



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

sid.inpe.br/mtc-m21c/2019/01.30.16.35-TDI

**QUANTIFICAÇÃO REMOTA DA CONCENTRAÇÃO DE
SÓLIDOS TOTAIS E INORGÂNICOS EM SUSPENSÃO
EM LAGOS DA PLANÍCIE DE INUNDAÇÃO DO BAIXO
AMAZONAS - UMA ABORDAGEM MULTI-SENSOR**

Daniel Andrade Maciel

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Evlyn Márcia Leão
de Moraes Novo, e Lino Augusto
Sander de Carvalho, aprovada em
25 de fevereiro de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3SLFNB5>>

INPE
São José dos Campos
2019

PUBLICADO POR:

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

CEP 12.227-010

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/7348

E-mail: pubtc@inpe.br

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

Presidente:

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

Membros:

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

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

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

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

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

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

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

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon

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

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

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

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

EDITORAÇÃO ELETRÔNICA:

Ivone Martins - Serviço de Informação e Documentação (SESID)

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



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

sid.inpe.br/mtc-m21c/2019/01.30.16.35-TDI

QUANTIFICAÇÃO REMOTA DA CONCENTRAÇÃO DE SÓLIDOS TOTAIS E INORGÂNICOS EM SUSPENSÃO EM LAGOS DA PLANÍCIE DE INUNDAÇÃO DO BAIXO AMAZONAS - UMA ABORDAGEM MULTI-SENSOR

Daniel Andrade Maciel

Dissertação de Mestrado do
Curso de Pós-Graduação em
Sensoriamento Remoto, orientada
pelos Drs. Evlyn Márcia Leão
de Moraes Novo, e Lino Augusto
Sander de Carvalho, aprovada em
25 de fevereiro de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3SLFNB5>>

INPE
São José dos Campos
2019

Dados Internacionais de Catalogação na Publicação (CIP)

Maciel, Daniel Andrade.

M187q Quantificação remota da concentração de sólidos totais e inorgânicos em suspensão em lagos da planície de inundação do Baixo Amazonas - uma abordagem multi-sensor / Daniel Andrade Maciel. – São José dos Campos : INPE, 2019.

xxx + 164 p. ; (sid.inpe.br/mtc-m21c/2019/01.30.16.35-TDI)

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

Orientadores : Drs. Evlyn Márcia Leão de Moraes Novo, e Lino Augusto Sander de Carvalho.

1. Landsat-8. 2. Sentinel-2. 3. CBERS-4. 4. Correção atmosférica. 5. Correção de Glint. I.Título.

CDU 528.8.04(282.281.3)



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

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

Aluno (a): **Daniel Andrade Maciel**

Título: "QUANTIFICAÇÃO REMOTA DA CONCENTRAÇÃO DE SÓLIDOS TOTAIS E INORGÂNICOS EM SUSPENSÃO EM LAGOS DA PLANÍCIE DE INUNDAÇÃO DO BAIXO AMAZONAS - UMA ABORDAGEM MULTI-SENSOR"

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

Dr. Milton Kampel



Presidente / INPE / SJC Campos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dra. Evelyn Márcia Leão de Moraes Novo

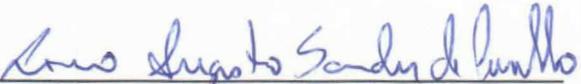


Orientador(a) / INPE / SJC Campos - SP

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dr. Lino Augusto Sander de Carvalho

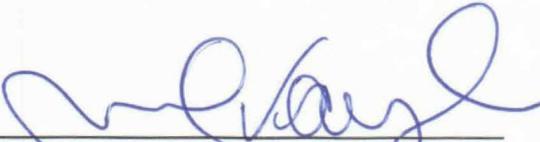


Orientador(a) / UFRJ / Rio de Janeiro - RJ

() Participação por Vídeo - Conferência

Aprovado () Reprovado

Dra. Natália Rudorff Oliveira



Membro da Banca / INPE / Cachoeira Paulista - SP

Participação por Vídeo - Conferência

Aprovado () Reprovado

Este trabalho foi aprovado por:

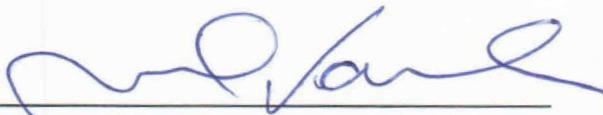
() maioria simples

unanimidade

São José dos Campos, 25 de fevereiro de 2019

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

Dr. Otávio Cristiano Montanher



Convidado(a) / UEM / Maringá - PR

Participação por Video - Conferência

Aprovado () Reprovado

Dra. Maycira Costa



Convidado(a) / UVic / Victoria - CAN

Participação por Video - Conferência

Aprovado () Reprovado

Este trabalho foi aprovado por:

() maioria simples

unanimidade

São José dos Campos, 25 de fevereiro de 2019

"La cultura es lo único que puede salvar un pueblo, lo único, porque la cultura permite ver la miseria y combatirla. La cultura permite distinguir lo que se debe cambiar y lo que se debe dejar, como la bondad de la gente, el compartir una empanada, un vino..."

Mercedes Sosa

AGRADECIMENTOS

À toda minha família, pelo apoio incondicional durante o meu percurso durante a realização do mestrado. Com especial aos meus pais, Max e Marcia e meus irmãos, André e Isabella. Um agradecimento especial também aos meus avós, tias e tios que também sempre estiveram juntos comigo.

Aos meus orientadores, Dr.a Evlyn Novo e Dr. Lino, pela amizade, confiança, incentivo e discussões extremamente importantes, sejam estas científicas ou sobre a vida. Sou muito grato pelos vários conselhos e ajudas durante todo este tempo. Também sou muito grato ao Dr. Cláudio Barbosa pela também orientação (mesmo que não oficial) e conselhos durante todo esse tempo de mestrado! A vocês, meu muito obrigado!

A todos os grandes amigos do Laboratório de Instrumentação em Sistemas Aquáticos (LabISA) do INPE pelas amizades, risadas, conselhos, cafés e almoços.

A todos os amigos da turma de 2017 do curso de mestrado em Sensoriamento Remoto do INPE e todos os outros agregados por todos os momentos felizes durante este tempo. Um obrigado especial à Juliana e ao Rogério, pela grande ajuda e amizade durante todo este tempo de mestrado. Também um obrigado à todos os professores que muito nos ensinaram durante este tempo.

À minha orientadora da graduação, Dr.a Margarete Volpato, por ter me apresentado a linda ciência que é o sensoriamento remoto e ter me despertado à paixão pela pesquisa. Meu muito obrigado por tudo e pela confiança!

Aos meus amigos de Cruzília e de Lavras, meu também muito obrigado por tudo! Um agradecimento especial também à Lorena, pela grande ajuda durante grande parte deste mestrado. Também agradeço aos meus amigos do apartamento pela amizade.

Um obrigado especial também a todo o pessoal da limpeza do INPE, em especial à Cristina, pela simpatia e pelo café de todo dia!

Agradeço também ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de mestrado e a pós-graduação do INPE, por fornecer toda a estrutura necessária sem a qual não seria possível a realização deste trabalho.

RESUMO

A utilização de imagens de sensoriamento remoto é de fundamental importância para aumentar o conhecimento sobre a dinâmica da troca de sedimentos entre o Rio Amazonas e as planícies de inundação já que ela pode ajudar a entender como as mudanças climáticas e de uso da terra influenciam esse processo. Neste sentido, este trabalho investigou a acurácia de algoritmos de estimativa de TSS (Total de Sólidos em Suspensão) e TSI (Total de Sólidos Inorgânicos em suspensão) através da utilização de três sensores de média resolução espacial (Landsat-8/OLI, Sentinel-2A/MSI e CBERS-4/WFI) em lagos na planície de inundação do Baixo Amazonas. Através de simulação Monte Carlo, foram calibrados e validados algoritmos empíricos e semi-analíticos a partir dados de refletância de sensoriamento remoto (R_{rs}) medidos *in-situ* e simulados para os três sensores (R_{rs_sim}) e dados de TSS e TSI coletados simultaneamente ao longo de quatro campanhas de campo em lagos do baixo Amazonas. Para calibração dos algoritmos, três conjuntos de dados foram avaliados: Conjunto completo, separados por campanhas e separados por lagos. Após a calibração dos algoritmos, estes foram aplicados a uma cena de agosto de 2017 de cada sensor para sua validação com dados de TSS e TSI *in-situ*. Além da validação dos dados de TSS e TSI, avaliou-se também o desempenho de diversos métodos de correção atmosférica para o OLI (6S, ACOLITE, L8SR), MSI (6S, ACOLITE, Sen2Cor) e WFI (6S) e também de correção de glint para o OLI e MSI tomando-se as R_{rs} simuladas a partir das medidas de R_{rs} *in-situ* como referência. Finalmente, avaliou-se a congruência entre os dados de TSS e TSI estimados pelos três sensores em imagens adquiridas no mesmo dia da passagem dos três satélites afim de avaliar a possibilidade da criação de constelações virtuais com estes sensores. O desempenho dos algoritmos com os dados *in-situ* mostrou resultados similares para as faixas espectrais equivalentes dos três sensores avaliados e também resultados semelhantes para os algoritmos empíricos e semi-analíticos que utilizam a mesma faixa espectral. A validação das correções atmosféricas mostrou uma dependência da faixa espectral utilizada e melhores resultados utilizando o 6S. Já a correção de glint se mostrou satisfatória e com grande influência principalmente sobre a acurácia do sensor MSI (Redução nos valores de MAPE > 100%). Os algoritmos empíricos e semi-analíticos de estimativa de TSS e TSI apresentaram melhores resultados de validação usando a banda do verde do sensor OLI (561 nm), do red-edge do sensor MSI (704 nm) do vermelho do sensor WFI (660 nm) quando aplicado às cenas de agosto de 2017 utilizando o os algoritmos calibrados com o conjunto completo (MAPE < 31%). A comparação das estimativas de TSS e TSI a partir de imagens simultâneas dos três sensores indicou que eles permitiram estimar as concentrações de TSS e TSI com diferenças entre as medianas das concentrações inferior a 1 mgL^{-1} . Estes resultados permitiram, pela primeira vez, a calibração e validação de algoritmos empíricos e semi-analíticos de TSS e TSI em lagos da planície de inundação do Baixo Amazonas utilizando sensores de média resolução espacial.

Palavras-chave: Landsat-8. Sentinel-2. CBERS-4. Correção Atmosférica.
Correção de glnt. Sedimentos.

REMOTE QUANTIFICATION OF INORGANIC AND TOTAL SUSPENDED SOLIDS OVER LOWER AMAZON FLOODPLAIN LAKES – A MULTISENSOR APPROACH

ABSTRACT

Remote sensing (RS) is a key tool for deepening the knowledge on the spatial and temporal dynamics of sediment exchange between Amazon River and their floodplains. Moreover, RS image can help to understand how both climate change and land use and land cover changes influence the sediment exchange between the Amazon River and floodplain lakes. In that sense, this study investigates the accuracy of Total Suspended Solids (TSS) and Total Inorganic Suspended Solids (TSI) estimates of Amazon floodplain lakes derived from medium resolution sensors (Landsat-8/OLI, Sentinel-2A/MSI and CBERS-4/WFI). Empirical and semi-analytical algorithms were calibrated and validated through a robust Monte Carlo simulation using both *in-situ* simulated remote sensing reflectance ($R_{rs,sim}$) and simultaneous TSS/TSI dataset collected over four field campaigns in the lower Amazon floodplain lakes. For algorithm calibration, three different datasets were evaluated: Complete dataset; Campaign dataset and Lake dataset. After the calibration process, calibrated algorithms were applied to an august/2017 scene of each sensor for validation using in-situ TSS and TSI concentration measurements. Despite TSS and TSI validation, the performance of several atmosphere correction methodologies for OLI (L8SR, 6S, ACOLITE), MSI (6S, ACOLITE, Sen2Cor) and WFI (6S) in R_{rs} retrieval were evaluated using *in-situ* $R_{rs,sim}$ as a reference. Furthermore, the impacts of glint correction on OLI and MSI R_{rs} retrieval were also evaluated. Finally, the consistency between TSS and TSI estimates by each sensor was accessed using near-simultaneous imagery aiming to create a virtual-constellation based on those three sensors to support the generation of sediment products. The performance of *in-situ* algorithms demonstrates similar estimates for similar spectral bands disregarding the sensor and the type of algorithm (empirical or semi-analytical). Atmosphere correction validation presented a dependency on the spectral bands used and better results were obtained using 6S, although satisfactory results were also observed with other methods. Moreover, glint correction presented good results and being fundamental to the accuracy of the algorithms based on MSI imagery, reducing MAPE values higher beyond 100%. Empirical and semi-analytical TSS and TSI algorithms best results varied for each sensor when applied to August/2017 scenes: for OLI the best result was for the green band (561 nm) while for MSI the best result was for the red-edge band (704 nm) and for WFI the red band (660 nm) presented best results (MAPE values lower than 31% for both TSS and TSI) using algorithms calibrated with the Complete dataset. The comparison between TSS and TSI estimates using the near-simultaneous overpass indicated that they allowed sediment estimates with median difference

values lower than 1 mgL⁻¹. These results demonstrated, for the first time, the calibration and validation of empirical and semi-analytical algorithms for TSS and TSI retrieval over lower Amazon Floodplain Lakes using medium-resolution sensors.

Keywords: Landsat-8. Sentinel-2. CBERS-4. Atmosphere Correction. Glint Correction. Sediments.

