}$ é a irradiância descendente logo abaixo da superfície e K_d é o coeficiente de atenuação difusa. A Equação 50

¹⁰ Esse fator de proporcionalidade relaciona a radiância mensurada quando o detector visa para cima e a radiância refletida do céu.

mostra que a irradiância que penetra na água decresce conforme a profundidade aumenta. O K_d é calculado pelos coeficientes de absorção e de espalhamento estimado a partir de imagens ópticas ou medidos *in situ*, como mostrado em Lee *et al.* (2013), que utiliza a Equação 51:

$$\begin{aligned} K_d(\lambda) = & (1 + 0.005 \times \theta_s) \times a(\lambda) \\ & + \left(1 - 0.265 \times \frac{b_{bw}(\lambda)}{b_b(\lambda)} \right) \times 4.259 \times (1 \\ & - 0.52 \times e^{-10.8 \times a(\lambda)} \times b_b(\lambda) \end{aligned} \quad (51)$$

Onde θ_s é o ângulo zenital solar, $a_t(\lambda)$ é o coeficiente de absorção total em um comprimento de onda λ , $b_b(\lambda)$ é o coeficiente de retroespalhamento em um comprimento de onda λ e $b_{bw}(\lambda)$ é o coeficiente de retroespalhamento da água pura em um comprimento de onda λ .

Estudos conseguem correlacionar os POA com os POI (MOREL; GENTILI, 1991; GORDON, 1991), com isso pode-se estimar os POI por sensores remotos que são capazes de calcular os POA. Assim, é possível estimar o coeficiente de absorção e de espalhamento por meio da R_{sr} , se se considerar que esses POI são dados em função das suas componentes opticamente ativas (COA). Ademais, K_d pode ser calculado pelos coeficientes de absorção e de espalhamento.


2.5.Componentes Opticamente Ativos (COA)

Componentes opticamente ativos (COA) são os componentes que interagem com a luz do Sol, absorvendo ou espalhando essa radiação. Os COA podem ser divididos em água pura, matéria orgânica dissolvida colorida (CDOM) e o material particulado (divididos em sedimentos orgânicos, minerais e fitoplâncton) (BARBOSA; NOVO; MARTINS, 2019). É importante notar que nem todo constituinte das águas naturais são opticamente ativos, o oxigênio dissolvido e a concentração de fósforo são exemplos de componentes não opticamente ativos.

2.5.1. Água pura

A água que não contém nenhum outro composto, a não ser as próprias moléculas de água, é chamada de água pura. A absorção da radiação solar pela água pura varia para cada comprimento de onda, sendo baixa nas regiões do azul e do verde, crescendo levemente na região do vermelho, subindo abruptamente no final do vermelho e começo do infravermelho-próximo (Figura 6). Isso explica o fato de corpos d'águas aparecerem escuros em bandas da região do infravermelho.

Figura 6 - Curvas espectrais do coeficiente de absorção da água pura



Fonte: Adaptado dos dados de Smith e Baker (1981), Pope e Fry (1997) e Sogandares e Fry (1997)


O espalhamento da radiação solar pela água pura possui uma resposta parecida com uma função exponencial, sendo alta nos menores comprimentos de onda e descendo exponencialmente nos comprimentos de ondas maiores (SMITH; BAKER, 1981). A cor azul em águas mais limpas ao redor do planeta é explicado por esse grande espalhamento no comprimento de onda do azul (BARBOSA; NOVO; MARTINS, 2019).

2.5.2. CDOM

A matéria orgânica dissolvida (MOD) está relacionada com a decomposição de plantas, animais e materiais presente nos efluentes (WETZEL, 2001). Os excrementos dos animais também são responsáveis pela MOD, já que expelem materiais orgânicos como carboidratos, vitaminas, lipídios e outros. Uma parte da MOD é absorvida nos comprimentos de ondas do ultravioleta e do visível. Essa parte é denominada de matéria orgânica colorida dissolvida (CDOM).

A CDOM varia de acordo com o tipo de ambiente aquático e da época do ano. Pesquisas do laboratório de Instrumentação de Sistemas Aquáticos (LabISA) e do Instituto Nacional de Pesquisas Espaciais (INPE) mostram a CDOM para diversos ambientes aquáticos do Brasil (Figura 7). Watanabe (2016) revela que o CDOM, na primavera, chega a ser 1,4 vezes maior que no outono em climas subtropicais, enquanto Silva (2018) evidencia que as épocas de vazante têm uma menor CDOM que as épocas de enchente. Apesar de os valores de CDOM sempre variarem, eles seguem uma curva exponencial, mostrando-se maiores em menores comprimentos de onda e baixíssimos em maiores comprimentos de onda.

Figura 7 - Coeficiente de absorção do CDOM



Fonte: Adaptado de Barbosa, Novo e Martins (2019)

A radiação no comprimento de onda ultravioleta é conhecida por ser prejudicial a quase todos os organismos (KUSTER *et al.*, 2005). Considerando que grande parte dela é absorvida pela CDOM, os seres vivos presentes nos ambientes aquáticos ficam protegidos dessa radiação.

Em contrapartida, a alta absorção da radiação em comprimentos de ondas curtas pode causar o déficit na energia necessária para a realização da fotossíntese por fitoplânctons. Estudos de águas por sensoriamento remoto também podem ser afetados pela concentração de CDOM, visto que ela pode alterar a coloração da água (XIE *et al.*, 2012).

2.5.3. Total de sólidos em suspensão


São chamados de sólidos em suspensão os elementos orgânicos e inorgânicos que permanecem em suspensão na água (não diluem). Geralmente, esses sólidos são maiores que 0,4 μm . O total de sólidos em suspensão (TSS) inclui tanto as partículas que contém pigmentos de clorofilas (presentes no fitoplâncton) quanto partículas não algais (NAP). Essas partículas não algais podem ser de origem orgânica ou inorgânica.

2.5.3.1. Fitoplânctons

Os fitoplânctons são microrganismos unicelulares que flutuam sobre as águas salgadas e doces. Esses organismos têm a capacidade de realizar a fotossíntese, por isso, procuram lugares de alcance da radiação solar. Morris (1974) mostra que, em águas com maior transparência, a produção fotossintética por fitoplâncton tem o seu auge em uma profundidade maior que em águas pouco transparentes. Todos os fitoplânctons são compostos de ao menos um tipo de clorofila (FONDRIEST ENVIRONMENTAL, 2014), a qual é responsável pela realização da fotossíntese.

Existem seis tipos de clorofilas conhecidas atualmente, a clorofila-*a* está presente em todos os seres que realizam a fotossíntese, sejam aquáticos ou não. A clorofila-*a* absorve a radiação proveniente do sol em todos os comprimentos de ondas do visível, porém, no comprimento de onda do verde, a radiação é pouco absorvida e grande parte é refletida, explicando, assim, a coloração esverdeada das plantas. Grande parte da radiação no comprimento de onda do azul e do vermelho é absorvida, como pode ser verificada na Figura 8. Além de clorofila, os fitoplânctons contêm outros elementos em sua estrutura que refletem outros comprimentos de onda, causando uma pigmentação diferente da verde.

Figura 8 - Coeficiente de absorção de alguns tipos de clorofila encontradas nos fitoplânctons



Fonte: Adaptado de Fondriest Environmental (2014)


Além do fitoplâncton ser responsável por grande parte da produção fotossintética do planeta, produzindo mais oxigênio que todas as plantas terrestres (FONDRIEST ENVIRONMENTAL, 2014), ele também é a base da cadeia alimentar dos sistemas aquáticos. No entanto, a alta produção desbalanceada desses microrganismos pode causar a morte desenfreada de peixes.

2.5.3.2.NAP

As partículas não algais (NAP) podem ser tanto orgânicas como inorgânicas (BARBOSA; NOVO; MARTINS, 2019). A parte orgânica é proveniente de células mortas de fitoplânctons e de produtos secundários da vegetação (frutos, folhas e sementes, por exemplo), enquanto a fração inorgânica são partículas rochosas que sofreram a ação do vento e da chuva. As NAP têm um poder de absorção maior ou menor dependendo de diferentes tamanhos, composições e formas de suas partículas (BARBOSA; NOVO; MARTINS, 2019).

A parte inorgânica da NAP tem uma maior absorção nos comprimentos de onda mais baixos (ultravioleta ao azul), decaindo exponencialmente nas regiões do verde e vermelho, como pode ser observado na Figura 9. A presença dessa fração da NAP é que causa um grande espalhamento da radiação solar.

Figura 9 - Coeficiente de absorção NAP



Fonte: Adaptado de Zhang *et al.* (2009)

Williams *et al.* (2018) mostra que a contribuição da NAP e do fitoplâncton na medida de TSS são iguais em quatro comprimentos de onda (~400 nm, ~545 nm, ~645 nm e ~700 nm), variando de forma inversamente proporcional nos outros comprimentos de onda. Ou seja, quando a contribuição do fitoplâncton é alta, a de NAP é baixa, e vice-versa.

2.6.Algoritmos bio-ópticos

Existe, na literatura, vários algoritmos bio-ópticos para extrair as informações dos COA em ambientes aquáticos (FAN, 2014; LEE, 2002, LEE, 2009; QU, 2014). Esses algoritmos podem ser classificados basicamente em empíricos, semianalíticos e analíticos. Os métodos empíricos se utilizam de modelos matemáticos e estatísticos que calibram um modelo tendo como parâmetros de entrada os dados *in situ* coletados na área de interesse juntamente com os dados dos sensores ópticos. Esse tipo de algoritmo nem sempre é possível de ser realizado, pois há lugares que não se pode coletar dados *in situ* e, além disso, os algoritmos empíricos não podem ser utilizados como um modelo global para todos os tipos de água.

Por isso, os estudos recomendam os algoritmos semianalíticos, que se utilizam de etapas empíricas e analíticas para estimação dos COA. Esses algoritmos se baseiam na equação de transferência radiativa, a qual utiliza as POI e algumas condições físicas (condições da água, radiância do céu e ângulo sólido do sensor, por exemplo) para encontrar as POA. Porém, esses

algoritmos também possuem a parte empírica, por que necessitam de dados coletados a campo para a sua calibração.

Os algoritmos analíticos também se utilizam das equações de transferência radiativa na coluna d'água e na atmosfera para calibrar os algoritmos que correlacionam dados das imagens com POI e POA coletados *in situ*. Apesar dos algoritmos analíticos conseguirem ser aplicados em diferentes tipos de ambientes aquáticos, as medidas coletadas são caras e difíceis de se obter (BERNARDO, 2015).

2.6.1. QAA

Entre os algoritmos semianalíticos, destaca-se, na literatura, o algoritmo quase-analítico (QAA) introduzido por Lee *et al.* (2002). Esse algoritmo, pela sua fácil compreensão e implementação, é muito utilizado tanto para os sensores multiespectrais, como MODIS, SeaWiFS e MERIS, quanto para sensores hiperespectrais. Lee *et al.* (2002) faz a recuperação do a_t e b a partir da R_{rs} em águas mais profundas. Tendo esses POI, é possível calcular a absorção pelo fitoplâncton e CDOM com material em suspensão.

A primeira etapa desse algoritmo expressa a reflectância de sensoriamento remoto subsuperfície (r_{rs}) em função da R_{rs} , como mostra a Equação 52.