LISTA DE FIGURAS

	<u>Pág.</u>
Figura 2.1 Esquema para a definição das propriedades ópticas inerentes.....	12
Figura 2.2 Coeficientes de absorção (m^{-1}) (POPE e FRY, 1997) (eixo à esquerda) e retroespalhamento (m^{-1}) (ZHANG; HU, 2009) (eixo à direita) da água pura.	14
Figura 2.3 Coeficientes de absorção característicos dos COA (m^{-1}) normalizados pelo coeficiente de absorção médio.....	15
Figura 2.4 Definição da refletância de sensoriamento remoto	18
Figura 3.1 Localização geográfica da área de estudo.....	24
Figura 3.2 Hidrógrafa para a estação fluviométrica de óbidos (17050001) entre os anos de 2015- 2018 (linhas vermelhas) e série histórica (1968 - 2018) para a estação fluviométrica de óbidos (linhas pretas).....	26
Figura 3.3 Configuração geométrica da obtenção dos dados radiométricos (Es, Lsky, Lt).....	28
Figura 3.4 Função de resposta espectral para os sensores OLI, MSI e WFI.....	30
Figura 4.1 Espectros de R_{rs} <i>in-situ</i> para os dados de todas as campanhas. As setas indicam os pontos com maior e menor concentração de TSS.	38
Figura 4.2 Espectros separados por campanhas.....	42
Figura 4.3 Valores de MAPE (%) obtidos através da simulação de Monte Carlo para os dados de R_{rs} simulados para as faixas espectrais dos sensores OLI, WFI e MSI, utilizando os modelos logarítmicos.	43
Figura 4.4 Valores de MAPE (%) obtidos através da simulação de Monte Carlo para os dados de R_{rs} <i>in situ</i> simulados para as bandas dos sensores OLI, WFI e MSI, utilizando os modelos de razão de bandas.....	45
Figura 4.5 Espectros de R_{rs} para os lagos de Curuai e Monte Alegre.....	47

Figura 4.6 Valores de MAPE (%) obtidos através da simulação de Monte Carlo para os dados de R_{rs} simulados para as faixas espectrais dos sensores OLI, WFI e MSI, utilizando os modelos logarítmicos.	48
Figura 4.7 Valores de MAPE (%) resultantes da simulação de Monte Carlo para os dados de R_{rs} simulados para as faixas espectrais dos sensores OLI, WFI e MSI, utilizando os modelos de razão de bandas.....	49
Figura 4.8 Distribuição acumulada das concentrações de TSS (linha preta) e de TSI (linha vermelha) dos dados utilizados no modelo com todos os dados (n = 94).....	54
Figura 4.9 Função de Distribuição de Probabilidades obtidas através da simulação de Monte Carlo para os modelos de TSS nas faixas espectrais que possuem uma FRE próxima.....	55
Figura 4.10 Função de Distribuição de Probabilidades obtidas através da simulação de Monte Carlo para os modelos de TSI nas faixas espectrais que possuem uma FRE próxima.....	56
Figura 4.11 Comparação das R_{rs} simulada nas faixas espectrais que possuem FRE próximas.	57
Figura 4.12 Função de Distribuição de Probabilidades para os melhores modelos encontrados para cada sensor, tanto para TSS quanto para TSI.....	59
Figura 4.13 Relação TSI/TSS.....	61
Figura 4.14 Relação do aumento do comprimento de onda com a acurácia dos modelos empíricos logarítmicos de TSS para as campanhas.....	64
Figura 4.15 Relação do aumento do comprimento de onda com a acurácia dos modelos empíricos logarítmicos de TSI para as campanhas.....	65
Figura 4.16 Razão TSI/TSS para Curuai e Monte Alegre	66

Figura 4.17 Variação dos valores de <i>slope</i> obtidos pela simulação de Monte Carlo (n = 10000) para os modelos de TSS em relação aos vários conjuntos de dados utilizados.	68
Figura 5.1 Comparação dos valores de MAPE (%) obtidos para o algoritmo NC e para os algoritmos empíricos (EMP) desenvolvidos no Capítulo 4 para as faixas espectrais do sensor MSI. O p-valor no título de cada figura demonstra a probabilidade do p-valor ser maior que 0.05, conforme descrito na Seção 4.2.2.	76
Figura 5.2 Dispersão dos pontos (n = 93) para os modelos de TSS obtidos através do algoritmo NC calibrados com os dados <i>in-situ</i> (pontos vermelhos) e com os coeficientes propostos por Nechad et al. (2010) (pontos pretos).	78
Figura 5.3 Dispersão dos pontos de TSS e modelagem para os algoritmos empíricos (EMP) e pelo algoritmo NC (NC) para as faixas do MSI.	84
Figura 5.4 Variação do coeficiente A^p e C^p do algoritmo NC em relação aos valores calibrados <i>in-situ</i> e o original publicado por Nechad et al. (2010) para os comprimentos de onda centrais dos sensores OLI, WFI e MSI.	85
Figura 5.5 Valores de MAPE (%) e R^2 para a variação do coeficiente A^p para a faixa $\rho_{w,MB4}$, $\rho_{w,MB5}$ e $\rho_{w,MB7}$ para valores entre 1 e 2000 de A^p e para variações no coeficiente C^p entre 0.2 a 0.5.	89
Figura 6.1 Localização das estações amostrais e datas em que foram realizadas as coletas em Curuai para a campanha de agosto de 2017.	94
Figura 6.2 Resultados da correção atmosférica e correção do <i>glint</i> avaliados com relação à dados de R_{rs} obtidos <i>in-situ</i>	99
Figura 6.3 Resultados da correção atmosférica e correção do <i>glint</i> avaliados com relação à dados de R_{rs} obtidos <i>in-situ</i>	100

Caixa superior à esquerda se refere ao comprimento de onda central das faixas do WFI (em nm) enquanto que valores de R^2 e MAPE (%) na caixa inferior à direita são relativos a todos os dados.....	100
Figura 6.4 Dispersão dos dados de TSS e TSI para o algoritmo empírico $\ln(R_{rs,OB3_6S_deglint})$ utilizando a correção atmosférica pelo 6S.	103
Figura 6.5 Dispersão dos dados de TSS e TSI para o algoritmo empírico $\ln(R_{rs,MB5_6S_deglint})$ utilizando a correção atmosférica pelo 6S.	106
Figura 6.6 Dispersão dos dados de TSS e TSI para o algoritmo empírico $\ln(R_{rs,WB4_6S})$ utilizando a correção atmosférica pelo 6S.	109
Figura 6.7 Dispersão dos dados de TSS e TSI estimados através do algoritmo NC para os sensores OLI (pontos em preto), MSI (pontos em vermelho) e WFI (pontos em verde) em relação aos valores de TSS e TSI <i>in-situ</i>	112
Figura 6.8 Mapas de TSS obtidos pelos sensores MSI, OLI e WFI através dos algoritmos empíricos que apresentaram os melhores resultados.....	114
Figura 6.9 Mapas de TSI obtidos pelos sensores MSI, OLI e WFI através dos algoritmos empíricos que apresentaram os melhores resultados.....	115
Figura 6.10 Comparação entre os métodos de correção atmosférica para o sensor OLI.....	117
Figura 6.11 Comparação entre os métodos de correção atmosférica para o sensor MSI.	120
Figura 6.12 Variação da concentração de TSS e de TSI em cinco áreas para os modelos empíricos gerados para as imagens OLI, MSI e WFI. As caixas na parte inferior representam a função de distribuição de probabilidade para os algoritmos de TSS e de TSI.....	125
Figura 7.1 Dispersão entre os valores de TSS estimados pelo OLI e MSI através dos algoritmos empíricos que utilizam a faixa do verde (B3), vermelho (B4), IVP (B5 OLI e B8 MSI) e red-edge (B5 MSI).....	133

Figura 7.2 Dispersão entre os valores de TSS estimados pelo OLI e WFI através dos algoritmos empíricos que utilizam a faixa do verde (B3), vermelho (B4), IVP (B5).....	135
Figura 7.3 Dispersão entre os valores de TSS estimados pelo OLI e MSI através do algoritmo NC para as faixas do verde (B3), vermelho (B4), IVP (B5 OLI e B8 MSI) e red-edge (B5 MSI)	137
Figura 7.4 Dispersão entre os valores de TSS estimados pelo OLI e WFI através do algoritmo NC para as faixas do verde (B3), vermelho (B4) e IVP (B5)	139
Figura 7.5 Mapa da diferença absoluta entre as estimativas de TSS derivadas dos sensores OLI, WFI e MSI e perfil com os valores de diferença entre os valores de TSS estimados pelo OLI, WFI e MSI.....	141

LISTA DE TABELAS

	<u>Pág.</u>
Tabela 3.1 Valores médios, mínimos, máximos e desvio padrão das concentrações de TSS, TSI, TSO e Chl-a para cada campanha realizada e número de amostras obtido para cada campanha.....	27
Tabela 3.2 Faixas espectrais dos sensores OLI, WFI e MSI. SNR = Relação Sinal Ruído.....	31
Tabela 4.1 Tipos de equações utilizadas para os algoritmos empíricos.	34
Tabela 4.2 Conjunto de dados utilizados neste trabalho.....	35
Tabela 4.3 Resultados da simulação de Monte Carlo para o conjunto completo.....	40
Tabela 4.4 Análise estatística dos componentes opticamente ativos por lagos.....	46
Tabela 4.5 Coeficiente de variação (CV, em %) calculado a partir da incerteza expandida (95% de confiança) para o intercepto das regressões utilizando os modelos logarítmicos para as faixas espectrais do WFI, OLI e MSI.	50
Tabela 4.6 Coeficiente de variação (CV, em %) calculado a partir da incerteza expandida (95% de confiança) para a inclinação das regressões utilizando os modelos logarítmicos para as faixas espectrais do WFI, OLI e MSI.	51
Tabela 4.7 Estatísticas das faixas espectrais com FRE próximas utilizadas na Figura 4.11.	58
Tabela 5.1 Valores de moda para o MAPE (%), R^2 e RMSE (mgL^{-1}) obtidos através da simulação de Monte Carlo (95% de confiança) para os algoritmos NC.	75
Tabela 5.2 Valores dos coeficientes A^p , C^p e B^p calibrados através da simulação Monte Carlo a partir dos dados de ρ_w para os sensores OLI, WFI e MSI, tanto para TSS quanto para TSI.....	77
Tabela 5.3 Coeficiente de variação (%) do modelo NC para os parâmetros A^p , B^p , C^p para os algoritmos de TSS e de TSI	79

Tabela 5.4 Valores de MAPE (%), R^2 e RMSE (mgL^{-1}) para os algoritmos de TSS para o modelo NC aplicado nos dados separados por campanhas.....	80
Tabela 5.5 Valores de MAPE (%), R^2 e RMSE (mgL^{-1}) para os algoritmos de TSI para o modelo NC aplicado nos dados separados por campanhas.....	81
Tabela 5.6 Valores de MAPE (%), R^2 e RMSE (mgL^{-1}) para os algoritmos de TSS e TSI para o modelo NC aplicado nos dados separados pelos lagos de Curuai e Monte Alegre.....	82
Tabela 6.1 Valores de MAPE (%), R^2 , RMSE (mgL^{-1}) e <i>Slope</i> para os algoritmos empíricos de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor OLI (n = 16).	101
Tabela 6.2 Valores de MAPE, R^2 , RMSE e <i>Slope</i> para os algoritmos empíricos obtidos através do conjunto de dados completo, apenas para a campanha de agosto de 2017 e apenas para o Lago de Curuai para o sensor OLI.	102
Tabela 6.3 Valores de MAPE (%), R^2 , RMSE (mgL^{-1}) e <i>Slope</i> para os algoritmos de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor MSI (n = 14).	104
Tabela 6.4 Valores de MAPE, R^2 , RMSE e <i>Slope</i> para os algoritmos empíricos obtidos através do conjunto de dados completo, apenas para a campanha de agosto de 2017 e apenas para o Lago de Curuai para o sensor MSI.....	105
Tabela 6.5 Valores de MAPE (%), R^2 , RMSE (mgL^{-1}) e <i>Slope</i> para os algoritmos empíricos com transformação logarítmica de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor WFI (n = 11). ...	106
Tabela 6.6 Valores de MAPE, R^2 , RMSE e <i>Slope</i> para os algoritmos empíricos obtidos através do conjunto de dados completo,	

apenas para a campanha de agosto de 2017 e apenas para o Lago de Curuai para o sensor WFI.....	108
Tabela 6.7 Valores de MAPE (%), R^2 , RMSE (mgL^{-1}) e <i>Slope</i> para os algoritmos NC de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor OLI (n = 16).	110
Tabela 6.8 Valores de MAPE (%), R^2 , RMSE (mgL^{-1}) e <i>Slope</i> para os algoritmos NC de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor MSI (n = 14).	111
Tabela 6.9 Valores de MAPE (%), R^2 , RMSE (mgL^{-1}) e <i>Slope</i> para o algoritmo NC com de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor WFI (n = 11).	112
Tabela 7.1 Data e horário de passagem dos sensores utilizados	129
Tabela 7.2 Valores de diferença mediana (MD), MAPE, R^2 , intercepto e slope para a comparação dos dados de TSS e TSI obtidos pelo OLI e pelo MSI.....	132
Tabela 7.3 Valores de diferença mediana (MD), R^2 , intercepto e slope para a comparação dos dados de TSS e TSI obtidos pelo OLI e pelo WFI	134
Tabela 7.4 Valores de diferença mediana (MD), R^2 , intercepto e <i>slope</i> para a comparação dos dados de TSS e TSI obtidos pelo OLI e pelo MSI	136
Tabela 7.5 Valores de diferença mediana (MD), R^2 , intercepto e <i>slope</i> para a comparação dos dados de TSS e TSI obtidos pelo OLI e pelo WFI	138

LISTA DE SIGLAS E ABREVIATURAS

6S	<i>Second Simulation Of The Satellite Signal In The Solar Spectrum</i>
AOP	<i>Apparent Optical Properties</i>
CDOM	Material Orgânico Colorido Dissolvido
COA	Componentes Opticamente Ativos
Chl-a	Clorofila-a
CV	Coeficiente de Variação
FDP	Função de Distribuição de Probabilidades
FRE	Função de Resposta Espectral
FITO	Fitoplancton
IOP	<i>Inherent Optical Propriets</i>
IVP	Infravermelho Próximo
HLS	<i>Harmonized Landsat Sentinel</i>
LaSRC	<i>Land Surface Reflectance Code</i>
LGC	Lago Grande do Curuai
MAPE	<i>Mean Absolute Percentage Error</i>
MD	<i>Median Difference</i>
MDC	Modelo com Dados Completos
MSI	<i>MultiSpectral Instrument</i>
NAIP	Material Particulado Não Algal Inorgânico
NAOP	Material Particulado Não Algal Orgânico
NC	Algoritmo Nechad
NDWI	<i>Normalized Difference Water Index</i>
NTU	Unidades Nefelométricas de Turbidez
OLI	<i>Operational Land Imager</i>

PSD	<i>Particle Size Distribution</i>
REM	Radiação Eletromagnética
RMSE	<i>Root Mean Squared Error</i> . (mgL ⁻¹)
S	Material em Suspensão Total, (mg L ⁻¹)
SBAF	<i>Spectral Band Adjustment Factor</i>
SSC	Concentração de Sedimentos em Suspensão, (mg L ⁻¹)
SNR	<i>Signal-to-Noise Ratio</i>
TM	Thematic Mapper
TSI	Total de Sólidos Inorgânicos em Suspensão, (mg L ⁻¹)
TSM	Material Total em suspensão, (mg L ⁻¹)
TSO	Total de Sólidos Orgânicos em Suspensão, (mg L ⁻¹)
TSS	Total de Sólidos em suspensão, (mg L ⁻¹)
VSF	Função de Espalhamento Volumétrico
WFI	<i>Wide Field Imager</i>

LISTA DE SÍMBOLOS

A	Absortância
$a(\lambda)$	Coefficiente de Absorção (m^{-1})
$a_{cdom}(\lambda)$	Coefficiente de Absorção do CDOM (m^{-1})
$a_{naop}(\lambda)$	Coefficiente De Absorção de Material Não Algal Orgânico (m^{-1})
$a_{naip}(\lambda)$	Coefficiente de Absorção do Material Não Algal Inorgânico (m^{-1})
$a_w(\lambda)$	Coefficiente de Absorção da água pura (m^{-1})
B	Escaterância
$b(\lambda)$	Coefficiente de espalhamento (m^{-1})
$b_b(\lambda)$	Coefficiente de Retroespalhamento (m^{-1})
$b_{bp}(\lambda)$	Coefficiente de Retroespalhamento do material particulado
b_{bp}^*	Coefficiente de Retroespalhamento Específico (m^2g^{-1})
$b_p(\lambda)$	Coefficiente de espalhamento do material particulado
$b_{naop}(\lambda)$	Coefficiente de Retroespalhamento do Material Não Algal Orgânico (m^{-1})
$b_{naip}(\lambda)$	Coefficiente de Retroespalhamento do Material Não Algal Inorgânico (m^{-1})
$b_{phy}(\lambda)$	Coefficiente de Retroespalhamento do Fitoplancton (m^{-1})
$\beta(\Psi, \lambda)$	Função de Espalhamento Volumétrico ($m^{-1} sr^{-1}$)
Ed	Irradiância Descendente ($W m^{-2}$)
Kd	Coefficiente de Atenuação (m^{-1})
L_{ATM}	Radiância da Atmosfera (Wm^2sr^{-1})
L_{SUP}	Radiância da Interface Ar-Água (Wm^2sr^{-1})
L_{SKY}	Radiância do Céu (Wm^2sr^{-1})

L_T	Radiância Captada pelo sensor em campo (Wm^2sr^{-1})
L_{TOA}	Radiância No Topo da Atmosfera (Wm^2sr^{-1})
L_U	Radiância Ascendente (Wm^2sr^{-1})
L_W	Radiância da água (Wm^2sr^{-1})
ρ	Refletância Interface Ar-Água
ρ_w	Refletância da água
R^2	Coefficiente de Determinação
R_{rs}	Refletancia de Sensoriamento Remoto de Superfície (sr^{-1})
$R_{rs,sim_{Bi}}$	Refletância de Sensoriamento Remoto simulada para a i-ésima faixa de cada sensor (sr^{-1})
$R_{rs,sat_{ac}}$	Refletância de Sensoriamento Remoto corrigida pelos efeitos da atmosfera (sr^{-1})
$R_{rs,sat_{ac}_{deglint}}$	Refletância de Sensoriamento Remoto corrigida pelos efeitos da atmosfera e de glint (sr^{-1})
r_{rs}	Refletância de Sensoriamento Remoto De Sub-superfície (sr^{-1})
S_{rs}	Refletância do Céu
T	Transmitância
T_{rs}	Refletância Da Água + Interface Ar-Água
t_{sup}	Transmitância da interface ar-água
t_w	Trasmitância da água
Φ_i	Fluxo Radiante Espectral Incidente
Φ_a	Fluxo Radiante Espectral Absorvido
Φ_s	Fluxo Radiante Espectral Espalhado
Φ_t	Fluxo Radiante Espectral Transmitido
σ	Desvio Padrão
μ	Média

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
1.1 Objetivo.....	4
1.2 Objetivos específicos.....	5
1.3 Estrutura do trabalho	5
2 FUNDAMENTAÇÃO TEÓRICA	7
2.1 As planícies de inundação do baixo amazonas e a origem dos sedimentos	7
2.2 Medidas <i>in-situ</i> de sólidos em suspensão	10
2.3 Propriedades ópticas de águas naturais.....	11
2.3.1 Propriedades ópticas inerentes	12
2.3.2 Propriedades ópticas aparentes	18
2.4 Modelagem de sedimentos por sensoriamento remoto	21
2.5 Correção atmosférica.....	22
3 MATERIAIS	24
3.1 Área de estudo	24
3.2 Dados limnológicos.....	26
3.3 Dados radiométricos	28
4 CALIBRAÇÃO DE MODELOS EMPÍRICOS UTILIZANDO R_{rs} <i>in-situ</i> SIMULADA PARA MULTI-SENSORES	32
4.1 Introdução.....	32
4.2 Métodos	34
4.2.1 Modelos empíricos	34
4.2.2 Calibração e validação dos modelos empíricos	35
4.3 Resultados.....	37
4.3.1 Modelos com Dados Completos (MDC)	37
4.3.2 Modelos separados por campanhas.....	41
4.3.3 Modelos separados por lagos	46
4.3.4 Variabilidade do <i>slope</i> e intercepto das regressões	50
4.4 Discussão	51

4.4.1	Variabilidade da concentração dos COAs e R_{rs} entre as campanhas e lagos	51
4.4.2	Acurácia da predição para os modelos utilizando dados de todas as campanhas	53
4.4.3	Variação da acurácia dos modelos de TSS e TSI ao longo das campanhas	60
4.4.4	Variação da acurácia para os lagos de Curuai e Monte Alegre.....	65
4.4.5	A incerteza nas estimativas dos coeficientes das regressões.....	67
4.5	Conclusões	68
5	CALIBRAÇÃO DE MODELOS SEMI-ANALÍTICOS UTILIZANDO R_{rs} <i>in-situ</i> SIMULADA PARA MULTI-SENSORES.....	70
5.1	Introdução.....	70
5.2	Métodos	71
5.2.1	O algoritmo de Nechad.....	71
5.2.2	Calibração e validação do modelo semi-analítico	73
5.3	Resultados.....	74
5.3.1	Calibração e validação – MDC	74
5.3.2	Variação dos resultados do algoritmo NC para os modelos separados por campanhas	79
5.3.3	Resultados do algoritmo NC aplicado aos lagos Curuai e Monte Alegre	82
5.4	Discussão	83
5.5	Conclusões	90
6	ESTIMATIVA DE TSS E TSI POR SATÉLITE	91
6.1	Introdução.....	91
6.2	Materiais e métodos.....	93
6.2.1	Dados orbitais.....	93
6.2.2	Correção atmosférica e de glint.....	94
6.2.3	Validação da correção atmosférica e de glint e dos algoritmos empíricos e semi-analíticos	96
6.3	Resultados.....	96
6.3.1	Correção atmosférica e de glint.....	96

6.3.2	Aplicação dos algoritmos empíricos de TSS e de TSI nas imagens.....	101
6.3.3	Aplicação dos modelos semi-analíticos baseados nas imagens ...	109
6.3.4	Espacialização das estimativas.....	112
6.4	Discussões.....	116
6.4.1	Resultado das correções atmosféricas e de glint.....	116
6.4.2	Aplicações dos modelos empíricos e semi-analíticos e espacialização.....	121
6.5	Conclusões.....	126
7	COMPARAÇÃO DAS ESTIMATIVAS DE TSS E TSI UTILIZANDO MULTISENORES.....	127
7.1	Introdução.....	127
7.2	Metodologia.....	129
7.2.1	Imagens utilizadas e correção atmosférica.....	129
7.2.2	Análise estatística.....	130
7.3	Resultados.....	131
7.3.1	Varição dos resultados de TSS e TSI obtidos através dos algoritmos empíricos.....	131
7.3.2	Varição dos resultados de TSS e TSI obtidos através do algoritmo de Nechad.....	135
7.4	Discussões.....	139
7.5	Conclusões.....	141
8	CONSIDERAÇÕES FINAIS.....	143
	REFERÊNCIAS BIBLIOGRÁFICAS.....	145

1 INTRODUÇÃO

As planícies de inundação da bacia amazônica, principalmente aquelas associadas aos rios de águas brancas (SIOLI, 1951) como o Rio Solimões/Amazonas e Madeira, possuem grande importância para os processos biogeoquímicos, tanto locais como globais, uma vez que estes são responsáveis pela quase totalidade dos sedimentos em suspensão transportados dos Andes para o Atlântico (MEADE, 1985, 1994; MERTES; SMITH; ADAMS, 1993). Particularmente, a planície de inundação do Baixo Amazonas é de grande interesse para a compreensão da dinâmica das trocas desses sedimentos, visto que ela se inicia após a confluência entre o Rio Madeira e o Rio Solimões, recebendo todo o aporte de sedimentos proveniente dos Andes que ainda não foram retidos nas planícies do médio e alto Amazonas (DUNNE et al., 1998a) sendo esta dinâmica controlada por fatores naturais/hidrológicos e antropogênicos.

Os fatores hidrológicos são os maiores responsáveis pelo aporte de sedimentos para as planícies de inundação, o que ocorre principalmente em épocas de cheias, pelo extravasamento da água pelas margens e diques (*overbank flow*) (DUNNE et al., 1998a; RUDORFF; DUNNE; MELACK, 2018). Deste total, parte é drenada pela planície e estima-se que cerca de 80% permanece na planície pela sedimentação e construção da topografia da várzea (MERTES; DUNNE; MARTINELLI, 1996). No entanto, esta deposição é temporária (BOURGOIN et al., 2007) porque há fluxo de sedimentos entre a planície de inundação e o Rio Amazonas, principalmente em épocas de vazante (BOURGOIN et al., 2007; MEADE, 1994; RUDORFF; DUNNE; MELACK, 2018). Além dos efeitos naturais, fatores antropogênicos, sobretudo relacionados à mudança no uso e cobertura da terra, como a remoção da floresta inundável para agricultura (RENÓ et al., 2011; RENÓ; NOVO; ESCADA, 2016), ocupação das planícies por pecuária (CASTELLO et al., 2013; SHEIKH; MERRY; MCGRATH, 2006) e criação de reservatórios na bacia

Amazônica (FORSBERG et al., 2017) também podem afetar a produção de sedimentos nesta região (MEADE, 1994).

Entretanto, a quantificação da concentração de sedimentos pelas técnicas tradicionais é onerosa, pois requer missões de coleta de amostras de água para posterior processamento em laboratório, o que demanda tempo, limitando a disponibilidade imediata da informação em casos emergenciais. Além disto, estas amostragens são geralmente pontuais, o que torna sua representatividade espacial limitada tendo em vista o custo envolvido no aumento do esforço amostral para a ampliação de sua área de abrangência. Neste sentido, torna-se fundamental o desenvolvimento de metodologias que possam, com confiabilidade, eficiência, baixo custo e maior representatividade espaço-temporal, estimar as concentrações de TSS (Total de Sólidos em Suspensão) e TSI (Total de Sólidos Inorgânicos em Suspensão) em águas interiores. Assim, o Sensoriamento Remoto (SR) orbital surge como uma alternativa de grande valia para este tipo de caracterização, já que permite maior cobertura espacial e temporal.