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

A fórmula usada por Gordom *et al.* (1988) (Equação 53) explica r_{rs} em função de u .

$$r_{rs}(\lambda) = g_0 u(\lambda) + g_1 [u(\lambda)]^2 \quad (53)$$

Sendo g_0 e g_1 são valores predeterminados que, segundo Lee *et al.* (2002), correspondem aos valores de 0,089 para g_0 e de 0,125 para g_1 . E $u(\lambda)$ é apresentado pela Equação 54.

$$u = \frac{b_b}{a_t + b_b} \quad (54)$$

Onde a_t é o coeficiente de absorção total e b_b o coeficiente de retroespalhamento. Tendo r_{rs} estimado pela Equação 53, a solução para Equação 54 é apresentada na Equação 55:

$$u(\lambda) = -\frac{-g_0 + [g_0^2 + 4 \times g_1 \times r_{rs}(\lambda)]^{1/2}}{2 \times g_1} \quad (55)$$

O passo seguinte desse algoritmo apresentado em Lee *et al.* (2009) é uma condição simples, que depende do valor de R_{sr} na banda com comprimento de onda (λ) próximo de 670 nm. Portanto, se $R_{sr}(670) < 0,0015 \text{ sr}^{-1}$, então as equações 56, 57 e 58 serão calculadas. Caso contrário, serão utilizadas as equações 59 e 58.

$$X = \log \left(\frac{r_{rs}(443) + r_{rs}(490)}{r_{rs}(\lambda_0) + 5 \times \frac{r_{rs}(667)}{r_{rs}(490)} \times r_{rs}(667)} \right) \quad (56)$$

$$a_t(\lambda_0) = a_w(\lambda_0) + 10^{h_0 + h_1 X + h_2 X^2} \quad (57)$$

$$b_{bp}(\lambda_0) = \frac{u(\lambda_0) \times a_t(\lambda_0)}{1 - u(\lambda_0)} - b_{bw}(\lambda_0) \quad (58)$$

Onde λ_0 é o comprimento de onda de referência (podem ser utilizados os comprimentos de onda de 550nm, 555nm ou 560nm dos sensores MODIS, MERIS SeaWiFS), a_w é o coeficiente de absorção da água pura encontrado em Pope e Fry (1997), b_{bp} o coeficiente de retroespalhamento de partículas suspensas, b_{bw} o coeficiente de espalhamento da água pura encontrada em Smith e Barker (1981) e h_0 , h_1 , h_2 foram valores encontrado por Lee *et al* (2009) que correspondem a -1,146, -1,366 e -0,469, respectivamente. Para os casos em que $R_{sr}(670) > 0,0015 \text{ sr}^{-1}$, utiliza-se as equações 58 e 59:

$$a_t(\lambda_0) = a_w(\lambda_0) + 0.39 \times \left(\frac{R_{sr}(667)}{R_{sr}(443) + R_{sr}(490)} \right)^{1,14} \quad (59)$$

As equações 59 e 58 utilizam λ_0 igual a 670 para o caso de $R_{sr}(670) \geq 0,0015 \text{ sr}^{-1}$.

Calculando b_{bp} para a banda de referência, é possível calcular o b_{bp} para qualquer banda, como mostra a Equação 60:

$$b_{bp}(\lambda) = b_{bp}(\lambda_0) \times \left(\frac{\lambda_0}{\lambda} \right)^\eta \quad (60)$$

Onde η é dado pela Equação 61:

$$\eta = 2 * \left(1 - 1,2 \times e^{-0,9 \times \frac{r_{rs}(443)}{r_{rs}(\lambda_0)}} \right) \quad (61)$$

Isolando a na Equação 54 e conhecendo a Equação 62, tem-se o a_t para qualquer banda, dada pela Equação 63 e b_b pela Equação 62:

$$b_b = b_{bw}(\lambda) + b_{bp}(\lambda) \quad (62)$$

$$a_t(\lambda) = \frac{(1 - u(\lambda)) \times (b_{bw}(\lambda) + b_{bp}(\lambda))}{u(\lambda)} \quad (63)$$

Encontrado os POI, o algoritmo caminha para a próxima etapa, que tem como objetivo estimar o coeficiente de absorção por fitoplâncton e a CDOM com NAP. Para isso, calcula-se os dois parâmetros apresentados pela Equação 64 e 65:

$$\zeta = \frac{a_{ph}(411)}{a_{ph}(443)} = 0,74 + \frac{0,2}{0,8 + \frac{r_{rs}(443)}{r_{rs}(\lambda_0)}} \quad (64)$$

$$\xi = \frac{a_{CDOM+NAP}(411)}{a_{CDOM+NAP}(443)} = e^{S(442,5-415,5)} \quad (65)$$

O ζ é um parâmetro que está relacionado à absorção pelo fitoplâncton, ξ está associado à matéria orgânica absorvida, a_{ph} é o coeficiente de absorção de fitoplâncton e $a_{CDOM+NAP}$ é o coeficiente de absorção por CDOM com NAP. Já S é dada pela Equação 66:

$$S = 0,015 + \frac{0,002}{0,6 + \frac{r_{rs}(443)}{r_{rs}(550)}} \quad (66)$$

Para o cálculo do coeficiente de absorção por CDOM e NAP, as equações 67 e 68 são utilizadas:

$$a_{CDOM+NAP}(443) = \frac{a(412) - \zeta \times a(443) - a_w(412) - \zeta \times a_w(443)}{\xi - \zeta} \quad (67)$$

$$a_{CDOM+NAP}(\lambda) = a_{CDOM+NAP}(443) \times e^{-S(\lambda-443)} \quad (68)$$

Por fim, o coeficiente de absorção por fitoplâncton $a_{ph}(\lambda)$ é dado pela Equação 69:

$$a_{ph}(\lambda) = a(\lambda) - a_{dg}(\lambda) - a_w(443) \quad (69)$$

O QAA, por se tratar de um algoritmo semianalítico, necessita de dados *in situ* para realizar a validação do modelo. Se o resultado da validação for apropriado, é possível realizar estudos temporais sobre a área sem a necessidade de novas coletas a campo. Esse algoritmo foi implementado para águas oceânicas e costeiras, mas já há estudos que utilizam o QAA para águas interiores (MOUW *et al.*, 2013, WATANABE, 2016, BERNARDO *et al.*, 2019).

As equações mostradas nesta Seção são as apresentadas pela QAA_V5 de Lee *et al.* (2009). Contudo, há muitos QAA parametrizados para tipos de água diferentes e sensores orbitais (WATANABE, 2016, BERNARDO *et al.*, 2019).


3. MATERIAIS E MÉTODOS

Esta seção apresenta a área de estudo (Seção 3.1), os dados utilizados no trabalho (Seção 3.2) e o método (Seção 3.3) que foi empregado no projeto.

3.1. Área de estudo

A área de estudo está localizada em uma extensão de aproximadamente 126 km ao longo do reservatório da usina hidrelétrica de Tucuruí (Figura 10), na Região Nordeste do estado do Pará, Brasil. Esse reservatório tem como origem o rio Tocantins, que nasce no estado de Goiás, corta o estado de Tocantins, passa por uma parte do estado do Maranhão e, por fim, no Pará, onde deságua no oceano Atlântico. Uma grande parte de floresta tropical nativa foi inundada com a construção desse reservatório. Atualmente, a área alagada abrange 2.290 km² em épocas de seca, podendo chegar a 2.850 km² em épocas de cheia. Foi inaugurada em 1984 e, desde então, estuda-se os impactos ambientais e sociais causados (FEARNSIDE, 1999). Localizada à 3°49'56'' S e 49° 38' 59'' O, a barragem possui um comprimento de 11 km e consegue produzir de energia um total de 8.370 MWh.

Figura 10 - Área de estudo em Tucuruí (PA): (A) Área de estudo no reservatório da Usina Hidrelétrica de Tucuruí e (B) dados de batimetria.



Fonte: Autor (2019)

3.2.Dados

As imagens utilizadas são do sensor OLI (*Operational Land Imager*) embarcado no satélite Landsat-8, que está em órbita desde 2013. Esse sensor possui nove bandas espectrais, em que oito tem resolução espacial de 30 m e a banda pancromática (banda 8) tem a resolução espacial de 15 m. A resolução radiometria é de 12 bits para todas as bandas. Esse satélite também possui o sensor *Thermal Infrared Sensor* (TIRS), porém, este trabalho utilizará apenas as seguintes bandas: Banda 1 – azul costal (0,433 μm – 0,453 μm); Banda 2 – azul (0,450 μm – 0,515 μm); Banda 3 - verde (0,525 μm – 0,600 μm); Banda 4 - vermelha (0,630 μm – 0,680 μm). As bandas 5 (0,845 μm - 0,885 μm), 6 (1,560 μm – 1,660 μm) e 7 (2,100 μm – 2,300 μm), representando as bandas do infravermelho próximo (NIR) e do infravermelho de ondas curtas (SWIR 1 e SWIR 2), serão utilizadas apenas para a correção atmosférica. Uma cena dessa imagem contém, aproximadamente, 170 km de largura e 183 km de comprimento e estão disponíveis no site da *United States Geological Survey* (USGS).¹¹ A imagem que será utilizada foi registrada no dia 18 de julho de 2013.

Para a recuperação da batimetria por imagem óptica são necessários dados de batimetria, que serão utilizados como profundidade de controle. Para este trabalho, foi utilizado dados de um ecobatímetro de pulso único, levantados na área de estudo entre os dias 5 a 15 de julho de 2013. As medidas *in situ* para a produção deste trabalho foram disponibilizadas por Curtarelli *et al.* (2015).


3.3.Métodos

Considerando os objetivos deste trabalho, os experimentos foram realizados em seis etapas. A primeira etapa consistiu em reduzir os efeitos atmosféricos com a correção atmosférica ACOLITE e avaliar o seu resultado. Na segunda etapa, foi feita a implementação e aplicação do QAA na área de estudo. A terceira etapa estimou o coeficiente de atenuação difusa. Na quarta etapa, foi feita a interpolação dos dados batimétricos para todo o reservatório, que foi usado como parâmetro de entrada para a etapa seguinte, na qual se avaliou o melhor método para reconstrução da profundidade do reservatório a partir de modelos estatísticos. Por fim, a última etapa consistiu em correlacionar o erro ao estimar a batimetria com a capacidade

¹¹ Disponível em: <https://earthexplorer.usgs.gov/>.

de absorção ou espalhamento de cada pixel. A metodologia empregada pode ser observada na Figura 11.

Figura 11 - Fluxograma da metodologia empregada



Fonte: Autor (2021)

Ao observar o fluxograma (Figura 11), pode-se observar que as imagens OLI corrigidas geram duas linhas de pesquisas diferentes: (a) a parte que estuda os componentes opticamente ativos derivados de algoritmos bio-ópticos e (b) a batimetria óptica, que se utiliza dos dados do ecobatímetro e das imagens OLI corrigidas dos efeitos atmosféricos.

Para a estimativa bio-óptica, foi preciso implementar o QAA que estima a_t e b_b , a partir dos quais foi estimado o K_d . Foi também estudado a batimetria óptica, que consegue estimar a profundidade em cada pixel por modelos estatísticos. Os modelos a serem comparados são o de Lyzenga (1978), o de Stumpf *et al.* (2003) e o de Diersen *et al.* (2003). Com isso, será analisado o melhor modelo de batimetria óptica. Para os dados de entrada dessa etapa, foi necessário realizar uma interpolação para toda área. Neste estudo, foram realizados testes com quatro

modelos matemáticos de krigagem ordinária mais comuns: esférica, exponencial, gaussiana e circular. Por fim, foi possível relacionar o erro da batimetria estimada pela imagem com os dados de a_t , b_b e K_d . Logo, será possível relacionar o erro da batimetria estimada pela imagem com os dados de coeficiente de absorção, de espalhamento e atenuação difusa.

3.3.1. Correção atmosférica


Neste trabalho, foi aplicada a correção do ACOLITE na imagem, que é uma das mais utilizadas em ambientes aquáticos, apresentando bom desempenho em alvos terrestres e aquáticos. Para essa correção, foi utilizado o aplicativo (v20190326.0), disponibilizado pelo *Royal Belgian Institute of Natural Sciences* (RBINS), comparando as três correções do ACOLITE existentes, como explicada na Seção 2.1.

Com o uso das imagens do sensor OLI adquiridas no dia 18 de julho de 2013 (três dias após o levantamento batimétrico ser concretizado), três métodos da correção atmosférica do ACOLITE foram realizados. Um dos métodos utiliza as bandas do vermelho e do infravermelho próximo (RED-NIR), assumindo que a taxa da reflectância da água entre essas duas bandas é uma constante. O outro método emprega ambas as bandas do infravermelho de ondas curtas presentes no sensor OLI (SWIR1-SWIR2), de modo que a reflectância na água nessas bandas são consideradas iguais e nulas. O mais novo método do ACOLITE, o DSF, pressupõe que uma das bandas do sensor tenha reflectância de superfície nula e que a atmosfera é homogênea. Utilizando o aplicativo `acolite_py_win_20190326.0` é possível manipular os parâmetros de entrada e gerar a reflectância de superfície das imagens. Tendo como objetivo encontrar a reflectância de superfície em ambientes aquáticos, é possível, com os algoritmos do ACOLITE e a Equação 49, estimar a (R_{sr}). Esta reflectância será utilizada como o parâmetro de entrada para o QAA e para a realização da batimetria óptica.

Para validação da correção atmosférica do ACOLITE, utiliza-se como referência os dados de correção atmosférica disponibilizados pela *National Aeronautics and Space Administration* (NASA). Trata-se de um resultado de correção atmosférica muito conveniente para vários tipos de aplicações, que é chamado de *Land Surface Reflectance Code* (LaSRC) (VERMOTE *et al.*, 2018; BERNARDO *et al.*, 2017, VANHELLEMONT; RUDDICK, 2015), disponibilizado pela USGS. O LaSRC é um modelo estável, que utiliza um modelo de transferência radiativa para estimar a reflectância de superfície das imagens de um sensor, utilizando as bandas do azul e do vermelho para atenuar os efeitos dos aerossóis presentes na atmosfera (VERMOTE *et al.*, 2018). Esse método é muito utilizado em diversos sensores, como os embarcados no Landsat

e no MODIS. O modelo LaSRC vem sendo aplicado nas imagens do Landsat-8 sob a demanda do usuário, onde cada pixel da imagem apresenta a reflectância de superfície re-escalada por um fator de 10.000. Sendo LaSRC considerado um método confiável, podemos compará-lo com os resultados do ACOLITE, para, assim, escolher o melhor modelo dentre os revisados. Para a análise da R_{sr} , é necessário aplicar a Equação 49 em todos os pixels da imagem. Para a validação da correção atmosféricas, também foram utilizados nove pontos, distribuídos aleatoriamente pelo reservatório, como mostra a Figura 12.

Figura 12 - Pontos de análise



Fonte: Autor (2021)

3.3.2. Estimação de a_t e b_b

Para a estimação de a_t e b_b por imagem orbitais, foi utilizado o QAA (Seção 2.5.1.) aplicado para as imagens do Landsat-8. Como no QAA original os comprimentos de onda não são iguais aos do OLI, alguns ajustes foram realizados. Para todo o reservatório da usina hidrelétrica de Tucuruí, foi estimado a_t e b_b , usando o QAA adaptado para o sensor multiespectral, como o OLI. Os passos do algoritmo apresentados no Quadro 2 são baseados no utilizado por Bernardo *et. al* (2019), que empregou imagens multiespectrais em águas com propriedades ópticas complexas (alta turbidez, alta concentração de clorofila, alta CDOM e TSS), mostrando em sua área de estudo um QAA 30% melhor ao estimar os POI em comparação com alguns QAA existentes.

O comprimento de onda de referência (λ_0) foi escolhido de forma que o coeficiente de absorção da água pura tenha maior resposta do que os outros coeficientes de absorção. É levado em consideração a afirmativa de Lee *et al.* (2002), que sugere uma melhor estimativa de a_t e b_b , para águas túrbidas se utilizando de bandas com maiores comprimentos de onda para o valor de λ_0 . Portanto, assim como em Bernardo *et. al.* (2019), a banda do vermelho ($\lambda_0 = 655nm$) foi utilizada como referência.

Quadro 2 - Algoritmo do QAA para bandas do sensor OLI

Etapa	Equação
0	$r_{rs}(\lambda) = \frac{R_{sr}(\lambda)}{0,52 + 1,7 * R_{sr}(\lambda)}$
1	$u(\lambda) = -\frac{-g_0 + [g_0^2 + 4 * g_1 * r_{rs}(\lambda)]^{\frac{1}{2}}}{2 * g_1}, g_0 = 0,0895 e g_1 = 0.125$
2	$X = \log \left(\frac{r_{rs}(443) + r_{rs}(562)}{r_{rs}(\lambda_0) + 2 * \frac{r_{rs}(562)}{r_{rs}(482)} * r_{rs}(562)} \right)$
3	$a_t(\lambda_0) = a_w(\lambda_0) + 10^{-1.146 - 1.366 * X - 0.469 * X^2}$

4	$b_{bp}(\lambda_0) = \frac{u(\lambda_0) * a_t(\lambda_0)}{1 - u(\lambda_0)} - b_{bw}(\lambda_0)$
6	$\eta = 2 * \left(1 - 1,2 * e^{-0,9 * \frac{r_{rs}(562)}{r_{rs}(\lambda_0)}} \right)$ $b_{bp}(\lambda) = b_{bp}(\lambda_0) * \left(\frac{\lambda_0}{\lambda} \right)^\eta$
7	$a_t(\lambda) = \frac{(1 - u(\lambda)) * (b_{bw}(\lambda) + b_{bp}(\lambda))}{u(\lambda)}$
8	$b_{bp}(\lambda) = b_{bp}(\lambda_0) * \left(\frac{\lambda_0}{\lambda} \right)^\eta$

Fonte: adaptado de Bernardo *et al.*, (2019)

3.3.3. Coeficiente de atenuação difusa

Ao estimar a_t e b_b pelo algoritmo QAA, é possível estimar o K_d pela Equação 70, como mostrado em Lee *et al.* (2013).

$$K_d = (1 + m_0 * \theta_s) * a_t + \left(1 - \gamma * \frac{b_{bw}}{b_b} \right) * m_1 * (1 - m_2 * e^{-m_3 * a}) * b_b \quad (70)$$

Onde θ_s é o ângulo zenital solar, a é o coeficiente de absorção total, b_{bw} e b_b os coeficientes de retroespalhamento da água pura e total, respectivamente. Os coeficientes m_0, m_1, m_2, m_3 e γ são parâmetros constantes invariantes ao comprimento de onda e às propriedades da água. Esses parâmetros encontrados em Lee *et al.* (2013) são 0,005, 4,259, 0,52, 10,80 e 0,265, respectivamente.

A Equação 70 apresentou bons resultados em estudos com ambientes aquáticos dominado por CDOM e Clorofila-a, utilizando como λ o valor de 482 nm para banda do OLI, que é o mais próximo de 490 nm (GOMES *et al.*, 2018). Utilizou-se o $K_d(490)$, pois é um estimador de qualidade da água, podendo indicar a sua turbidez, além de estar relacionada com as partículas em suspensão, o que ajuda a entender as características da área de estudo.

3.3.4. Interpolação de dados do sonar

Para realizar a batimetria por modelos estatísticos, primeiramente, foi necessário obter valores interpolados da batimetria feita por sonar. Para realizar essa interpolação, comparou-se quatro modelos matemáticos de krigagem ordinária: o esférico, exponencial, gaussiano e circular. Para avaliação dos resultados, foi calculado o RMSE de cada modelo e foi feita, também, uma validação cruzada entre os pontos coletados pelo sonar e os pontos calculados pela interpolação. Após essa etapa, é possível encontrar um modelo matemático que melhor estima a batimetria, tendo como dado de entrada a R_{sr} .

3.3.5. Modelos batimétricos

Os modelos batimétricos calculados neste trabalho são os estatísticos, visto que foram coletados os dados *in situ*. Os modelos batimétricos estatísticos realizados são os apresentados por Lyzenga (1978), Stumpf *et al.* (2003) e Dirsén *et al.* (2003). O método de Lyzenga (1978) consiste em realizar regressões lineares múltiplas, correlacionando os dados do Sonar com as imagens de sensoriamento remoto. Os modelos utilizados são mostrados pelas equações 71 e 72. Os prefixos correspondem às bandas do azul costal (CB), azul (B), verde (G) e vermelho (R).

$$Z = a_0 + a_{CB}(X_{CB}) + a_B(X_B) + a_G(X_G) + a_R(X_R) \quad (71)$$

Onde:

$$X_i = \ln (R_{sr}(\lambda_i) - R_{\infty}(\lambda_i)) \quad (72)$$

O R_{sr} é a refletância de sensoriamento remoto de um determinado ponto, que varia para cada banda espectral (λ_i). R_{∞} é a menor refletância da água na sua área de estudo e a_0, a_{CB}, a_B, a_G e a_R são constantes encontradas por regressão linear múltipla apresentadas pelas equações 73 a 77.

$$L = A * X \quad (73)$$

$$L = \begin{bmatrix} Z_1 \\ \vdots \\ Z_n \end{bmatrix} \quad (74)$$

$$A = \begin{bmatrix} 1 & x_i^1 & x_j^1 \\ \vdots & \vdots & \vdots \\ 1 & x_i^n & x_j^n \end{bmatrix} \quad (75)$$

$$X = \begin{bmatrix} a_0 \\ a_i \\ a_j \end{bmatrix} \quad (76)$$

$$X = (A^T A)^{-1} A^T L \quad (77)$$

Utilizando novamente as regressões lineares múltiplas, correlacionando os dados do ecobatímetro com as imagens de satélite, será realizado o modelo utilizado baseado no modelo de Stumpf *et al.* (2003), como mostra a Equação 78:

$$\begin{aligned} Z = -m_0 + m_1 \frac{\ln(nR_{sr}(\lambda_{CB}))}{\ln(nR_{sr}(\lambda_B))} + m_2 \frac{\ln(nR_{sr}(\lambda_{CB}))}{\ln(nR_{sr}(\lambda_G))} + m_3 \frac{\ln(nR_{sr}(\lambda_{CB}))}{\ln(nR_{sr}(\lambda_R))} \\ + m_4 \frac{\ln(nR_{sr}(\lambda_B))}{\ln(nR_{sr}(\lambda_G))} + m_5 \frac{\ln(nR_{sr}(\lambda_B))}{\ln(nR_{sr}(\lambda_R))} \end{aligned} \quad (78)$$

Onde Z é a profundidade e $m_0, m_1, m_2, m_3, m_4, m_5$ são encontrados por regressão linear. O valor de n é uma constante que garante que o resultado da função logarítmica seja sempre positivo. R_{sr} é a refletância de sensoriamento de um determinado ponto.