Os métodos de sensoriamento remoto dos ambientes aquáticos baseiam-se na interação entre a radiação eletromagnética (REM) no espectro do visível e do infravermelho próximo (IVP) e seus componentes opticamente ativos (COAs – Água, Fitoplâncton, Material Colorido Dissolvido – CDOM (*Colored Dissolved Organic Matter*) e material particulado). O variação nas propriedades físicas (e.g. concentração, índice de refração) das partículas presentes na água provoca uma mudança em suas propriedades ópticas inerentes (IOPs, da sigla em inglês *Inherent Optical Properties*) e aparentes (AOPs, da sigla em inglês *Apparent Optical Properties*), tornando possível modelar matematicamente a relação entre as IOPs ou AOPs, com a concentração de TSS e TSI. Dados de sensores remotos, como o *Operational Land Imager* (OLI), a bordo do satélite Landsat 8, o *MultiSpectral Instrument* (MSI), a bordo dos satélites Sentinel 2A e 2B e o *Wide Field Imager* (WFI), a bordo do satélite CBERS-4, podem ser utilizados para esta estimativa, permitindo que se obtenham mapas de TSS e TSI em larga escala. Para a obtenção da relação entre dados de reflectância de sensoriamento remoto (R_{rs}) obtidos por estes sensores e os de TSS e TSI,

diversas técnicas matemáticas e estatísticas podem ser aplicadas para esta estimativa de sedimentos por sensoriamento remoto.

Diversos tipos de algoritmos são propostos na literatura, principalmente relacionando a refletância de sensoriamento remoto (R_{rs}) com a concentração de TSS e TSI. Destas, destacam-se a modelagem empírica e a modelagem semi-analítica. Comumente, a modelagem empírica se baseia em uma faixa espectral ou operação aritmética (e.g. razão de bandas, transformação logarítmica, entre outras) para definir uma relação com a concentração de TSS e TSI (DOXARAN; CHERUKURU; LAVENDER, 2005; MONTANHER et al., 2014; NOVOA et al., 2017). No entanto, o aumento da concentração de TSS e TSI, provoca uma saturação nos valores de R_{rs} na faixa do visível (KNAEPS et al., 2015), que apresenta resultados mais satisfatórios quando as concentrações de TSS e TSI estão mais baixas (geralmente abaixo de 50 mgL^{-1}) (GIARDINO et al., 2017). Desse modo, em regiões com alta concentração de sedimentos ($\sim 150\text{-}750 \text{ mgL}^{-1}$), é necessária a utilização de comprimentos de onda maiores, como infravermelho próximo e, em casos de concentrações muito altas, faixas do infravermelho médio (GIARDINO et al., 2017; KNAEPS et al., 2015). Alguns trabalhos na literatura relatam a aplicação de algoritmos empíricos para estimativa de da concentração de sedimentos em suspensão através de sensoriamento remoto ao longo de rios da bacia Amazônica (ESPINOZA VILLAR et al., 2013, 2016; FASSONI-ANDRADE; PAIVA, 2019; MONTANHER et al., 2014; YEPEZ et al., 2018). Entretanto, poucos trabalhos se baseiam em um amplo conjunto de dados de R_{rs} *in-situ* para calibrar algoritmos de estimativa de sedimentos para diferentes sensores, principalmente de média resolução espacial (LOBO et al., 2012).

Um dos grandes desafios do sensoriamento remoto para estimativa de TSS e TSI nos últimos anos tem sido a utilização de vários sensores em conjunto (constelações virtuais) para ampliar a resolução temporal, com uma grande vantagem principalmente em locais muito afetados pela cobertura de nuvens como a região Amazônica (ASNER, 2001; MARTINS et al., 2018a). A utilização concomitante dos sensores OLI, MSI e WFI pode aumentar a frequência de aquisição nesta região para menos que 3 dias. Além disto, a modelagem dos

efeitos atmosféricos e de glint (reflexão do sol e do céu na interface ar-água) e suas técnicas de correção não são únicas e são muito dependentes do local avaliado, do tipo de sensor utilizado e das condições ambientais de aquisição dos dados (HARMEL et al., 2018; MARTINS et al., 2017).

Deste modo, o conhecimento da concentração de sedimentos nas planícies de inundação é importante para a avaliação dos impactos da mudança do uso e cobertura da terra na planície (LOBO; COSTA; NOVO, 2015; RENÓ; NOVO; ESCADA, 2016) e das mudanças climáticas (BARICHIVICH et al., 2018; SORRIBAS et al., 2016) sobre a variabilidade das trocas de sedimentos para a planície, bem como para estimativas mais precisas de seu balanço de carbono, visto que representam uma grande fração do total de sedimentos em suspensão (TSS) presentes nas áreas alagáveis (HESS et al., 2015; JUNK et al., 2011), as quais são umas das maiores fontes de emissão natural de carbono para a atmosfera (BATTIN et al., 2009), como o CH₄ e o CO₂ (BARTLETT; HARRISS, 1993; MOREIRA-TURCQ et al., 2004; RICHEY et al., 2002; SAWAKUCHI et al., 2017). Como fluxos de TSS tem papel relevante sobre os processos biogeoquímicos e sobre a biodiversidade da planície de inundação, sua dinâmica de troca tem sido objeto de estudo por diversos autores (BARBOSA, 2005; BARBOSA et al., 2010; BONNET et al., 2008; BOURGOIN et al., 2007; DUNNE et al., 1998a; RUDORFF; DUNNE; MELACK, 2018; ZOCATELLI et al., 2013, 2016) tornando a quantificação de suas concentrações ao longo do tempo um importante indicador dos possíveis impactos climáticos e antropogênicos sobre os processos da várzea amazônica.

1.1 Objetivo

Este trabalho tem por objetivo estimar a concentração de TSS e de TSI na planície de inundação do baixo Amazonas através técnicas de sensoriamento remoto *in-situ* e sua aplicação em imagens de satélites de três diferentes sensores (OLI, MSI e WFI).

1.2 Objetivos específicos

- Calibração e validação de algoritmos empíricos para a estimativa de TSS e de TSI para a planície de inundação do baixo Amazonas através de dados de R_{rs} simuladas para as faixas espectrais dos sensores OLI, WFI e MSI;
- Calibração e validação de algoritmos semi-analíticos para a estimativa de TSS e de TSI para a planície de inundação do baixo Amazonas através de dados de R_{rs} simuladas para as faixas espectrais dos sensores OLI, WFI e MSI;
- Avaliação de técnicas de correção atmosférica e de glint aplicadas às cenas OLI, WFI e MSI e avaliação da acurácia dos algoritmos empíricos e semi-analíticos calibrados com os dados *in-situ* aplicados nas cenas OLI, WFI e MSI;
- Avaliação da convergência entre estimativas de TSS e TSI em uma comparação com dados de satélite do mesmo dia de passagem afim de avaliar a possibilidade da criação de constelações virtuais.

1.3 Estrutura do trabalho

Esta dissertação de mestrado foi organizada em oito diferentes capítulos:

Capítulo 1 - Introdução apresenta uma breve introdução sobre as características sedimentológicas dos rios da Amazônia, bem como técnicas de quantificação dos sedimentos por sensoriamento remoto. Além disto, apresenta a relevância desta pesquisa e identifica as lacunas no conhecimento que serão preenchidas a partir do alcance do objetivo geral e específico.

Capítulo 2 – Fundamentação teórica: apresenta o referencial teórico acerca da origem dos sedimentos na planície de inundação do Baixo Amazonas, quantificação de sedimentos *in-situ*, propriedades ópticas de águas naturais, modelagens de sedimentos por sensoriamento remoto e suas limitações bem como a importância da validação e convergência de dados entre diferentes sensores.

Capítulo 3 – Materiais: delinea os materiais utilizados que são comuns aos próximos capítulos: Área de estudo, obtenção das concentrações dos componentes opticamente ativos e os protocolos utilizados nas medidas radiométricas.

Capítulo 4 – Algoritmos empíricos: descreve a metodologia para a geração e validação de algoritmos empíricos para estimativas de TSS e de TSI utilizando dados de R_{rs} *in-situ* para os sensores OLI, WFI e MSI, bem como discute e avalia a variação dos resultados de acordo com cada algoritmo.

Capítulo 5 – Algoritmos semi-analíticos: detalha a metodologia para a geração e validação de algoritmos semi-analíticos para estimativas de TSS e de TSI utilizando dados de R_{rs} simulados para os sensores OLI, WFI e MSI, bem como discute e avalia a variação dos resultados de acordo com cada algoritmo.

Capítulo 6 – Correção atmosférica e de glint: delinea a validação de diferentes técnicas de correção atmosférica e de glint e sua influência na acurácia da predição de sedimentos na planície de inundação do Baixo Amazonas.

Capítulo 7 – Análise multi-sensor: avalia brevemente possibilidade da criação de constelações virtuais para estimativa de TSS e de TSI nas planícies de inundação do Baixo Amazonas através da comparação de dados obtidos no mesmo dia para os três sensores utilizados neste estudo.

Capítulo 8 – Síntese e conclusão geral: sintetiza as principais contribuições e resultados obtidos neste estudo em relação à estimativa de sedimentos através de sensoriamento remoto.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 As planícies de inundação do baixo Amazonas e a origem dos sedimentos

Desde a última metade do século XX até a atualidade diversos autores vem estudando a dinâmica de inundação, formação, origem e a variabilidade dos sedimentos nas águas do Rio Amazonas e em suas planícies de inundação (BARBOSA, 2005; BONNET et al., 2008; DUNNE et al., 1998a; GIBBS, 1967; MEADE, 1985, 1994; MERTES; SMITH; ADAMS, 1993; RICHEY et al., 1986; RUDORFF; DUNNE; MELACK, 2018; SIOLI, 1951). Estas planícies são formadas devido ao pulso de inundação que ocorre nas épocas de cheia em decorrência do aumento da precipitação na bacia hidrográfica amazônica e também devido ao derretimento do gelo nos andes (JUNK, 2013). O aumento da vazão no Rio Amazonas causa o extravasamento da água de seu canal para o interior da planície por meio da entrada da água em canais ou de forma difusa quando o nível da água supera a altura de suas margens e dos diques marginais durante os máximos de cheia (JUNK et al., 1989).

As planícies de inundação localizadas no baixo Amazonas são de particular importância para os ciclos biogeoquímicos que ocorrem em escalas regionais e globais visto que recebem todo o aporte de sedimento que é proveniente dos Andes através do Rio Madeira, que traz sedimentos dos Andes Bolivianos e do Rio Solimões, que traz sedimentos originários no Peru e que ainda não foram retidos nas planícies do médio Amazonas (MEADE, 1994). Estes dois Rios contribuem em cerca de 90-95% com o aporte de sedimentos para o Rio Amazonas, com uma contribuição parcialmente igualitária entre eles (MEADE, 1994).

Diversos fatores naturais e antropogênicos influenciam o aporte de sedimentos do Rio Amazonas para as planícies de inundação. O principal fator influenciador na dinâmica desta troca de sedimentos é a variação interanual da vazão em decorrência da variabilidade interanual da precipitação associada ao clima da Amazônia (MARENGO et al., 2001). A variabilidade interanual do

pulso de inundação está intimamente ligada às variações na composição e concentração de sedimentos nos lagos da planície (AFFONSO; BARBOSA; NOVO, 2011; BARBOSA et al., 2010; RUDORFF; DUNNE; MELACK, 2018).

O aumento da precipitação na bacia Amazônica no período chuvoso (dezembro – maio) acarreta o aumento do nível da água no Rio Amazonas e o aumento da concentração de sedimentos, devido à erosão provocada pela chuva nos Andes (MCCLAIN; NAIMAN, 2008) o que contribui para a alta produtividade das águas do Rio Amazonas e de suas planícies de inundação devido aos nutrientes advindos desta erosão (ALMEIDA et al., 2015; GAGNE-MAYNARD et al., 2017). Esta água com alta concentração de sedimentos entra nas planícies de inundação através do extravasamento de canais (*overbank flow*) e através de vários canais que ligam o Rio com a planície, o que contribui também para o aumento da carga orgânica, já que este fluxo passa pelas florestas alagadas e de Terra Firme e segue para a planície de inundação (MELACK et al., 2013; ZOCATELLI et al., 2013). Deste fluxo de entrada de sedimentos, estima-se que cerca de 80% permanece na planície devido aos processos de sedimentação e também para a construção da topografia da várzea na época de cheia (BOURGOIN et al., 2007; DUNNE et al., 1998a; LATRUBESSE; FRANZINELLI, 2002; MERTES; DUNNE; MARTINELLI, 1996; PARK; LATRUBESSE, 2017; RUDORFF; DUNNE; MELACK, 2018). Já quando o fluxo de entrada de água diminui, na época de vazante, há uma diminuição no nível de água e uma troca de sedimentos entre a planície e o Rio Amazonas acontece devido principalmente à ação de ventos que acarretam na resuspensão dos sedimentos de fundo (BOURGOIN et al., 2007; MEADE, 1994; RUDORFF; DUNNE; MELACK, 2018).

Estudos recentes relatam alterações no clima que parecem impactar o regime de chuvas na região, causando mudanças na vazão do Rio Amazonas as quais podem influenciar diretamente o aporte de sedimentos para a planície. Barichivich et al. (2018) relatam o aumento no número de eventos de cheia extrema em Manaus e em Óbidos no século XXI em comparação ao século XX (desde 1903), cuja origem está relacionada à anomalias positivas de temperatura no oceano Atlântico. Em relação às secas, Jiménez-Muñoz et al.

(2016) e Garcia et al. (2018) também relatam um aumento na frequência e intensidade destas secas, relacionadas principalmente ao fenômeno El-Niño.

Já a ação antropogênica na Bacia Amazônica também pode causar mudança no aporte de sedimentos, com destaque para a criação de reservatórios para geração de energia elétrica que tenderiam a reter sedimentos à montante e o desflorestamento das florestas inundáveis para a ampliação das atividades agrosilvipastoris, que tenderiam a reduzir o processo de sedimentação das várzeas. Com o aumento da demanda por energia elétrica no Brasil e nos países da bacia Amazônica (TUNDISI et al., 2014), está sendo planejada a construção de mais de 200 hidroelétricas nesta bacia (CASTELLO; MACEDO, 2016). Os impactos da construção destes reservatórios no transporte de sedimentos e na alteração dos pulsos de inundação na Amazônia são relatados por diversos autores (CASTELLO; MACEDO, 2016; FORSBERG et al., 2017; LATRUBESSE et al., 2017; MCCLAIN; NAIMAN, 2008; TUNDISI et al., 2014). Forsberg et al. (2017) avaliando o impacto de seis hidroelétricas a serem implantadas nos Andes apontam uma redução de 65, 51 e 23% no aporte de sedimentos, fósforo e nitrogênio para a Bacia Amazônica. Estes impactos alteram a produtividade nas planícies devido à menor quantidade de nutrientes dos sedimentos vindo dos Andes (ALMEIDA et al., 2015; TUNDISI et al., 2014). Latrubesse et al. (2017) também apontam alto impacto da construção de reservatórios na dinâmica de troca de sedimentos e em toda a ecologia da planície do Baixo Amazonas.

O desflorestamento na terra-firme causado pela agricultura e pecuária também causa impactos no aporte de sedimentos dentro da planície (CASTELLO et al., 2013; NEILL et al., 2001). A conversão de áreas de floresta para áreas de agricultura ou pastagem está associada ao aumento na quantidade de sedimentos transportados para o curso d'água devido ao aumento do escoamento superficial (FIQUEPRON; GARCIA; STENGER, 2013; TUNDISI; MATSUMURA-TUNDISI, 2008). Renó et al. (2011) avaliando o desmatamento na região entre Parintins (AM) e Almeirim (PA) na planície do baixo Amazonas entre os anos de 1975 – 2008 observaram uma redução na área de floresta de cerca de 47%. Esta remoção foi principalmente devido à agricultura da juta

(*Corchorus capsularis*), importante fator para o desflorestamento nesta região entre os anos de 1940-1990 (WINKLERPRINS, 2006) e também devido à criação de búfalos nas regiões da planície (RENÓ; NOVO; ESCADA, 2016; SHEIKH; MERRY; MCGRATH, 2006) a partir da década de 1990.

2.2 Medidas *in-situ* de sólidos em suspensão

Algumas técnicas gravimétricas de laboratório são utilizadas para avaliar a concentração de sólidos em suspensão presentes na água. Basicamente, duas metodologias diferentes podem ser empregadas. Estas duas metodologias se diferenciam em relação a amostra de água utilizada no momento da amostragem da água a ser passada pelo filtro.

Na metodologia proposta pelo Standard Methods - APHA (1999), uma alíquota de água é obtida através de amostragem previamente realizada (e.g. uma alíquota de 100 ml é retirada de uma amostra de 1 L). Esta alíquota é utilizada para passagem pelo filtro e obtenção do TSS através da pesagem do filtro. Já a metodologia proposta por WETZEL e LIKENS (2013) utiliza todo o volume de água da amostragem para passar pelo filtro e assim obter o valor da concentração de sólidos presentes na água. Segundo Guo (2006), a metodologia de APHA (1999) apresenta muitos erros ($R^2 < 0,38$ entre valores reais e estimados) para tamanho de partículas maiores que $250 \mu\text{m}^1$ devido à sedimentação destas partículas maiores pelo aumento de seu peso. Além disto, essas duas metodologias requerem laboratórios e equipamentos específicos para sua utilização.

Vê-se assim, que a obtenção dos valores de TSS e TSI através dos métodos gravimétricos demanda grandes custos, como mão de obra qualificada, reagentes, materiais e tempo. Ainda, condições desfavoráveis, como rios com alta vazão ou com fortes ventos, dificultam o acesso ao local e, conseqüentemente, à obtenção de amostras de água nestes pontos, além da

¹ É equivalente a “Areia Grossa”. Areia fina, silte e argila são menores que $250 \mu\text{m}$.

natureza pontual da amostragem. Ou seja, existe uma dificuldade em obter mapas regionais confiáveis, já que, para isto, seria necessária uma quantidade considerável de pontos, o que muitas vezes não é possível devido ao alto custo (KRÖGER; LAW, 2005; NOVO; STEFFEN; ZUCCARI FERNANDES BRAGA, 1991) .

Desta maneira, há demanda de metodologias que permitam, com eficiência e baixo custo, quantificar a concentração de TSS e TSI. Neste sentido, com o avanço, nas últimas décadas, do conhecimento da óptica hidrológica e das propriedades ópticas da água, um grande número de trabalhos tem sido desenvolvido visando relacioná-las as medidas de concentração de TSS e TSI. Estas metodologias baseiam-se na interação da radiação eletromagnética (REM) com os constituintes opticamente ativos (COA) presentes na água, e utilizam diversos tipos de equipamentos de campo e laboratório, como espectroradiômetros (NECHAD et al. 2010; NOVO; STEFFEN; ZUCCARI FERNANDES BRAGA, 1991) e espectrofotômetros de campo (ROESLER; BOSS, 2008; SANDER DE CARVALHO et al., 2015) para a obtenção de AOPs e IOPs. Estes equipamentos produzem, assim como os métodos gravimétricos, dados pontuais, porém, com uma velocidade maior que os métodos de laboratório.

2.3 Propriedades ópticas de águas naturais

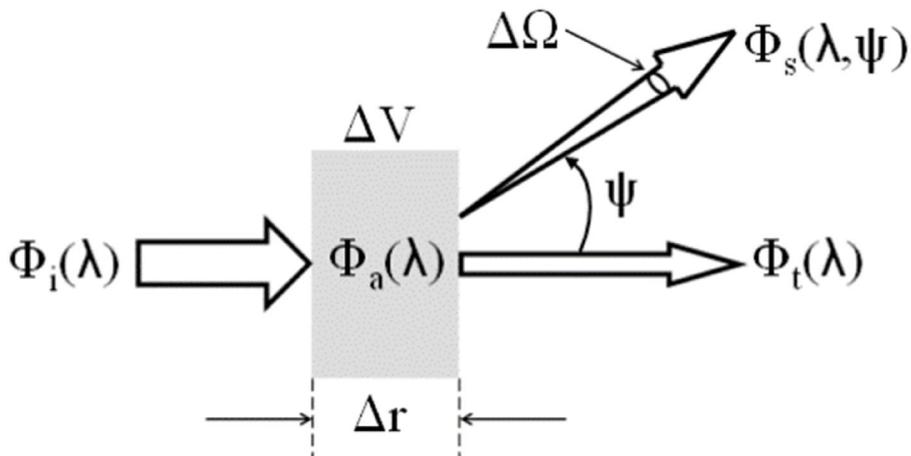
As águas naturais são compostas por uma combinação de materiais particulados e dissolvidos e, alguns destes, interagem com a radiação eletromagnética e alterando suas propriedades ópticas, as quais podem ser divididas em duas diferentes classes: Propriedades ópticas inerentes (IOP, da sigla em inglês), que são as propriedades da água que variam apenas com a mudança na composição do meio aquático, sem ser influenciada pelo campo de luz incidente; e as Propriedades Ópticas Aparentes (AOP, da sigla em inglês) que são dependentes do meio e também da estrutura geométrica de distribuição da luz incidente (MOBLEY, 1994).

As AOPs, contudo, devem apresentar características regulares e estáveis, que possam descrever o meio sem grande variação no tempo (KIRK, 2010; MOBLEY, 1994). Da conexão entre as AOPs e IOPs com os COAs provém a base do entendimento para a ciência da óptica hidrológica (MOBLEY, 1994).

2.3.1 Propriedades ópticas inerentes

Quando o fluxo radiante espectral (Φ_i) atravessa um meio com uma determinada espessura (Δr) e volume (Δv) estes fótons podem sofrer dois processos: podem ser absorvidos (Φ_a) ou espalhados (Φ_s) (KIRK, 2010; MOBLEY, 1994). As propriedades de espalhamento e absorção da REM em determinado comprimento de onda são dadas pela função de espalhamento volumétrico e pelo coeficiente de absorção (KIRK, 2010). O fluxo também pode não sofrer interferência e continuar na mesma direção. Este processo é chamado de transmitância (Φ_t). Na Figura 2.1 estes processos de transmissão, espalhamento e absorção estão representados.

Figura 2.1 Esquema para a definição das propriedades ópticas Inerentes.



Fonte: Mobley (1994).

A partir da Lei de Kirchhoff, pode-se deduzir o fluxo absorvido, transmitido e espalhado no meio (Equação 2.1).

$$A(\lambda) = \frac{\Phi_a}{\Phi_i} ; B(\lambda) = \frac{\Phi_s}{\Phi_i} ; T(\lambda) = \frac{\Phi_t}{\Phi_i} \quad (2.1)$$

Em que, $A(\lambda)$ representa a absorptância do meio, $B(\lambda)$ representa a escaterância e $T(\lambda)$ representa a transmitância. A relação entre a escaterância e a absorptância pela distância (Δr) define os coeficientes de absorção $a(\lambda)$ e de espalhamento $b(\lambda)$ para o meio (MOBLEY, 1994).

Se considerarmos que o meio é isotrópico (i.e. a influência da luz é a mesma em todas as direções) e a luz não polarizada, podemos considerar o espalhamento com simetria azimutal, ou seja, dependente apenas do ângulo de espalhamento Ψ , conforme a Figura 2.1. Assim, a função de espalhamento volumétrico (VSF) ($\beta(\Psi, \lambda)$) pode ser definida de acordo com a Equação 2.2 (MOBLEY, 1994; MOBLEY; BOSS; ROESLER, 2010).

$$\beta(\Psi, \lambda) = \lim_{\Delta V \rightarrow 0} \left(\frac{I_s(\Psi, \lambda)}{E_i(\lambda) \Delta V} \right) (\text{m}^{-1} \text{sr}^{-1}) \quad (2.2)$$

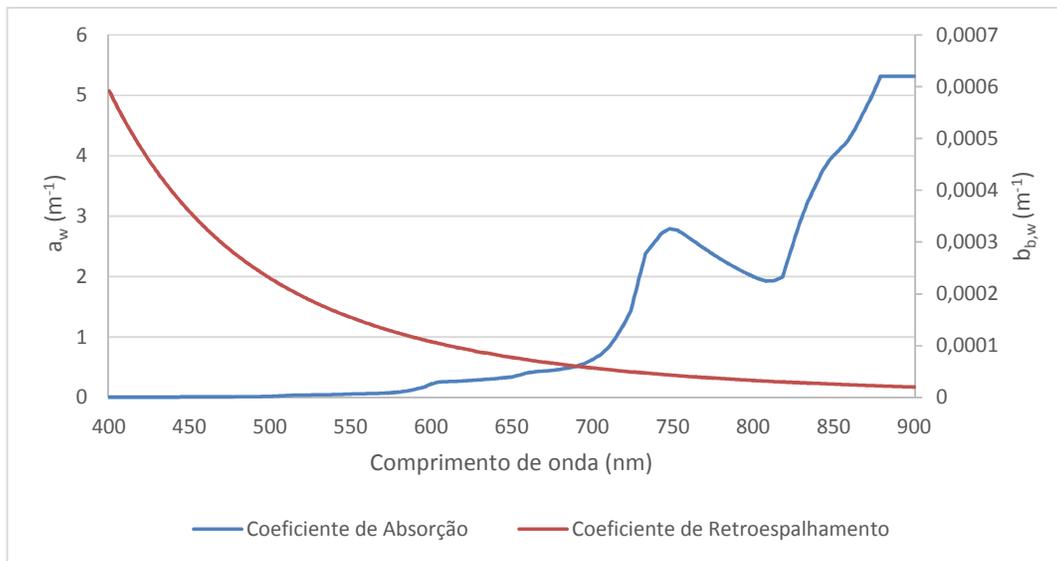
Sendo $I_s(\Psi, \lambda)$ a intensidade radiante (Wsr^{-1}) do espalhamento em um dado ângulo sólido na direção Ψ , $E_i(\lambda)$ a irradiância incidente (Wm^{-2}) e ΔV o volume iluminado pelos feixes.

Integrando $\beta(\Psi, \lambda)$ em todas as direções temos o coeficiente de espalhamento $b(\lambda)$ (Equação 2.3) e sua integração pode ser dividida no coeficiente de espalhamento frontal (bf, $0 < \Psi < \frac{\pi}{2}$) e no coeficiente de retroespalhamento (bb, $\frac{\pi}{2} < \Psi < \pi$).

$$b(\lambda) = 2\pi \int_0^\pi \beta(\Psi, \lambda) \text{sen } \Psi \, d\Psi \quad (2.3)$$

Diversos componentes controlam o modo como as águas naturais absorvem e espalham a REM. Os COAs são componentes que, ao interagir com a REM irão provocar uma alteração na mesma, seja por absorção ou espalhamento da REM. Inicialmente, o principal COA a se considerar é a própria água pura (i.e. água sem outros COAs) (Figura 2.2). Seu coeficiente de absorção exibe um comportamento complexo, aumentando com o comprimento de onda, com alguns picos de absorção, enquanto o coeficiente de espalhamento possui um comportamento exponencial, decrescendo com o comprimento de onda, devido ao espalhamento por flutuação de densidade² (JONASZ; FOURNIER, 2011; MOBLEY, 1994).