Outro método que foi utilizado segue um modelo polinomial de segundo grau apresentado por Dirsén *et al.* (2003), como mostram as equações 79 e 80:

$$\log(Z) = c + bx + ax^2 \quad (79)$$

$$x = \log \frac{R_{sr}(\lambda_B)}{R_{sr}(\lambda_R)} \quad (80)$$

Onde Z é a profundidade, os parâmetros a , b e c são estimados por regressão. Nesse caso, os parâmetros a , b e c são encontrados por regressão linear múltipla polinomial, similarmente às equações 73 a 76, porém, agora, A e X são dados pelas equações 81 e 82:

$$A = \begin{bmatrix} 1 & x & x^2 \\ \vdots & \vdots & \vdots \\ 1 & x & x^2 \end{bmatrix} \quad (81)$$

$$X = \begin{bmatrix} c \\ b \\ a \end{bmatrix} \quad (82)$$

Tendo os parâmetros estimados (Equação 82), é possível determinar a Equação 77, a fim de estimar a profundidade da água. Como se trata de regressão linear, um método para a seleção do melhor modelo aplicado é o Critério de Informação de *Akaike*, do inglês *Aikaike Information Criteria* (AIC), e o critério de informação Bayseano, ou *Bayesian Information Criterion* (BIC), que são calculados pela Equação 83 e 84, respectivamente.


$$AIC = -2 \log(L_p) + 2p \quad (83)$$

$$BIC = -2 \log(L_p) + p * \log(n) \quad (84)$$

Onde L_p é a função de máxima verossimilhança do modelo, p é o número de parâmetros e n o número de observações. O menor valor de AIC e BIC define o melhor modelo. Sendo assim, o AIC aumenta conforme o número de parâmetros aumenta (p), penalizando modelos complexos, e diminui conforme o modelo melhor explica os dados, beneficiando os modelos bem explicados. Já o BIC aumenta conforme o número de parâmetros (p) e de observações (n), gerando penalizações quando se tem muitos dados observados e, assim como AIC, diminuindo conforme o modelo melhor explica os dados.

Um dos maiores problemas da batimetria óptica é em águas profundas e túrbidas, onde a penetração da luz é menor e, conseqüentemente, a estimativa por sensores ópticos se torna inviável. Estudos mostram que a estimativa por batimetria óptica consegue chegar até próximo de 30 m. Por isso, ao aplicar os modelos empíricos neste trabalho, foi selecionado uma área mais rasa, ao Sul do reservatório, como mostra a Figura 13.

Figura 13 - Área que será realizada a batimetria óptica por modelos estatísticos



Fonte: Autor (2021)

Vale, também, verificar se alguma observação é influente no modelo. Para esse cálculo, utiliza-se os parâmetros de DFFITS e a distância de Cook, que identificam os *outliers* influentes no modelo seguindo o critério das Equações 85 e 86:

$$DFFITS = \sqrt{\frac{\bar{p}}{n}} \quad (85)$$

$$Cook's distance = F(p, n - p) > 50\% \quad (86)$$


O DFFITS mede a influência que cada observação tem sobre o seu próprio valor ajustado e a distância de Cook mede a influência que cada observação tem sobre todas as observações ajustadas.

4. RESULTADOS

4.1. Correção atmosférica


Na primeira etapa deste trabalho, os métodos de correção atmosférica do ACOLITE foram comparados com o LaSRC, que é um método confiável como já mencionado. Para a análise, foram selecionados, aleatoriamente, nove pontos no reservatório, de modo a comparar os valores de R_{sr} calculados pelos modelos do ACOLITE com o LaSRC. As Figuras 14, 15 e 16 apresentam os resultados.

Figura 14 - Comparação entre a reflectância de sensoriamento remoto da LaSRC com a ACOLITE RED-NIR




Fonte: Autor (2021)

Figura 15 - Comparação entre a reflectância de sensoriamento remoto da LaSRC com a ACOLITE SWIR1-SWIR2



Fonte: Autor (2021)

Figura 16 - Comparação entre a reflectância de sensoriamento remoto da LaSRC com a ACOLITE DSF



Fonte: Autor (2021)

Assim como em Bernardo *et al.* (2017), a correção RED-NIR para a banda NIR resultou em refletâncias negativas, por conta de uma sobrecorreção atmosférica (Figura 14). Essa sobrecorreção é provavelmente gerada pela alta turbidez do reservatório. Isso acontece porque o ACOLITE RED-NIR leva em consideração que a banda NIR tem refletância nula, o que não se verifica nos casos de águas mais túrbidas, em que a resposta espectral pode chegar até 900 nm (LILLESAND; KIEFER; CHIPMAN, 2015). Além disso, é possível visualizar que, na correção RED-NIR, as R_{sr} estimadas têm valores mais altos do que o correto (em média: 0,0077 sr⁻¹; 0,0082 sr⁻¹; 0,0098 sr⁻¹; 0,0064 sr⁻¹; e -0,0007 sr⁻¹ para as bandas do azul costal, azul, verde, vermelho e infravermelho próximo, respectivamente), enquanto que na correção SWIR1-SWIR2 (em média: 0,0056sr⁻¹; 0,00062 sr⁻¹; 0,0081 sr⁻¹; 0,0049 sr⁻¹; e 0,0021 sr⁻¹ para as bandas do azul costal, azul, verde, vermelho e infravermelho próximo, respectivamente) e DSF (em média: -0,0055sr⁻¹; 0,0060 sr⁻¹; 0,0077 sr⁻¹; 0,0045 sr⁻¹; e 0,0017 sr⁻¹ para as bandas do azul costal, azul, verde, vermelho e infravermelho próximo, respectivamente), os valores de R_{sr} apresentam mais próximas da LaSRC.

Foi realizada, também, uma comparação entre as correções ACOLITE e a LaSRC por meio de uma relação linear. A Tabela 2 mostra, para cada banda, as relações entre cada modelo do ACOLITE com o LaSRC.

Tabela 2 - Relação entre a correção ACOLITE e o produto LaSRC

Correção	Banda	p-valor	a	b	RMSE	Viés	R²
	B1	<0,01	0,9320	0,0025	0,002213	0,002202	0,983
	B2	<0,01	0,9426	0,0023	0,002040	0,002032	0,990
RED-NIR	B3	<0,01	0,9725	0,0018	0,001616	0,001612	0,999
	B4	<0,01	0,9629	0,0016	0,001461	0,001457	0,998
	B5	<0,01	0,9731	-0,0030	0,003161	-0,003160	0,999
	B1	<0,01	0,9320	0,0005	0,000249	0,000118	0,983
	B2	<0,01	0,9426	0,0004	0,000193	0,000085	0,990
SWIR1-SWIR2	B3	<0,01	0,9725	0,00008	0,000176	-0,000135	0,999
	B4	<0,01	0,9629	0,0002	0,000112	0,000416	0,998
	B5	<0,01	0,9731	-0,0003	0,000413	-0,000407	0,999
	B1	<0,01	0,7401	0,0015	0,000561	0,000008	0,899
	B2	<0,01	0,7270	0,0014	0,000649	-0,000201	0,876
DSF	B3	<0,01	0,8573	0,0005	0,000901	-0,000576	0,929
	B4	<0,01	0,7165	0,0009	0,000913	-0,000489	0,83
	B5	<0,01	0,6191	0,0004	0,001150	-0,000806	0,747

Para as correções ACOLITE e LaSRC serem perfeitamente iguais, os parâmetros “a” e “b” (Tabela 2) deveriam ser 1 e 0, respectivamente. Assim sendo, pode-se observar que as equações da correção SWIR1-SWIR2 são mais próximas da reta ideal do que a RED-NIR e DSF, pois “a” é mais próximo de 1 e “b” mais próximo de 0. Isso também é comprovado pelo coeficiente de determinação (R^2), que tende a ser próximo de 1. Ademais, todos os RMSE da SWIR1-SWIR2 são menores que o do DSF e que o RED-NIR. O viés também é maior para a correção RED-NIR e DSF, exceto na banda do azul costal do DSF. Portanto, levando-se em consideração que a melhor correção atmosférica é a que mais se aproxima do LaSRC


(VERMOT *et al.*,2018; BERNARDO *et al.*, 2017), a correção SWIR1-SWIR2 é a mais apropriada, entre as correções ACOLITE, para a região de estudo.

4.2.Estimação dos POI

Os sensores passivos (que não emitem luz própria) não são capazes de medir os POI, porém, é possível estimá-los por meio de algoritmos bio-ópticos. Um desses algoritmos é o QAA, que converte a R_{sr} em reflectância de sensoriamento remoto de subsuperfície (r_{rs}), que, por sua vez, estima a_t e b_b baseado na relação analítica proposta por Gordon *et al.* (1988).


Considerou-se os mesmos nove pontos utilizados na validação da correção atmosférica (Figura 12). Os valores de a_t e b_b foram extraídos e apresentados nas Figura 17 e 18, respectivamente. E a Figura 19 apresenta a R_{sr} em cada banda espectral.

Figura 17 - Coeficiente de absorção total (a_t) estimado pelo QAA




Fonte: Autor (2021)

Figura 18 - Coeficiente de retroespalhamento (b_b) estimado pelo QAA



Fonte: Autor (2021)


Figura 19 - Reflectância de sensoriamento (R_{sr}) remoto para cada ponto



Fonte: Autor (2021)

As Figuras 20-I apresentam os resultados ao estimar a_t e as Figuras 20-II estimam b_b para cada banda do sensor OLI.

Figura 20 - Resultados do QAA da absorção total (I) e do retroespalhamento (II) aplicada as bandas: (a) Azul costal; (b) Azul; (c) Verde e (d) Vermelha



Fonte: Autor (2021)

A Figura 19 mostra que a R_{rs} para a banda do verde (560 nm) é maior que a do azul (480 nm) devido à alta absorção nos comprimentos de onda do azul, que chega a ser três vezes maior que a absorção no verde, verificado pela Figura 20-I-b, que apresenta maiores valores (intervalo de $0,18 \text{ m}^{-1}$ a $3,85 \text{ m}^{-1}$) relativamente à Figura 20-I-c, que apresenta menores valores (intervalo de $0,17 \text{ m}^{-1}$ a $1,30 \text{ m}^{-1}$). A alta absorção na banda do vermelho pode indicar a presença de fitoplâncton no ponto indicado.


Na Figura 20-II, observa-se que o retroespalhamento é maior para bandas com comprimentos de onda menores. Esse fato pode ter relação com a presença de sedimentos em suspensão. A água pura também possui o mesmo comportamento, contudo, em magnitude maior.

Nas figuras 18 e 20-II, pode-se observar que o b_b contém uma baixa variabilidade e valores similares para cada banda, enquanto que nas figuras 17 e 20-I mostram uma maior variabilidade dos dados de a_t , principalmente na banda do azul costal.

4.3. Coeficiente de atenuação difusa da luz

O coeficiente de atenuação difusa da luz (K_d) no comprimento de onda de 490 ($K_d(490)$) é muito utilizado para descrever a presença de luz na coluna d'água. Ele mostra a taxa de decaimento da luz com o aumento da profundidade. Neste trabalho, o $K_d(490)$ é determinado pelas POI e pela radiação incidente na água. Como o sensor OLI não possui uma banda específica para o comprimento de onda de 490 nm, $K_d(490)$ foi calculado utilizando-se da banda do azul (482 nm). O resultado é apresentado pela Figura 21.