Figura 2.2 Coeficientes de absorção (m^{-1}) (POPE e FRY, 1997) (eixo à esquerda) e retroespalhamento (m^{-1}) (ZHANG; HU, 2009) (eixo à direita) da água pura.



Fonte: Adaptado de Pope e Fry (1997) e Zhang e Hu (2009).

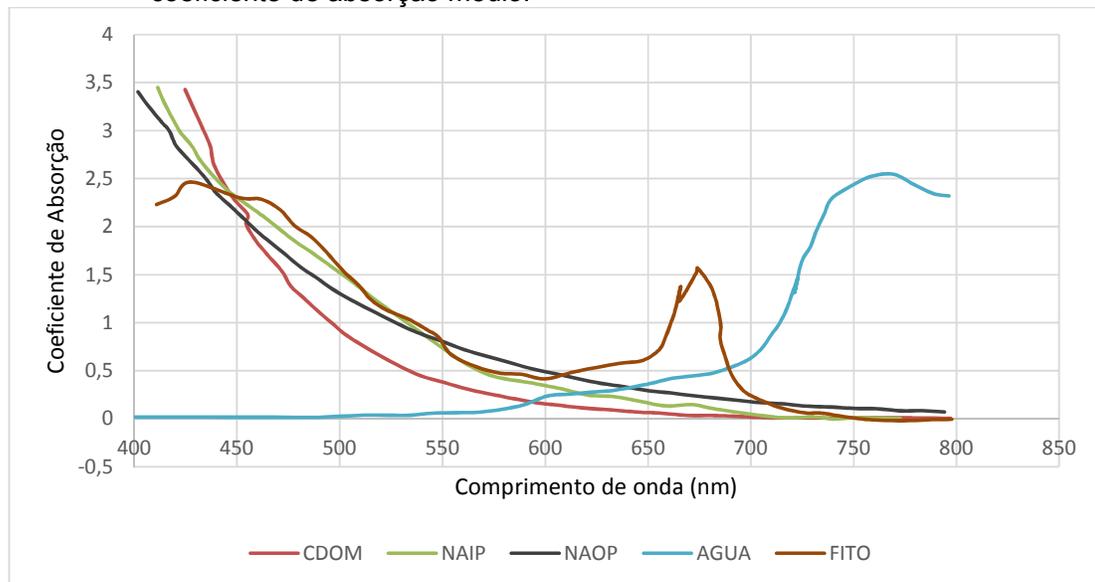
Outro importante COA é o material orgânico dissolvido (CDOM (*Colored Dissolved Organic Matter*, da sigla em inglês) ou *Geb/stoff*). O CDOM possui

² Também conhecido como espalhamento de Einstein–Smoluchowski.

alto coeficiente de absorção nas faixas do ultravioleta e do azul, com diminuição exponencial nos comprimentos de onda maiores. Este comportamento faz com que corpos d'água com altas concentrações de material orgânico dissolvido apresentem coloração amarelada (daí o nome, *Gelbstoff*, que em alemão significa substância amarela) (JONASZ; FOURNIER, 2011).

Finalmente, outro COA de extrema importância é o material em suspensão na água (JONASZ; FOURNIER, 2011). Os materiais em suspensão englobam tanto partículas orgânicas, como fitoplâncton, e partículas inorgânicas, como materiais advindos da erosão de rochas e solos (e.g. quartzo, areia, silte, argila). Estes COA's apresentam espectros de absorção (Figura 2.3) e espalhamento diferentes, o que permite a sua caracterização em determinadas condições.

Figura 2.3 Coeficientes de absorção característicos dos COA (m^{-1}) normalizados pelo coeficiente de absorção médio.



CDOM – Material Orgânico Colorido Dissolvido; NAIP – Partículas Não Algas Inorgânicas; NAOP – Partículas Não Algas Orgânicas; AGUA – Água Pura; FITO – Fitoplancton.

Fonte: Adaptado de Roesler e Boss (2008).

No tocante à absorção da REM, o CDOM e o material em suspensão (desconsiderando fitoplâncton) apresentam no visível um máximo de absorção nos comprimentos de onda mais curtos com decaimento que pode ser aproximado para uma função exponencial (ROESLER; BOSS, 2008). Já quando se considera constituintes com clorofila e outros pigmentos fotossintetizantes, estes apresentam comportamentos mais complexos, com picos de absorção da REM em diferentes faixas do visível (KIRK, 2010). O comportamento do coeficiente de absorção de águas naturais pode ser aproximado pela Equação 2.4 (STRAMSKI et al., 2004; ROESLER; BOSS, 2008), sendo $a_w(\lambda)$ o coeficiente de absorção da água pura, $a_{CDOM}(\lambda)$ o coeficiente de absorção pelo CDOM, $a_{phy}(\lambda)$ o coeficiente de absorção pelo fitoplâncton, $a_{NAP}(\lambda)$ o coeficiente de absorção por partículas não-algais.

$$a(\lambda) = a_w(\lambda) + a_{CDOM}(\lambda) + a_{NAP}(\lambda) + a_{phy}(\lambda) \quad (2.4)$$

Para o espalhamento da REM na água, as partículas em suspensão são as que contribuem majoritariamente, com as partículas inorgânicas contribuindo mais devido ao seu índice de refração (KOBAYASHI et al., 2010; ROESLER e BOSS, 2008) conforme Equação 2.5. Sua contribuição é muito mais alta do que a do espalhamento por flutuação de densidade e é dependente da concentração, índice de refração, diâmetro da partícula, absorção e forma das partículas (CLAVANO; BOSS; KARP-BOSS, 2007; KOBAYASHI et al., 2010; ROESLER; BOSS, 2008).

$$b(\lambda) = b_w(\lambda) + b_{NAOP}(\lambda) + b_{phy}(\lambda) + b_{NAIP}(\lambda) \quad (2.5)$$

Se as partículas forem consideradas pouco absorvedoras, como as inorgânicas, o espalhamento será pouco dependente do comprimento de onda.

O coeficiente de retroespalhamento das partículas inorgânicas, em geral, possui um comportamento exponencial, com o expoente sendo dependente da distribuição de tamanho de partículas e sua intensidade dependente da concentração e da parte real do índice de refração (JONASZ; FOURNIER, 2011; KOBAYASHI et al., 2010; MOBLEY; BOSS; ROESLER, 2010). Segundo Loisel et al. (2007), em ambientes em que a concentração de TSI é maior a razão entre o retroespalhamento por partículas (b_{bp}) e o espalhamento por partículas (b_p) é maior que em locais com maior concentração de clorofila devido ao alto índice de refração das partículas inorgânicas.

Segundo Roesler e Boss (2008), partículas inorgânicas irão espalhar mais REM do que partículas orgânicas, com valores que podem chegar a mais de dez vezes. Esse comportamento é devido à variação da parte real do índice de refração em relação à água, que possui valores de cerca de 1,02 para partículas orgânicas e 1,2 para partículas inorgânicas. Além do índice de refração, a distribuição de tamanho de partículas (PSD, da sigla em inglês *Particle Size Distribution*) também é de grande importância. A PSD descreve como a concentração das partículas varia com seu diâmetro (CLAVANO; BOSS; KARP-BOSS, 2007). Em escala logarítmica se aproximam de uma função Junge (ou hiperbólica) (JONASZ; FOURNIER, 2011; ROESLER; BOSS, 2008). Segundo Stramski et al. (2004) as partículas dentro do corpo d'água podem variar de 0,1 nm (partículas dissolvidas) até cerca de 1 cm (e.g. zooplâncton, partículas em suspensão agregadas). Quanto menor o expoente da função Junge da PSD menor o retroespalhamento pelas partículas (TWARDOWSKI et al., 2001). Se for considerada apenas a concentração, sem levar em conta a variação do índice de refração e do expoente da PSD, há o aumento do espalhamento com o aumento da concentração (ROESLER e BOSS, 2008, p. 27). Ainda, a variação no retroespalhamento detectado pelo sensor remoto é também dependente da forma das partículas (CLAVANO; BOSS; KARP-BOSS, 2007; JONASZ; FOURNIER, 2011) orientação da partículas em relação ao ângulo de incidência da luz (CLAVANO; BOSS; KARP-BOSS, 2007) e bolhas de ar (MOBLEY, 1994).

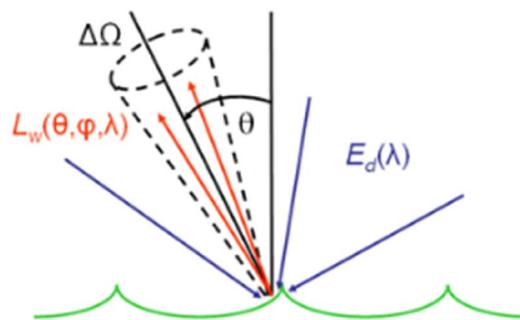
2.3.2 Propriedades ópticas aparentes

Um dos principais objetivos da óptica hidrológica é o conhecimento das propriedades de determinado corpo d'água (e.g. concentração de TSS). Idealmente, este conhecimento pode ser obtido utilizando-se as IOP's, como a VSF. Porém, devido à impossibilidade da mensuração direta das IOP's por satélite, é necessário utilizar as AOPs para descrever as propriedades do corpo d'água.

Uma AOP deve fornecer informações úteis para descrever o corpo d'água através de medições mais simples para caracterizar a interação da REM (MOBLEY, 1994) com o corpo d'água. Segundo Mobley (1994) as AOP's são definidas como: (1) as propriedades que dependem do meio (IOP's) e da estrutura geométrica de distribuição de radiância e (2) devem ter uma certa estabilidade em relação as variações ambientais (e.g. época do ano, nuvens) para serem úteis para descrever o corpo d'água.

Dentre as AOPs existentes, destaca-se principalmente a Refletância de Sensoriamento Remoto (R_{rs}) (Figura 2.4), que é dada pela razão entre a Radiância da Água (L_w) pela Irradiância Descendente (E_d) (MOBLEY; BOSS; ROESLER, 2010).

Figura 2.4 Definição da refletância de sensoriamento remoto.



Fonte: Mobley, Boss e Roesler (2010).

A Equação 2.6 define a Refletância de Sensoriamento Remoto ($R_{rs}(\theta, \phi, \lambda)$), uma das principais AOP's utilizadas, em que θ e ϕ especificam as direções polares e azimutais, respectivamente (MOBLEY, 1999). Ainda, outras AOPs importantes para a óptica hidrológica são o coeficiente de atenuação difusa (K_d) e a razão de irradiâncias (R).

$$R_{rs}(\theta, \phi, \lambda) = \frac{L_w(\theta, \phi, \lambda)}{E_d(\lambda)} \text{ (sr}^{-1}\text{)} \quad (2.6)$$

Apesar de sua obtenção ser mais simples se comparada às IOP's, alguns passos são necessários para obter bons resultados. Primeiramente, como as medidas de R_{rs} são feitas acima da superfície da água, o sinal captado pelo sensor (L_T) é a soma da radiância da água (L_w) com a radiância do céu (*skylint*) e do sol (*sunglint*) refletidas pela superfície da água (L_{SKY}) (LEE et al., 2010). Deve-se então, corrigir os valores de L_T para se obter L_w . Segundo Lee et al. (2010), o valor de L_T é dado pela Equação 2.7.

$$L_T(\theta, \phi, \lambda) = L_w(\theta, \phi, \lambda) + \rho(\theta, \phi) L_{SKY}(\theta', \phi, \lambda) \quad (2.7)$$

Em que $L_{SKY}(\theta', \phi, \lambda)$ é a radiância do céu, com um ângulo de visada θ' ($180^\circ - \theta$) (LEE et al., 2010) e $\rho(\theta, \phi)$ é a refletância da interface ar-água, que reflete a radiância incidente do céu. Segundo Mobley (1999), um ângulo de visada de 40° e um ângulo azimutal de 135° são indicados para minimizar os valores de $\rho(\theta, \phi)$. Pode-se calcular a R_{rs} simplesmente dividindo a Equação 2.7 pela irradiância descendente (E_d). Rearranjando, resulta na Equação 2.8.

$$R_{rs} = \frac{L_t(\theta, \phi, \lambda) - \rho(\theta, \phi) L_{SKY}(\theta', \phi, \lambda)}{E_d} \quad (2.1)$$

Neste ponto, a correta estimativa do valor de $\rho(\theta, \phi)$ é de grande importância, porém também de grande dificuldade. Este valor é dependente de vários fatores, como as condições da superfície da água (e.g. ondas, ventos), geometria de visada do sensor e condições do céu. Segundo Mobley (1999), nas condições ideais de visada ($\theta = 40^\circ$ e $\phi = 135^\circ$) e velocidade do vento menor que 5 ms^{-1} , o valor de $\rho(\theta, \phi)$ pode ser aproximado para 0,028. Para outras condições ambientais e geométricas, o valor de $\rho(\theta, \phi)$ pode ser obtido através de Mobley (2015). Porém, nestas aproximações, não é considerada a dependência espectral do valor de $\rho(\theta, \phi)$. Lee et al. (2010) mostram que este valor pode diferir em até 8 vezes entre 400 a 800 nm, considerando a mesma medida, principalmente se a superfície da água não for plana.

A partir do conhecimento das propriedades ópticas inerentes é possível obter relações entre as AOPs, como por exemplo a obtenção dos valores de r_{rs} , que é a refletância de sensoriamento remoto de subsuperfície a partir da metodologia semi-analítica proposta na Equação 2.9 (GORDON; BROWN; JACOBS, 1975; GORDON et al., 1988).

$$r_{rs}(\lambda) = \frac{L_u(0^-, \lambda)}{E_d(0^-, \lambda)} = g1 \left(\frac{b_b(\lambda)}{a(\lambda) + b_b(\lambda)} \right) + g2 \left(\frac{b_b(\lambda)}{a(\lambda) + b_b(\lambda)} \right)^2 \quad (2.9)$$

Em que os parâmetros $g1$ e $g2$ são constantes geométricas e, segundo Lee et al. (1999), para águas turvas, os valores utilizados podem ser de 0,084 e 0,17, respectivamente. Segundo Lee et al. (2002), a r_{rs} pode ser convertida para a R_{rs} através da Equação 2.10.

$$r_{rs} = \frac{R_{rs}}{T + \gamma Q R_{rs}} \quad (2.10)$$

Em que $T = t_- t_+ / n^2$, sendo t_- a transmitância da radiância de dentro para fora da superfície da água e t_+ é a transmitância da radiância de fora para dentro da superfície da água. γ é o coeficiente de reflexão da interface ar-água e Q é a

razão entre a irradiância ascendente pela radiância ascendente abaixo da superfície da água. Estes valores, para águas opticamente profundas e um sensor com visada à nadir, podem ser aproximados para $T \sim 0,52$ e $\gamma Q \sim 1,7$.

Como a R_{rs} é diretamente proporcional ao coeficiente de retroespalhamento, os fatores que causam seu aumento irão também causar um aumento na R_{rs} . Assim, torna-se possível estimar a concentração dos COA's através de métodos de sensoriamento remoto orbital e em campo, com equipamentos que quantificam as AOP's.

2.4 Modelagem de sedimentos por sensoriamento remoto

Nas últimas décadas o monitoramento de TSS e TSI através de sensoriamento remoto vem aumentando em estudos sobre as propriedades dos corpos d'água e, bem como, para seu monitoramento (LEPOT; AUBIN; BERTRAND-KRAJEWSKI, 2013). Através da relação entre a REM refletida pelo corpo d'água pode-se inferir, por exemplo, a concentração de TSS e TSI. Para esta relação, três abordagens principais podem ser aplicadas para as diferentes plataformas existentes (orbital, aerotransportadas, campo ou laboratório): empírica, semi-analítica e analítica (NOVOA et al., 2017). A abordagem empírica baseia-se na relação estatística entre os dados ópticos e as concentrações dos COAs e, dependendo do modelo estatístico gerado, pode levar a alguns resultados espúrios, visto que, uma causalidade estatística não necessariamente significa uma relação causal (DEKKER, 1993; VIGEN, 2015). Ademais, se forem consideradas as informações sobre o comportamento espectral da corpo d'água e do COA a ser analisado, pode-se selecionar antes da aplicação da metodologia estatística, faixas espectrais que são condizentes com a variação que o COA irá provocar no espectro de refletância, por exemplo, levando assim, a resultados mais fisicamente consistentes (DEKKER, 1993; MONTANHER, 2013). Estes modelos necessitam de uma calibração regional e são dependentes da concentração de TSS e TSI (NOVOA et al., 2017). Já as abordagens semi-analíticas e analíticas são baseadas em simplificações das equações de transferência radiativa e propõe uma

abordagem e aplicação mais global (DOGLIOTTI et al., 2015; NECHAD et al., 2010; NOVOA et al., 2017), apesar de também necessitarem de parametrizações locais.

Para todas estas metodologias, ao utilizar dados provenientes de plataformas orbitais, é crucial a realização da correção atmosférica dos dados. A correta realização da correção atmosférica proporcionará a obtenção de valores de refletância de superfície ou de refletância de sensoriamento remoto consistentes, sendo isto um pré-requisito essencial para a quantificação de propriedades biogeoquímicas a partir da refletância de superfície, uma vez que são removidas as contribuições de espalhamento na atmosfera pelos aerossóis e gases, absorção por vapor d'água e outros gases opticamente ativos (VERMOTE et al., 1997). Além disso, deve-se considerar a contribuição da refletância difusa do céu refletida na interface ar-água e também da refletância direta também refletida pela interface ar-água no sinal captado pelo sensor. Este efeito deve ser considerado em ambas as plataformas (orbitais/aerotransportadas e campo) (HARMEL et al., 2018; KAY et al., 2009; LEE et al., 2010). Com estas duas correções aplicadas corretamente, pode-se ter uma redução na quantidade de erros nos dados finais.

2.5 Correção atmosférica

A correção atmosférica é um passo crucial ao utilizar dados provenientes de sensores orbitais. Isto ocorre devido à alta influência dos constituintes opticamente ativos presentes na atmosfera, que modificam o sinal de radiação refletido pelo alvo visto do espaço. Estas modificações são frutos de dois processos: Espalhamento molecular e por aerossóis e absorção pelos gases opticamente ativos, como ozônio, gás-carbônico e vapor d'água (VERMOTE et al., 1997). Assim, o sinal recebido pelo sensor, no topo da atmosfera (L_{TOA}), pode ser expresso pela Equação 2.11. Desconsiderando efeitos de adjacência e de fundo, temos que:

$$L_{TOA} = L_{atm} + L_{sup} * t_{sup} + L_w t_w \quad 2.11$$

Em que, L_{atm} é a contribuição da atmosfera no sinal recebido, L_{sup} é a contribuição da reflexão especular da interface ar-água e L_w é a radiância proveniente do corpo d'água. t_{sup} e t_w são as transmitâncias da radiância da interface ar-água e da água, pela atmosfera. Devido à complexidade da atmosfera na região Amazônica, influenciada pela alta cobertura de nuvens, concentração de vapor d'água e aerossóis (ASNER, 2001; MARTINS et al., 2017, 2018a), é de grande importância a correta quantificação da contribuição da atmosfera e da interface ar-água para a obtenção de valores coerentes de L_w .

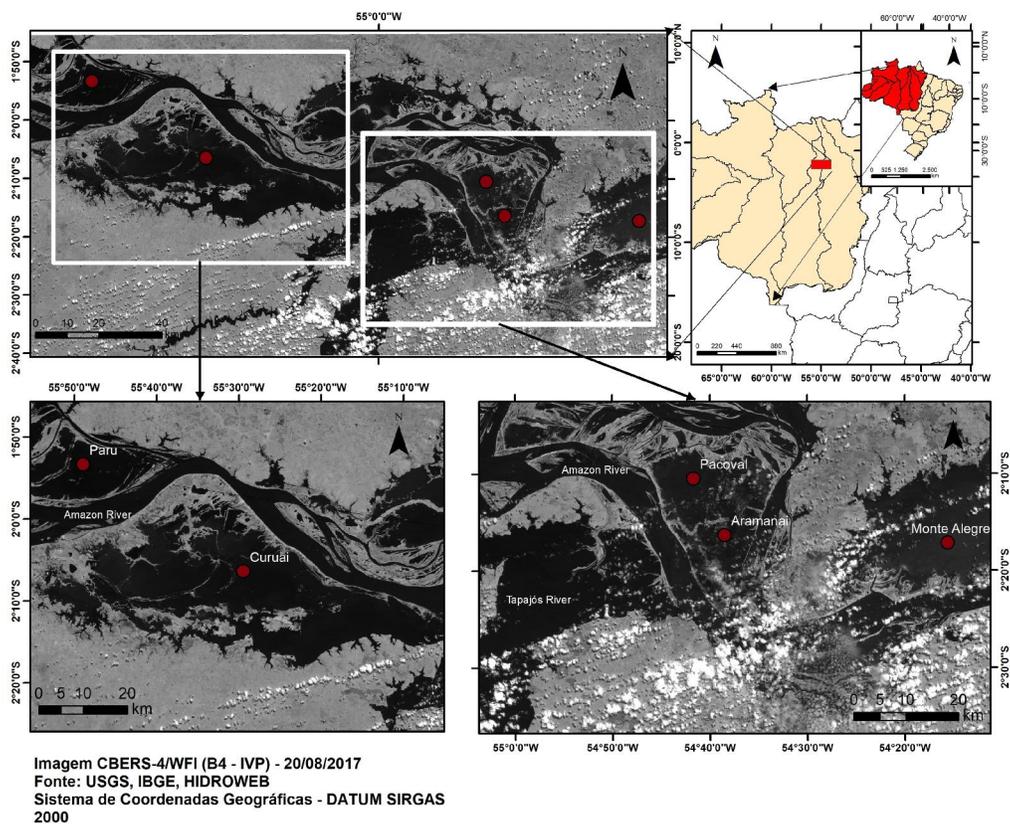
Diversos modelos são difundidos na literatura para a realização da correção atmosférica. Estes modelos podem ser divididos em *image-based*, em que a correção é aplicada com dados extraídos da própria imagem, (e.g. ACOLITE, DOS) (VANHELLEMONT; RUDDICK, 2014, 2015) e modelos físicos, que, através de dados auxiliares, como concentração de aerossóis, ozônio e visibilidade, aplicam modelos de transferência radiativa para estimar a atenuação atmosférica no sinal recebido no topo da atmosfera. Exemplos destes modelos são o 6S (VERMOTE et al., 1997) e MODTRAN (BERK et al., 1987).

3 MATERIAIS

3.1 Área de estudo

A área de estudo deste trabalho compreende seis lagos da planície de inundação do Baixo Amazonas: Lago Grande Curuai, Lago Paru, Lago Pacoval, Lago Aramanai e Lago Monte Alegre e está localizada entre as cidades de Paritins (AM) a Oeste e Almerim (PA) a Leste (Figura 3.1). Esta planície é dominada por grandes lagos, formando sistemas de planícies locais cujo nome é associado ao lago menos afetado pela oscilação do nível da água.

Figura 3.1 Localização geográfica da área de estudo.



Fonte: Produção do autor.

Esta região está sujeita a extrema fragmentação da floresta inundável que nos últimos 40 anos (1975 – 2008) foi reduzida em cerca de 56% (RENÓ et al., 2011), sendo ocupada primeiro pela agricultura da juta e posteriormente pela pecuária bubalina e bovina (RENÓ et al. 2016; SHEIKH et al. 2006). Dentre estes sistemas lago-planície, destaca-se o sistema da Planície de Inundação do Lago Grande de Curuai (LGC), localizado a cerca de 900 km à montante da foz do Rio Amazonas. Este complexo sistema contém mais de 30 lagos interconectados ligados ao Amazonas por canais permanentes e temporários e apresenta uma variação de área de espelho d'água de 600 km² a 3500 km² entre os períodos de seca e cheia, respectivamente (BARBOSA, 2005; BOURGOIN et al., 2007). No LGC a variabilidade hidrológica é explicada principalmente pelo fluxo do Rio Amazonas (70 – 90% da entrada de água no sistema) o que resulta em um tempo de residência hidráulica de cerca de três meses (BONNET et al., 2008).

Segundo Barbosa et al. (2010) a dinâmica hidrológica no LGC pode ser caracterizada por quatro períodos, relacionando o regime de cheia e seca local: Período 1) Época de enchimento, caracterizado pelo aumento no nível da água a taxas acima de 3,6 cm dia⁻¹, nos meses de Janeiro e Fevereiro; Período 2) Época de cheia, com um aumento na profundidade à valores menores que 1,2 cm dia⁻¹, nos meses de Abril, Maio e Junho; Período 3) Época de diminuição do nível d'água, à taxas maiores que 3,6 cm dia⁻¹, nos meses de Agosto, Setembro e Outubro; Período 4) Águas baixas, com pouca variação no nível da água, nos meses de Outubro e Novembro. A diminuição da profundidade no mês de novembro favorece a ressuspensão de sedimentos no lago pela ação do vento, com uma cota em relação ao fundo de aproximadamente 100 cm (BARBOSA, 2005; RUDORFF et al.2014; SANDER DE CARVALHO, 2016), favorecendo o aumento da concentração de TSS na coluna d'água nesta época (BARBOSA, 2005; BARBOSA et al., 2010).

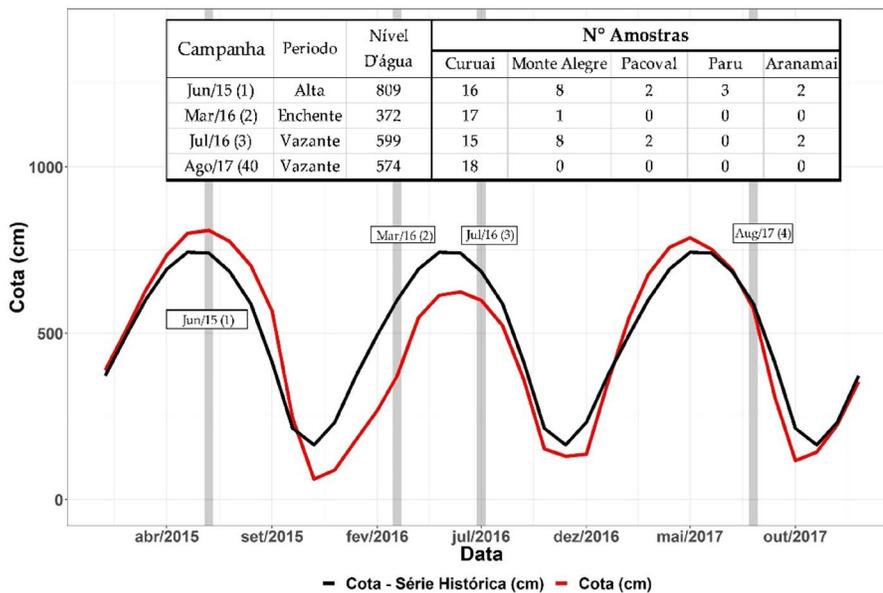
Além da planície do LGC, destaca-se o sistema de planície do Lago Paru, majoritariamente influenciado pelo pulso de inundação do Rio Amazonas, mas menos impactado por ações antrópicas (KOUMROUYAN; SANTANA, 2008). Os sistemas de planície do Pacoval, Aramanai e Monte Alegre, contudo, são

influenciadas tanto pelo pulso de inundação do Amazonas quanto pelo do Rio Tapajós em algumas fases da hidrógrafa (COSTA et al., 1998).