Figura 21 - $K_d(482)$ estimado



Fonte: Autor (2021)

Na Figura 21, pode-se observar que $K_d(490)$ segue o mesmo padrão que a absorção da banda 2 (Figura 20-I-b), possuindo valores maiores na Região Sul e Oeste. Isso acontece porque

a_t e b_b da banda do azul são utilizados como apresentado pela Equação 70, em que b_b tem grande influência sobre K_d (482). A Tabela 3 apresenta os valores de K_d (490), os coeficientes a_t e b_b estimados e a profundidade para os nove pontos considerados neste estudo.

Tabela 3 - K_d (490), a_t e b_b estimados e profundidade coletada para os nove pontos

Ponto	K_d (490) (m^{-1})	a_t (482) (m^{-1})	b_b (482) (m^{-1})	Profundidade (m)
P01	4,992	0,635	0,089	36,277
P02	5,099	0,723	0,095	24,878
P03	4,977	0,628	0,080	43,680
P04	4,928	0,587	0,067	53,685
P05	4,865	0,538	0,058	50,444
P06	5,016	0,658	0,076	36,718
P07	5,085	0,712	0,091	33,571
P08	5,097	0,723	0,088	28,717
P09	5,080	0,705	0,116	18,448

Observando a Tabela 3, verifica-se que o K_d (490) com maiores valores estão localizados em lugares mais rasos do que os pontos cujo K_d (490) é menor. Verifica-se, ainda, que K_d (490) é diretamente proporcional a a_t (482) e b_b (482), o que também pode ser concluído pela Equação 70.

4.4. Interpolação dos dados de batimetria

A interpolação dos dados foi realizada com a krigagem ordinária, pois apresenta melhor resultado na batimetria (CURTARELLI *et al.*, 2015; FERREIRA *et al.*, 2017). Neste trabalho, foram testados quatro tipos de krigagem ordinária: gaussiana, exponencial, esférica e circular. Os parâmetros do semivariograma para cada tipo são apresentados na Tabela 4. Quando o semivariograma possui diferentes comportamentos para diferentes direções, então há um caso de anisotropia.


Tabela 4 - Parâmetros do semivariograma utilizado na interpolação da batimetria

Modelo	Direção da anisotropia	Efeito pepita (Nugget)	Patamar (Sill)	Alcance (Range)
Gaussiana	88,41	77	118	2750
Exponencial	77,69	51	257	9690
Esférica	82,26	55	200	4700
Circular	81,74	57	203	4200

Por meio do software ArcMap, foram testados os quatro tipos de krigagem ordinária com os dados de batimetria coletados em campo com um sonar entre os dias 5 a 15 de julho de 2013. Segundo Curtarelli *et al.* (2015), não foi possível a coleta de dados de batimetria em algumas regiões mais rasas, por conta da presença de árvores mortas que estão submersas no reservatório e impossibilitam a passagem de embarcações.

Os resultados das interpolações são apresentados na Figura 22. Para correlacionar os dados de batimetria com R_{rs} , a interpolação foi realizada com uma resolução espacial de 30 m x 30 m, para ser coerente com as imagens do sensor OLI.


Figura 22 - Batimetria obtida por krigagem ordinária: (a) gaussiana; (b) exponencial; (c) esférica e (d) circular



Fonte: Autor (2021)

Para a avaliação dos resultados dos interpoladores, realiza-se uma validação cruzada entre os dados reais e os calculados pela krigagem. Essa relação é apresentada na Figura 23.

Figura 23 - Validação cruzada dos dados de krigagem (K.O.): (a) gaussiana; (b) exponencial; (c) esférica e (d) circular



Fonte: Autor (2021)

Nas figuras 23-a, 23-b, 23-c e 23-d, pode-se observar que, dentre os quatro tipos de krigagem ordinária, a exponencial apresenta menor RMSE (~1,8 m), enquanto que o maior é para o modelo gaussiano (~2,6 m). Apesar dos quatro coeficientes de determinação serem parecidos (~0.98), o MAPE da krigagem exponencial (~3,6%) é menor do que nos outros tipos de krigagem ordinária (>4), apresentando uma média de erro absoluta menor. Nota-se, também, que o viés é menor que zero para todos os interpoladores, o que significa que todos os modelos tendem a subestimar os valores de profundidade.

Para uma melhor análise, foram utilizados dois transectos feitos ao longo do reservatório (Figura 12), a fim de comprovar que a krigagem exponencial é a que melhor se adequa à região,

como discutido anteriormente. As figuras 24 e 25 mostram os dois transectos com as quatro formas de krigagem e com a batimetria coletada pelo sonar.

Figura 24 - Transecto A: comparação entre valores originais e interpolados





Figura 25 - Transecto B: comparação entre valores originais e interpolados



Pelos transectos, é possível verificar a coerência dos dados interpolados. No transecto A, em que há uma mudança mais brusca de profundidade, observa-se que o interpolador que mais se aproxima dos dados reais é a krigagem ordinária exponencial e a que menos se aproxima é a gaussiana. No transecto B (Figura 25), observa-se que a krigagem exponencial, a circular e a esférica são muito parecidas entre si e são as que mais se aproximam da original. Com os transectos mostrados pelas figuras 24 e 25, é possível calcular o RMSE de cada transecto, como mostrado na Tabela 5.

Tabela 5 - Dados de RMSE dos transectos para cada tipo de interpolador

Transecto	RMSE (m)			
	Gaussiana	Exponencial	Esférica	Circular
Transecto A	1,327231	0,895159	0,966577	0,986824
Transecto B	2,989033	2,264831	2,318276	2,347887
Total	4,316264	3,15999	3,284853	3,334711

Além do MAPE, do R^2 e do RMSE dos valores gerais, os valores de RMSE dos transectos confirmam que o melhor tipo de krigagem ordinária para esse conjunto de dados é o modelo exponencial.

4.5. Batimetria óptica

Considerando o problema da batimetria óptica em águas profundas e turbidas, em que a penetração da luz é menor e, conseqüentemente, a estimativa por sensores ópticos se torna inviável, os modelos empíricos de Lyzenga (1978), Stumpf *et al.* (2003) e Diersen *et al.* (2003) foram aplicados para uma região mais rasa da área de estudo. A Tabela 6 apresenta os resultados para cada modelo, considerando a nova região.


Tabela 6 - Análise de batimetria estimada por modelos estatísticos

Lyzenga			
$Z_{Lyzenga} = -49,94 - 2,03x_{CB} + 6,05x_B - 19,11x_G + 0,32x_R$			$R^2 = 0,281$
Estatística		Estatística	
Desvio padrão(m)	2,07	MAPE (%)	12,64
Max (m)	45,12	AIC	392308,82
Min (m)	13,86	BIC	392354,94
Viés (m)	$-4,41 \cdot 10^{-13}$	DFFITS	3370
RMSE (m)	3,32	Cook's distance	4294
Stumpf			
$Z_{Stumpf} = 1257,04 - 1589,36x_{CB/B} + 1190,55x_{CB/G} + 531,76x_{CB/R} - 883,54x_{B/G} - 610,78x_{B/R} + 138,63x_{G/R}$			$R^2 = 0,189$
Estatística		Estatística	
Desvio padrão(m)	1,70	MAPE (%)	13,93
Max (m)	68,24	AIC	401310,64
Min (m)	-0,01	BIC	401375,21
Viés (m)	$8,49 \cdot 10^{-12}$	DFFITS	2755
RMSE (m)	3,53	Cook's distance	168
Diersen			
$Z_{Diersen} = 17,9041 + 4,295x_{B/R} + 429,89x_{B/R}^2$			$R^2 = 0,148$
Estatística		Estatística	
Desvio padrão(m)	1,50	MAPE (%)	14,50
Max (m)	53,58	AIC	404933,43
Min (m)	17,89	BIC	404961,10
Viés (m)	$-4,53 \cdot 10^{-14}$	DFFITS	2689
RMSE (m)	3,61	Cook's distance	1093

Ao observarmos as equações de Z, pode-se verificar que Z_{Lyzenga} possui seu coeficiente independente negativo. Isso significa que as somas dos outros coeficientes devem ser positivas, para assim atingir os valores mínimos e máximos positivos apresentados pela Tabela 6. Os coeficientes de Z_{Stumpf} apresentam valores altos devido ao fato de a constante utilizada para a função logarítmica não ser negativa.


Verifica-se que, para todos os modelos, os coeficientes de determinação são baixos, o que significa que uma pequena porcentagem dos dados é de fato explicada pelo modelo. O R^2 do modelo de Lyzenga (1978), mesmo sendo o maior entre os três modelos, é apenas 1,9 vezes maior do que o modelo de Diersen *et al.* (2003). Os RMSE também são muito parecidos, uma vez que o maior (DIERSEN *et al.*, 2003) tem apenas 29 cm a mais que o menor deles (LYZENGA, 1978). O mesmo se dá com o MAPE, em que o de Lyzenga (1978) é ligeiramente menor que os outros modelos. As figuras 26, 27 e 28 apresentam os gráficos de DFFITS e distância de Cook.

Figura 26 - Outliers presentes no modelo de Lyzenga (1978) para a área aplicada




Fonte: Autor (2021)

Figura 27 - Outliers presentes no modelo de Stumpf *et al.* (2003) para a área aplicada



Fonte: Autor (2021)


Figura 28 - Outliers presentes no modelo de Diersen *et al.* (2003) para a área aplicada



Fonte: Autor (2021)

Embora a Tabela 7 mostre que a quantidade de pontos que atendem a distância de Cook para Stumpf *et al.* (2003) é menor que a de outros modelos, nota-se, pelas Figuras 26, 27 e 28 que o valor de distância Cook é praticamente 70 vezes maior do que no Lyzenga (1978) ou Diersen *et al.* (2003). Vale, também, verificar a posição desses pontos, os quais influenciam no modelo, como pode ser observado pela Figura 29.

Figura 29 - Distribuição dos pontos DFFITS e distância de Cook para os modelos de: (a) Lyzenga (1978); (b) Stumpf et al. (2003) e (c) Diersen et al. (2003)




Fonte: Autor (2021)

Na Figura 29, pode-se observar que os *outliers* que influenciam o modelo estão localizados, geralmente, em áreas com a menor profundidade estimada. Percebe-se, também, que, em Stumpf *et al.* (2003), os pontos estão mais distribuídos, o que dificulta o entendimento do erro. Duas regiões que apresentam bastante *outliers* são: 1- a área do extremo Sul-Leste e 2 - a parte Central-Leste. A Região Central-Leste fazia parte do rio Tocantins antes da sua inundação. Já a parte Sul-Leste era uma área de vegetação nativa.

Para a escolha do modelo, utiliza-se o AIC e o BIC que foram menores para o modelo de Lyzenga (1978), assim como o MAPE e o RMSE que foram ligeiramente menores que os outros modelos. Portanto, ao escolher o modelo de Lyzenga (1978), é possível verificar o erro entre a batimetria estimada e a batimetria de campo, conforme se vê na Figura 30.


Figura 30 - Análise do erro ao estimar a batimetria: (a) Batimetria coletada pelo Sonar e interpolada por krigagem Ordinária Exponencial; (b) Batimetria estimada pelo método de Lyzenga (1978) e (c) diferença entre batimetria de campo e estimada



Fonte: Autor(2021)

Por meio da Figura 30-c, observa-se que os erros extremos representados pelas áreas roxas (8,19 m a 25,91 m) e vermelhas (-31,91 m a -8,41 m) estão localizadas principalmente onde a distância de Cook é maior do que o seu critério de aceitação. Constata-se, ainda, que, para profundidades menores, Lyzenga (1978) sobrestima os valores, enquanto que para profundidades maiores, o valor é subestimado. Isso é também observado na Figura 31, que apresenta o gráfico do viés em relação à profundidade.

Figura 31 - Gráfico do viés de cada profundidade



Fonte: Autor (2021)

Comumente, na estimação da batimetria por sensores óticos, águas mais rasas tendem a ter um erro menor que águas mais profundas. No entanto, neste trabalho, observou-se o contrário. Segundo Fearnside (2015), na área oeste do reservatório, há a presença de macrófitas, o que explica o erro em regiões com menor profundidade. Geralmente, as macrófitas se encontram em áreas mais rasas, pois precisam de radiação eletromagnética para sobreviverem. Além disso, essas áreas estão mais próximas da margem do que do antigo curso do rio Tocantins, como explicado por Curtarelli *et al.* (2015), lugar onde, geralmente, é mais raso e mais propensos ao crescimento de macrófitas. Por outro lado, em locais com maior profundidade, é de se esperar que o erro da batimetria seja grande. Isso acontece pela pouca interação da luz com a água em regiões mais profundas.

5. DISCUSSÃO

A R_{sr} é considerada uma propriedade óptica aparente (POA), podendo ser quantificada por sensores passivos. Além disso, ela pode fornecer informações qualitativas e quantitativas dos componentes opticamente ativos (COAs) (VALERIO, *et al.*, 2011). R_{sr} é definida como a quantidade de luz incidente que retorna da coluna d'água em uma determinada direção até chegar a um determinado sensor. Em se tratando de sensores que sofrem influência da atmosfera, é necessário não apenas a correção da radiância refletida da superfície da água (como em casos de espectralímetro), mas também a atenuação por gases e aerossóis que estão presentes na atmosfera. Daí a necessidade de realização de uma correção atmosférica apropriada para o local de estudo. Uma boa estimativa da R_{sr} depende de uma boa correção atmosférica.

Estudos mostram que a correção LaSRC consegue estimar com acurácia a R_{sr} (BERNARDO *et al.*, 2017; VERMOT *et al.*, 2018). Estudos que comparam correções atmosféricas chegam à conclusão de que nas bandas do verde e vermelho os resultados são mais precisos do que na banda do infravermelho próximo (BERNARDO *et al.*, 2017). Este estudo mostrou resultados similares com as correções do ACOLITE, onde o RMSE e o viés da banda do infravermelho próximo são maiores que nos outros comprimentos de onda do sensor OLI embarcado no Landsat-8. Mesmo o ACOLITE obtendo bons resultados para ambientes aquáticos (VANHELLEMONT; RUDDICK, 2014; VANHELLEMONT; RUDDICK, 2015; WEI *et al.*, 2018; CABALLERO; STUMPF, 2020), um dos três modelos apresenta resultado mais compatível com o LaSRC em águas turbas, como é o caso da área escolhida para a realização deste trabalho. Assim como em Vanhellemont e Ruddick (2015) e Bernardo *et al.* (2017), a correção ACOLITE SWIR1-SWIR2 se apresenta melhor que a ACOLITE RED-NIR. Ademais, tal como em Caballero e Stumpf (2020), a correção ACOLITE SWIR1-SWIR2 se apresenta melhor que a ACOLITE DSF.

Utilizando como dado de entrada a R_{sr} proveniente da correção atmosférica ACOLITE-SWIR1-SWIR2, o QAA consegue estimar os parâmetros de a_t e b_b . Na literatura, há muitos algoritmos baseados no QAA (WATANABE, 2016; LEE, 2002; BERNARDO *et al.*, 2019). Este trabalho utilizou a versão 5 do QAA proposto por Lee *et al.* (2009), com adaptações para o sensor multiespectral OLI, como mostrado em Bernardo *et al.* (2019), que exibiu um resultado 30% melhor em relação a outros QAAs existentes para a sua área de estudo.

Sabe-se que, para águas com concentração de CDOM, a absorção total possui um maior valor nos menores comprimentos de onda (Figura 7), assim como a concentração de NAP

(Figura 9). A diferença entre esses dois COA é em questão de magnitude, posto que a grandeza de absorção de CDOM pode chegar a ser 80% maior que a de NAP (MENESES; ALMEIDA; BAPTISTA, 2009). Esses dois COA se diferem da absorção por fitoplâncton, que tem o seu primeiro pico no comprimento de onda entre o 450 nm e 500 nm e o seu segundo pico entre 600 nm e 700 nm, como mostrado na Figura 8. Pode-se observar, na Figura 17, que, no reservatório da Usina Hidrelétrica de Tucuruí, há casos de materiais em suspensão e fitoplâncton. Barbosa *et al* (2014) corrobora essa afirmação ao dizer que o local é heterogêneo, com a influencia de diferentes COA no sinal registrado pelo sensor.

Segundo Meneses, Almeida e Baptista (2009), a Figura 18 pode representar um caso de águas com fitoplâncton, devido à sua baixa magnitude do retroespalhamento. Além disso, vê-se que o decaimento em direção aos comprimentos de ondas maiores é menos acentuado. Isso explica a cor verde de mares com maior produtividade (fitoplâncton está ligado diretamente com a produtividade primária nos oceanos). Partículas inorgânicas mostrariam um crescimento exponencial em direção aos comprimentos de onda maiores.

Um dos produtos que podem ser derivados de a_t e b_b é o K_d (490), que representa a taxa de decaimento da irradiância no comprimento de onda de 490 nm com a profundidade. A Equação 70, utilizada na estimativa de K_d (490), é a que apresenta melhor resultado (GOMES, 2018) para águas mais turbidas. Esse coeficiente consegue estimar o coeficiente de atenuação difusa da radiação fotossinteticamente ativa – K_d (PAR). Ambos os coeficientes são muito estudados na busca de melhor entendimento da circulação atmosférica, modelos de ecossistemas e biogeoquímica (SON; WANG, 2015). O K_d (PAR) está intimamente ligado com a zona eufótica (GOMES, 2020), que é a profundidade que recebe luz solar suficiente para que aconteça a fotossíntese.

Segundo Curtarelli *et al* (2015), a krigagem ordinária melhor interpola os dados de batimetria coletados com o sonar, apresentando um RMSE de 0,92 m. Os resultados obtidos neste trabalho, em relação aos quatro tipos principais de krigagem ordinária, possuem um RMSE maior do que 1,5 m, não alcançando o apresentado em Curtarelli *et al*. (2015). Isso acontece, provavelmente, pelo grid utilizado em cada um dos trabalhos. Curtarelli *et al*. (2015), utiliza um grid de 250 m x 250 m, que possui uma resolução espacial 70 vezes maior que o utilizado neste trabalho (30 m x 30 m). Nesse caso, o modelo que apresentou menor RMSE foi a krigagem ordinária exponencial, e ela foi utilizada como parâmetro de entrada para a estimativa da batimetria via sensores ópticos.


O modelo de Lyzenga (1978) vem sendo utilizado em muitos trabalhos de batimetria óptica empírica (PACHECO *et al*, 2014; KABIRI, 2017) e se mostrando mais acurado ao

utilizar mais do que duas bandas e ao utilizar R_{sr} como parâmetro de entrada. Kabiriri (2017) mostrou que, ao aplicar Stumpf *et al* (2003) e Lyzenga (1978), ambos apresentam resultados semelhantes, com Lyzenga (1978) obtendo um RMSE apenas 16 cm menor que Stumpf *et al.* (2003), o que corrobora os resultados encontrados neste trabalho. O modelo de Diersen *et al.* (2003) também se mostrou próximo aos valores dos outros dois modelos. Na Figura 29, ao observar onde estão localizados os *outliers*, percebe-se que eles se encontram onde a batimetria estimada possui valores mais altos e mais baixos. Uma tendência verificada nos três modelos. Sendo assim, regiões com maior profundidade e com menor profundidade acabam influenciando no modelo.

Para escolher o melhor modelo estatístico, foi utilizado um método muito conhecido de seleção de melhores modelos de regressão, o AIC e o BIC. Quanto menor o AIC e o BIC, melhor o modelo. Para este trabalho, o que apresentou menor valor de AIC e BIC foi o modelo de Lyzenga (1978).


Para a discussão da hipótese, valem as figuras 32 e 33. A Figura 32 apresenta as R_{sr} de cada banda e a Figura 33 traz os resultados para a área em que a batimetria é viável.


Figura 32 - Reflectância de sensoriamento remoto para as bandas: (a) azul costal; (b) azul; (c) verde e (d) vermelho



Fonte: Autor (2021)

Figura 33 - Resultados aplicado para área de batimetria viável: (a) erro entre a batimetria estimada e verdadeira; (b) composição colorida da área em 1984; ; (c) K_d (490); (d) a_t (443); (e) a_t (482); (f) a_t (562); (g) a_t (655); (h) b_b (443); (i) b_b (482); (j) b_b (562); e (k) b_b (655)






Pela Figura 33-a, é possível observar que, na estimativa da batimetria em cada pixel, a maioria possui um erro de ± 3 m. Esse valor ainda se mostra alto se comparado com outros estudos de batimetria óptica (CABELLERO; STUMPF; MEREDITH, 2013; PACHECO *et al*, 2015; KABIRIRI, 2017), porém, assim como em Minghelli-Roman e Dupouy (2013), este trabalho possui um intervalo de profundidade maior (4 m a 51 m), o que acaba influenciando no modelo.

A Figura 33-b é uma imagem composição colorida do local em 1984, antes da construção da usina hidrelétrica. De acordo com Curtarelli *et al.* (2015), as regiões mais profundas estão no curso principal do Rio Tocantins. A Figura 33-b mostra o antigo curso do Rio Tocantins em 1984, antes da inauguração da usina hidrelétrica em 22 de novembro de 1984. Atualmente, toda a área apresentada pela Figura 33-b é água, sem a presença de vegetação. Olhando mais atentamente para as Figuras 33-a e 33-b, observa-se que as áreas que contêm os maiores erros sobrestimado (estimado > verdadeiro) estão localizadas onde antigamente era área de floresta nativa, que também são as áreas mais rasas (Figura 30-a). Importante notar que não são todas as áreas de mata nativa que possuem esse erro, algumas dessas áreas apresentam erros pequenos. Leva-se, também, em consideração que, de acordo com Fearnside (2015), a parte Oeste do reservatório possui maior quantidade de macrófitas, algo que pode explicar esses erros sobrestimados.


Selecionando, aleatoriamente, 42 pontos para a análise do erro, as figuras 34 e 35 apresentam os erros sobrestimados e subestimados em relação a a_t e b_b .

Figura 34 - Absorção total (a_t) de lugares que possuem erros subestimado e sobrestimado



Fonte: Autor (2021)

Figura 35 - Retroespalhamento (b_b) de lugares que possuem erros subestimado e sobrestimado



Fonte: Autor (2021)

Como é possível observar, nas figuras 34 e 35, tanto para a_t quanto para b_b , os valores menores apresentam os erros sobrestimados (em verde), ao passo que os valores maiores apresentam os erros subestimados (vermelho). Viela (2010) analisou três parâmetros da água: transparência, concentração de clorofila e turbidez. A transparência se relaciona com o comprimento de onda do azul, a concentração de clorofila, com o comprimento de onda do verde e a turbidez, com a vermelha. A transparência é diretamente proporcional à absorção da banda do azul. A concentração de clorofila e a turbidez são inversamente proporcionais às suas absorções nos comprimentos de ondas do verde e vermelho, respectivamente. Isso indica que os valores sobrestimados são, em sua maioria, menos transparentes quando há maior concentração de clorofila e maior turbidez, já que seus valores de absorção são mais baixos que os valores subestimados. Sendo assim, é de se esperar que a batimetria por sensores ópticos não seja capaz de estimar essas áreas com precisão. Isso vai de acordo com o que foi estudado por Minghelli-Roman e Dupouy (2013), que constataram que áreas com menor presença de clorofila tendem a apresentar um RMSE da batimetria estimada menor do que áreas com alta concentração de clorofila.

Os erros sobrestimados, como dito anteriormente, podem estar ligados à presença de macrófitas na região, o que envolveria erros maiores, mesmo que a região seja mais transparente, com menor concentração de clorofila e com menor turbidez. Essas regiões com erro sobrestimado estão localizadas exatamente em locais em que a profundidade é menor, ou seja, lugares mais rasos e geralmente próximos da borda, o que também indica uma situação favorável ao crescimento de macrófitas (ROTTA, 2011). A área central também apresenta uma região com erro sobrestimado, mesmo estando mais afastada da borda, porém, nesse local, há a presença de ilhas, o que faz a região ser mais rasa, podendo conter macrófitas.

A Figura 35 mostra que o retroespalhamento é mais perceptível a essa relação, quando maiores valores de b_b apresentam erros subestimados e valores menores apresentam erros sobrestimados. Segundo Meneses, Almeida e Baptista (2009), o retroespalhamento total é dado pela contribuição de partículas, assim ele aumenta conforme o aumento da concentração de sedimentos em suspensão. Sendo assim, os erros subestimados são prováveis de terem maior concentração de sedimentos em suspensão do que os erros sobrestimados.

Em regiões rasas, há maior resposta do sensor do que em regiões mais profundas, isso porque há menos volume de coluna d'água e, portanto, menos iterações com os COA. Com a presença de macrófitas nas regiões mais rasas, o retorno do sinal é menor, pois as macrófitas absorvem a radiação solar. Logo, o retorno do sinal é menor, como em águas mais profundas, por isso os erros acabam sendo sobrestimados. Já em regiões com presença da NAP há maior

retroespalhamento e, por isso, há um maior sinal do sensor, o que indicaria uma região rasa. Contudo, a NAP está concentrada em regiões mais profundas, o que justifica o erro subestimado.

6. CONCLUSÕES E RECOMENDAÇÕES

A utilização da correção ACOLITE SWIR1-SWIR2 se mostrou melhor do que a RED-NIR e a DSF para a representação da R_{sr} , que foi parâmetro de entrada para outras etapas do projeto. Por meio de comparações com a LaRSC, foi possível identificar qual a melhor correção para a área de estudo e, assim estimar a_t e b_b .

Utilizando R_{sr} como parâmetro de entrada para a estimação de a_t e b_b por meio do algoritmo do QAA, mostrando maiores valores de a_t para banda do azul, o que indica dominância de partículas inorgânicas em suspensão ou fitoplâncton. Enquanto o b_b é maior para menores λ , indicando presença de sedimentos em suspensão, o a_t tem maior variabilidade que b_b . Tendo a_t e b_b como parâmetros de entrada para cálculo do K_d (490), tendo como resultado um K_d (490) diretamente proporcional a a_t (482) e b_b (482). Significando que a atenuação da luz na água é maior onde há mais presença de a_t (482) e b_b (482).

Para interpolação da área, foi comparado os tipos de krigagem ordinária e percebe-se que a exponencial é mais acurada do que a circular, a gaussiana e a esférica, para a representação do reservatório. A comparação foi realizada pelas profundidades coletadas pelo sonar. Esses valores interpolados foram utilizados como parâmetros de entrada para a etapa de batimetria óptica.

A batimetria estimada por sensores ópticos pelos modelos de Lyzenga (1978), Diersen *et al.* (2203) e Stumpf *et al.* (2003) se mostra muito similar, contudo, pelo AIC e BIC, que são critérios que conseguem avaliar qual o melhor tipo de regressão, Lyzenga (1974) apresentou uma melhor regressão.

Os erros na estimação da batimetria óptica por Lyzenga (1978) são separados em dois tipos: os subestimados e os sobrestimados. Os sobrestimados (estimado>verdadeiro) possuem a_t e b_b menores do que os erros subestimados (estimado<verdadeiro). Há indicativos de que os erros sobrestimados acontecem devido à existência de macrófitas na região, ao passo que os erros subestimados devem conter maior quantidade de sedimentos em suspensão

Uma possibilidade para trabalhos futuros é a identificação de coeficientes de absorções específicos (clorofila, CDOM e NAP) para correlacionar com os erros causados pela batimetria óptica. Outra sugestão é a realização da batimetria óptica por intervalos particionados por distância da borda do reservatório, o que pode gerar uma melhoria na estimação da batimetria. Pode-se, também, aplicar o QAA utilizando outra correção atmosférica, como a própria LaSRC, ou outras imagens, como as imagens do Sentinel-2 ou Sentinel-3.

REFERÊNCIAS BIBLIOGRÁFICAS

ALCÂNTARA, Enner *et al.* Integrating historical topographic maps and SRTM data to derive the bathymetry of a tropical reservoir. **Journal of hydrology**, v. 389, n. 3-4, p. 311-316, 2010.

ANDRADE, Caroline *et al.* An assessment of semi-analytical models based on the absorption coefficient in retrieving the chlorophyll-a concentration from a reservoir. **Advances in Space Research**, v. 63, n. 7, p. 2175-2188, 2019.

BARBOSA, Cláudio *et al.* Bio-optical characterization of two Brazilian hydroelectric reservoirs as support to understand the carbon budget in hydroelectric reservoirs. In: **2014 IEEE Geoscience and Remote Sensing Symposium**. IEEE, 2014. p. 898-901.

BARBOSA, Claudio Clemente Faria; NOVO, Evlyn Marcia Leão de Moraes; MARTINS, Vitor Souza (Ed.). **Introdução ao sensoriamento remoto de sistemas aquáticos: princípios e aplicações**. Instituto Nacional de Pesquisas Espaciais, 2019.

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

BERK, Alexander *et al.* MODTRAN4 radiative transfer modeling for atmospheric correction. In: **Optical spectroscopic techniques and instrumentation for atmospheric and space research III**. International Society for Optics and Photonics, 1999. p. 348-353.

BERNARDO, Nariane Marselhe Ribeiro. Análise do potencial do sensor OLI (Operational Land Imager) a bordo do Landsat-8 em estimar a concentração de sólidos totais em suspensão no reservatório de Barra Bonita. **Dissertação de Mestrado em Ciências Cartográficas, aprovada em 30 de outubro de 2015**.

BERNARDO, Nariane *et al.* Atmospheric correction issues for retrieving total suspended matter concentrations in inland waters using OLI/Landsat-8 image. **Advances in Space Research**, v. 59, n. 9, p. 2335-2348, 2017.

BERNARDO, Nariane et al. Retrieval of suspended particulate matter in inland waters with widely differing optical properties using a semi-analytical scheme. **Remote Sensing**, v. 11, n. 19, p. 2283, 2019.

BICALHO, Bruna de Castro. Modelo Espaço-Temporais: Estudo de Caso. **Dissertação de Mestrado em Ciências Exatas**. Departamento de Estatística do Instituto de Exatas da Universidade Federal de Minas Gerais. UFMG. Belo Horizonte, Minas Gerais, 2008

BRANDO, Vittorio E. *et al.* A physics based retrieval and quality assessment of bathymetry from suboptimal hyperspectral data. **Remote Sensing of Environment**, v. 113, n. 4, p. 755-770, 2009.

CABALLERO, Isabel; STUMPF, Richard P. Atmospheric correction for satellite-derived bathymetry in the Caribbean waters: from a single image to multi-temporal approaches using Sentinel-2A/B. **Optics express**, v. 28, n. 8, p. 11742-11766, 2020.

CABALLERO, Isabel; STUMPF, Richard P.; MEREDITH, Andrew. Preliminary assessment of turbidity and chlorophyll impact on bathymetry derived from Sentinel-2A and Sentinel-3A satellites in South Florida. **Remote Sensing**, v. 11, n. 6, p. 645, 2019.

COLLINGS, Simon *et al.* Depth from Satellite Images: Depth Retrieval Using a Stereo and Radiative Transfer-Based Hybrid Method. **Remote Sensing**, v. 10, n. 8, p. 1247, 2018.

CURTARELLI, Marcelo *et al.* Assessment of spatial interpolation methods to map the bathymetry of an Amazonian hydroelectric reservoir to aid in decision making for water management. **ISPRS International Journal of Geo-Information**, v. 4, n. 1, p. 220-235, 2015.

DIERSSSEN, Heidi M. *et al.* Ocean color remote sensing of seagrass and bathymetry in the Bahamas Banks by high-resolution airborne imagery. **Limnology and oceanography**, v. 48, n. 1part2, p. 444-455, 2003.

DIERSSSEN, Heidi M.; THEBERGE, Albert E. Bathymetry: Assessing Methods. **Encyclopedia of Ocean Sciences**, 2014.

FAN, Chunlei. Spectral analysis of water reflectance for hyperspectral remote sensing of water quality in estuarine water. **Journal of Geoscience and Environment Protection**, v. 2, n. 02, p. 19, 2014.

FEARNSIDE, Philip M. Social impacts of Brazil's Tucuruí dam. **Environmental Management**, v. 24, n. 4, p. 483-495, 1999.

FEARNSIDE, Philip Martin. Hidrelétricas na Amazônia: impactos ambientais e sociais na tomada de decisões sobre grandes obras-Volume 2. 2015.

FERREIRA, Italo Oliveira et al. In bathymetric surfaces: IDW or Kriging? **Boletim de Ciências Geodésicas**, v. 23, p. 493-508, 2017.

Fondriest Environmental, Inc. "Algae, Phytoplankton and Chlorophyll." **Fundamentals of Environmental Measurements**. 22 Oct. 2014. Web. Disponível em <<https://www.fondriest.com/environmental-measurements/parameters/water-quality/algae-phytoplankton-and-chlorophyll>>. Acessado em 23 de julho de 2019.

GOMES, Ana Carolina Campos et al. Diffuse attenuation coefficient retrieval in CDOM dominated inland water with high chlorophyll-a concentrations. **Remote Sensing**, v. 10, n. 7, p. 1063, 2018.

GOMES, Ana Carolina et al. Satellite estimates of euphotic zone and Secchi disk depths in a colored dissolved organic matter-dominated inland water. **Ecological Indicators**, v. 110, p. 105848, 2020.

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

GORDON, Howard R. Absorption and scattering estimates from irradiance measurements: Monte Carlo simulations. **Limnology and Oceanography**, v. 36, n. 4, p. 769-777, 1991.

HAMM, Nicholas A. S.; ATKINSON, Peter M.; MILTON, Edward J. A per-pixel, non-stationary mixed model for empirical line atmospheric correction in remote sensing. **Remote sensing of environment**, v. 124, p. 666-678, 2012.

KABIRI, Keivan. Accuracy assessment of near-shore bathymetry information retrieved from Landsat-8 imagery. **Earth Science Informatics**, v. 10, n. 2, p. 235-245, 2017.

KERR, Jeremy M.; PURKIS, Sam. An algorithm for óptically-deriving water depth from multispectral imagery in coral reef landscapes in the absence of ground-truth data. **Remote sensing of environment**, v. 210, p. 307-324, 2018.

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

LEE, Zhongping *et al.* Hyperspectral remote sensing for shallow waters: 2. Deriving bottom depths and water properties by optimization. **Applied optics**, v. 38, n. 18, p. 3831-3843, 1999.

LEE, ZhongPing; CARDER, Kendall L.; ARNONE, Robert A. Deriving inherent óptical properties from water color: a multiband quasi-analytical algorithm for óptically deep waters. **Applied optics**, v. 41, n. 27, p. 5755-5772, 2002.

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

LEE, ZhongPing *et al.* An update of the quasi-analytical algorithm (QAA_v5). **International Ocean Color Group Software Report**, p. 1-9, 2009.

LEE, Zhongping *et al.* Penetration of UV-visible solar radiation in the global oceans: Insights from ocean color remote sensing. **Journal of Geophysical Research: Oceans**, v. 118, n. 9, p. 4241-4255, 2013.

LEGLEITER, Carl J.; FOSNESS, Ryan L. Defining the Limits of Spectrally Based Bathymetric Mapping on a Large River. **Remote Sensing**, v. 11, n. 6, p. 665, 2019.

LILLESAND, Thomas; KIEFER, Ralph W.; CHIPMAN, Jonathan. **Remote sensing and image interpretation**. John Wiley & Sons, 2015.

LIU, Kuo-Nan. **An introduction to atmospheric radiation**. Elsevier, 2002.

LYZENGA, David R. Passive remote sensing techniques for mapping water depth and bottom features. **Applied optics**, v. 17, n. 3, p. 379-383, 1978.

LYZENGA, D. Shallow-water bathymetry using combined lidar and passive multispectral scanner data. **International Journal of Remote Sensing**, v.6, n. 1, p. 115-125, 1985.

MANESSA, Masita Dwi Mandini *et al.* Simulation-based investigation of the generality of Lyzenga's multispectral bathymetry formula in Case-1 coral reef water. **Estuarine, Coastal and Shelf Science**, v. 200, p. 81-90, 2018.

MENESES, Paulo Roberto; DE ALMEIDA, Tati; DE MELLO BAPTISTA, Gustavo Macedo. **Refletância dos materiais terrestres**. Oficina de Textos, 2009.

MINGHELLI-ROMAN, Audrey; DUPOUY, Cécile. Influence of water column chlorophyll concentration on bathymetric estimations in the lagoon of New Caledonia, using several MERIS images. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 6, n. 2, p. 739-745, 2013.

MISHRA, Deepak R. *et al.* 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, Deepak R. *et al.* Enhancing the detection and classification of coral reef and associated benthic habitats: A hyperspectral remote sensing approach. **Journal of Geophysical Research: Oceans**, v. 112, n. C8, 2007.

MISHRA, Sachidananda *et al.* Quantifying cyanobacterial phycocyanin concentration in turbid productive waters: A quasi-analytical approach. **Remote Sensing of Environment**, v. 133, p. 141-151, 2013.

MOBLEY, Curtis D. **Light and water: radiative transfer in natural waters**. Academic press, 1994.

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

MOREL, André; GENTILI, Bernard. Diffuse reflectance of oceanic waters: its dependence on Sun angle as influenced by the molecular scattering contribution. **Applied optics**, v. 30, n. 30, p. 4427-4438, 1991.

MORRIS, I. The limits to the productivity of the sea. **Science Progress (1933-)**, p. 99-122, 1974.

MOUW, Colleen B. *et al.* Evaluation and optimization of bio-óptical inversion algorithms for remote sensing of Lake Superior's óptical properties. **Journal of Geophysical Research: Oceans**, v. 118, n. 4, p. 1696-1714, 2013.

NIROUMAND-JADIDI, Milad; VITTI, Alfonso; LYZENGA, David R. Multiple Optimal Depth Predictors Analysis (MODPA) for river bathymetry: Findings from spectroradiometry, simulations, and satellite imagery. **Remote sensing of environment**, v. 218, p. 132-147, 2018.

PACHECO, André *et al.* Retrieval of nearshore bathymetry from Landsat 8 images: A tool for coastal monitoring in shallow waters. **Remote Sensing of Environment**, v. 159, p. 102-116, 2015.

POPE, Robin M.; FRY, Edward S. Absorption spectrum (380–700 nm) of pure water. II. Integrating cavity measurements. **Applied optics**, v. 36, n. 33, p. 8710-8723, 1997.

QU, Liqin. Remote sensing suspended sediment concentration in the Yellow River. 2014. **Tese de Doutorado, aprovada em 6 de maio de 2014.**

ROTTA, Luiz Henrique da Silva. Inferencia Espacial para Mapeamento de Macrófitas Submersas – Estudo de Caso. **Dissertação de Mestrado em Ciências Cartográficas, aprovada em 25 de fevereiro de 2011.**

RÖTTGERS, R. *et al.* The Water Optical Properties Processor (WOPP): Pure Water Spectral Absorption, Scattering, and Real Part of Refractive Index Model. *ATBD*, Issue 1.8, ESA **Water Radiance Project**. 2016.

RUDDICK, Kevin George; OVIDIO, Fabrice; RIJKEBOER, Machteld. Atmospheric correction of SeaWiFS imagery for turbid coastal and inland waters. **Applied optics**, v. 39, n. 6, p. 897-912, 2000.

RUDDICK, Kevin G. *et al.* Seaborne measurements of near infrared water-leaving reflectance: The similarity spectrum for turbid waters. **Limnology and Oceanography**, v. 51, n. 2, p. 1167-1179, 2006.

RUDORFF, Conrado M. *et al.* Análise derivativa de dados hiperespectrais medidos em nível de campo e orbital para caracterizar a composição de águas opticamente complexas na Amazônia. **Acta Amazonica**, v. 37, p. 269-280, 2007.

SILVA, Maria Paula. modelos de sensoriamento remoto no estudo da variabilidade espacial e sazonal da matéria orgânica dissolvida em lagos da planície de inundação do Solimões/Amazonas a partir de suas propriedades ópticas **Dissertação de Mestrado em Sensoriamento Remoto, aprovada em 26 de março de 2018.**

SMITH, Raymond C.; BAKER, Karen S. Optical properties of the clearest natural waters (200–800 nm). **Applied optics**, v. 20, n. 2, p. 177-184, 1981.

SOGANDARES, Frank M.; FRY, Edward S. Absorption spectrum (340–640 nm) of pure water. I. Photothermal measurements. **Applied Optics**, v. 36, n. 33, p. 8699-8709, 1997.

SON, SeungHyun; WANG, Menghua. Diffuse attenuation coefficient of the photosynthetically available radiation K_d (PAR) for global open ocean and coastal waters. **Remote Sensing of Environment**, v. 159, p. 250-258, 2015.

STUMPF, Richard P.; HOLDERIED, Kristine; SINCLAIR, Mark. Determination of water depth with high-resolution satellite imagery over variable bottom types. **Limnology and Oceanography**, v. 48, n. 1part2, p. 547-556, 2003.

SU, Lihong; HUANG, Yuxia. Seagrass resource assessment using worldview-2 imagery in the redfish bay, texas. **Journal of Marine Science and Engineering**, v. 7, n. 4, p. 98, 2019.

TRAGANOS, Dimosthenis *et al.* Estimating satellite-derived bathymetry (SDB) with the google earth engine and sentinel-2. **Remote Sensing**, v. 10, n. 6, p. 859, 2018.

DE MATOS VALERIO, Aline; KAMPEL, Milton; STECH, José Luis. Correlação de dados de reflectância de sensoriamento remoto estimados com dados do sensor MODIS e medidas in situ.

VAN DER MEER, Freek. Physical principles of optical remote sensing. In: **Spatial statistics for remote sensing**. STEIN, Alfred; VAN DER MEER, Freek D.; GORTE, Ben, (Ed.). Springer Science & Business Media, 2006, p 27-41.

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

VANHELLEMONT, Quinten; RUDDICK, Kevin. Advantages of high quality SWIR bands for ocean colour processing: Examples from Landsat-8. **Remote Sensing of Environment**, v. 161, p. 89-106, 2015.

VANHELLEMONT, Quinten. Adaptation of the dark spectrum fitting atmospheric correction for aquatic applications of the Landsat and Sentinel-2 archives. **Remote Sensing of Environment**, v. 225, p. 175-192, 2019.

VERMOTE, E. et al. LaSRC (Land Surface Reflectance Code): Overview, application and validation using MODIS, VIIRS, LANDSAT and Sentinel 2 data's. In: **IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium**. IEEE, 2018. p. 8173-8176.

WATANABE, Fernanda Sayuri Yoshino. Parameterization of bio-óptical models for estimating chlorophyll-a concentration in a tropical eutrophic reservoir. 2016. **Tese de Doutorado em Ciências Cartográficas, aprovada em 15 de março de 2016.**

WATANABE, Fernanda *et al.* Landsat-based remote sensing of the colored dissolved organic matter absorption coefficient in a tropical oligotrophic reservoir. **Remote Sensing Applications: Society and Environment**, v. 9, p. 82-90, 2018.

WORLD COMMISSION ON DAMS. **Dams and development: A new framework for decision-making: The report of the world commission on dams**. Earthscan, 2000.

WEI, Jianwei *et al.* An assessment of Landsat-8 atmospheric correction schemes and remote sensing reflectance products in coral reefs and coastal turbid waters. **Remote sensing of environment**, v. 215, p. 18-32, 2018.

WETZEL, Robert G. **Limnology: lake and river ecosystems**. gulf professional publishing, 2001.

WILLIAMS, G.N., P. Larouche, A.I. Dogliotti, and M.P. Latorre. 2018. Light absorption by phytoplankton, non-algal particles, and dissolved organic matter in San Jorge Gulf in summer. **Oceanography** 31(4):40–49, <https://doi.org/10.5670/oceanog>

XIE, Huixiang *et al.* The dynamics of absorption coefficients of CDOM and particles in the St. Lawrence estuarine system: Biogeochemical and physical implications. **Marine Chemistry**, v. 128, p. 44-56, 2012.

YAMAMOTO, Jorge Kazuo; LANDIM, Paulo M. Barbosa. **Geoestatística: conceitos e aplicações**. Oficina de textos, 2015.

YANG, Wei *et al.* Retrieval of inherent optical properties for turbid inland waters from remote-sensing reflectance. **IEEE Transactions on Geoscience and Remote Sensing**, v. 51, n. 6, p. 3761-3773, 2012.

ZHANG, Yun L. *et al.* Bio-optical properties and estimation of the optically active substances in Lake Tianmuhu in summer. **International Journal of Remote Sensing**, v. 30, n. 11, p. 2837-2857, 2009.

ZOFFOLI, Maria; FROUIN, Robert; KAMPEL, Milton. Water column correction for coral reef studies by remote sensing. **Sensors**, v. 14, n. 9, p. 16881-16931, 2014.