3.2 Dados limnológicos

Os dados limnológicos utilizados neste estudo (TSS, TSI, TSO e Clorofila-a (Chl-a)) foram coletados em quatro campanhas de campo realizadas entre 2015 e 2017 (junho/2015, março/2016, julho/2016 e agosto/2017) com subsídio do projeto MAS-BNDES 1022114003005. A distribuição das amostragens de campo possibilitou a avaliação destes dados limnológicos em diferentes fases da hidrógrafa (Veja as datas em relação a fase da hidrógrafa na Figura 3.2).

Figura 3.2 Hidrógrafa para a estação fluviométrica de Óbidos (17050001) entre os anos de 2015- 2018 (linha vermelha) e série histórica (1968 - 2018) para a estação fluviométrica de Óbidos (linha preta).



A Tabela em destaque se refere ao número de amostras por cada lago.

Fonte: HidroWeb ANA (2019).

A quantificação do TSS, TSI e TSO foi realizada utilizando a metodologia proposta por Wetzel e Likens (2013), em que um volume conhecido de água foi

filtrado em um filtro de fibra de vidro Whatman GF/C (1,2 µm), previamente pesado. Após isto, o filtro foi seco à 60°C por 24 horas e pesado posteriormente para a determinação do total de sólidos em suspensão (TSS). Em seguida, o filtro foi colocado em um cadinho de porcelana e levado a mufla à 480°C por 1 hora. Após isto, o filtro é pesado e é determinada a concentração de sólidos inorgânicos totais (TSI). Por diferença entre o peso antes e depois da mufla, é obtido a concentração de sólidos orgânicos (TSO). Todos os pontos foram feitos em duplicata. A concentração de Chl-a foi determinada utilizando um filtro de fibra de vidro Whatman GF/F (0,7 µm), conforme Nush (NUSH, 1980), também feita em duplicata. Os valores de concentração de cada ponto amostral foram obtidos a partir da média simples das duplicatas.

Tabela 3.1 Valores médios, mínimos, máximos e desvio padrão das concentrações de TSS, TSI, TSO e Chl-a para cada campanha realizada e número de amostras obtido para cada campanha.

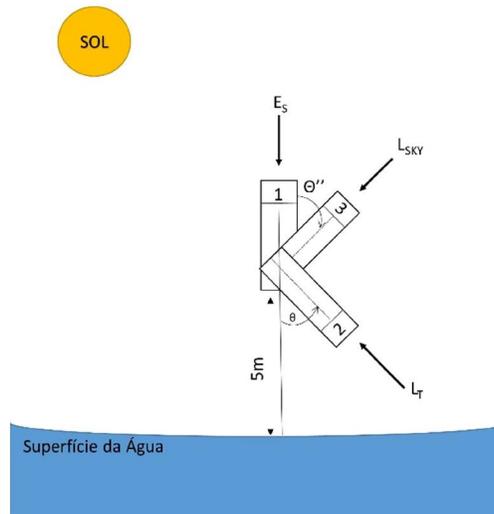
Campanha	Número de Amostras	Estatística	TSS	TSI	TSO	Chl-a	Média TSI/TSS (%)
			(mg L ⁻¹)	(mg L ⁻¹)	(mg L ⁻¹)	(µg L ⁻¹)	
Junho/2015	31	Média	16,76	10,08	6,7	3,23	55,93
		Mínimo	5,25	2	3,25	0,35	
		Máximo	33,2	27,6	12,75	8,59	
		Desvio Padrão	7,15	6,24	2,58	1,97	
Março/2016	18	Média	74,46	57,85	16,61	19,76	71,58
		Mínimo	20,5	10,5	10	0,66	
		Máximo	235,5	218,5	27	42,32	
		Desvio Padrão	51,16	49,06	4,82	12,75	
Julho/2016	27	Média	32,86	21,93	10,93	21,97	64,40
		Mínimo	17	6,86	3	5,21	
		Máximo	64,67	56,67	21,25	85,05	
		Desvio Padrão	11,93	11,8	5,44	20,89	
Agosto/2017	18	Média	17,7	11,12	6,59	31,11	59,12
		Mínimo	7	3,38	3,62	9,34	
		Máximo	43,5	33,75	12,12	67,85	
		Desvio Padrão	8,52	7,53	2,39	17,24	
Todas as Campanhas	94	Média	32,61	22,83	9,79	17,12	62,97
		Mínimo	5,25	2	3	0,35	
		Máximo	235,5	218,5	27	85,04	
		Desvio Padrão	31,84	28,64	5,5	17,83	

Fonte: Laboratório de Instrumentação em Sistemas Aquáticos – LabISA.

3.3 Dados radiométricos

As medidas radiométricas foram realizadas com três espectroradiômetros (TRIOS-RAMSES), intercalibrados, operando em comprimentos de onda de 350 a 950 nm. Cada instrumento mediu, respectivamente, a irradiância incidente na superfície $E_d(\lambda)$, a radiância emergente da água acima da superfície $L_T(\lambda)$ em um ângulo nadiral de 45° e um ângulo azimutal de 135° e a radiância do céu $L_{sky}(\lambda)$, em um ângulo zenital de 45° e azimutal de 135° . Todos os sensores estavam posicionados a 5m da superfície da água, para reduzir a influência de sombras e reflexão da embarcação. Todas as medidas foram realizadas simultaneamente conforme protocolos propostos por Mobley (1999), conforme já descrito na Seção 2.3.1 (Figura 3.3).

Figura 3.3 Configuração geométrica da obtenção dos dados radiométricos (E_s , L_{sky} , L_t).



Fonte: Produção do autor.

Para o cálculo da R_{rs} foi utilizada a Equação 3.1. Os valores de $\rho(\theta, \phi)$ foram obtidos a partir de Mobley (2015) utilizando dados de vento obtidos no momento da coleta dos pontos através de um anemômetro.

$$R_{rs}(\theta, \phi, \lambda) = \frac{L_T(\theta, \phi, \lambda)}{E_d(\lambda)} - \frac{\rho(\theta, \phi) L_{SKY}(\theta, \phi, \lambda)}{E_d(\lambda)} \quad (\text{sr}^{-1}) \quad (3.1)$$

Para cada ponto amostral, aproximadamente 150 espectros foram medidos durante 30 minutos (1 espectro a cada 10s). Inicialmente, todos os espectros para cada ponto amostral foram avaliados para a remoção de *outliers* através de inspeção visual. Em seguida, o espectro selecionado para representar o ponto amostral foi escolhido com base no menor valor do somatório da diferença entre a mediana de todos os espectros medidos e cada um dos 150 espectros após a remoção dos outliers (Equação 3.2).

$$\text{Dif } Rrs_i = \sum_{\lambda=400}^{900} |Rrs_{i, \lambda} - Rrs_{\text{Median}, \lambda}| \quad (3.2)$$

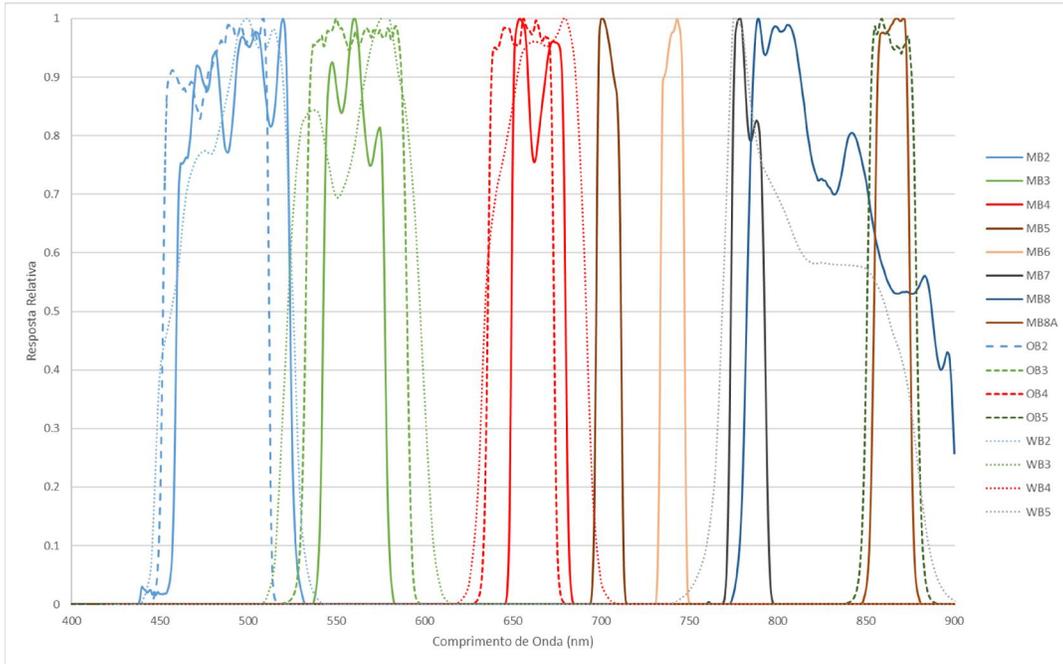
Em que $\text{Dif } Rrs_i$ é a diferença entre a mediana e o valor de R_{rs} em cada comprimento de onda para a medida i , $R_{rs, i, \lambda}$ é a R_{rs} no ponto i e no comprimento de onda λ e $Rrs_{\text{Mediana}, \lambda}$ é a mediana da R_{rs} para cada ponto e comprimento de onda, em determinado comprimento de onda. Após a seleção do espectro representativo do ponto amostral, os valores de R_{rs} originalmente com resolução espectral de ~ 3.3 nm foram interpolados de 1 em 1 nm e utilizados para simular a R_{rs} nas bandas espectrais dos sensores OLI / Landsat 8, MSI / Sentinel 2A e WFI / CBERS-4 com base nas funções de resposta espectral de cada um deles (AGENCY, 2017; BARSÍ et al., 2014; PINTO et al., 2016) conforme Equação 3.3.

$$Rrs_{sim}(B_i) = \frac{\int_{\lambda_n}^{\lambda_m} SRF(\lambda) * R_{rs_m(\lambda)} d\lambda}{\int_{\lambda_n}^{\lambda_m} SRF(\lambda) d\lambda} \quad (3.3)$$

Em que $Rrs_{sim_sensor}(B_i)$ é a Rrs simulada para a i -ésima faixa espectral dos sensores OLI, MSI e WFI, $SRF(\lambda)$ é a função de resposta espectral do sensor

em um comprimento de onda específico e a $R_{rs_m(\lambda)}$ é a R_{rs} medida em campo para o intervalo $n \rightarrow m$ que compõe a faixa espectral de cada sensor.

Figura 3.4 Função de resposta espectral para os sensores OLI, MSI e WFI.



Fonte: Barsi et al. (2014), Ehipanio (2009) e Pahlevan et al. (2017b).

Os valores de R_{rs} simulados serão chamados, neste texto, R_{rs,sim_OBi} (e.g. R_{rs,sim_OB2} para a banda 2 do OLI) para o sensor OLI, R_{rs,sim_MBi} (e.g. R_{rs,sim_MB2} para a banda 2 do MSI) para o sensor MSI e R_{rs,sim_WBi} (e.g. R_{rs,sim_WB2} para a banda 2 do WFI), para o sensor WFI. A Tabela 3.2 apresenta as faixas espectrais das bandas dos sensores OLI, WFI e MSI, bem como sua resolução espacial, radiométrica, tempo de revista, swath e relação-sinal-ruído (SNR).

Tabela 3.2 Faixas espectrais dos sensores OLI, WFI e MSI. SNR = Relação Sinal Ruído.

Sensor /Bandas	Faixa Espectral (nm)	Resolução Espacial (m)	Resolução Radiométrica (bits)	Tempo de revisita (dias)	Swath (km)	SNR
OLI/B1	435 - 451	30	16	16	185	238
OLI/B2	452 - 512	30	16	16	185	364
OLI/B3	533 - 590	30	16	16	185	302
OLI/B4	636 - 673	30	16	16	185	227
OLI/B5	851 - 879	30	16	16	185	204
OLI/B6	1566 – 1651	30	16	16	185	265
OLI/B7	2107 – 2294	30	16	16	185	334
WFI/B13	450 - 520	64	10	5	866	48
WFI/B14	520 - 590	64	10	5	866	48
WFI/B15	630 - 690	64	10	5	866	47
WFI/B16	770 - 890	64	10	5	866	47
MSI/B2	447,6 - 545,6	10	12	5	290	439
MSI/B3	537,5 - 582,5	10	12	5	290	102
MSI/B4	645,5 - 683,5	10	12	5	290	79
MSI/B5	694,4 - 713,4	20	12	5	290	45
MSI/B6	731,2 - 749,2	20	12	5	290	45
MSI/B7	768,5 - 796,5	20	12	5	290	34
MSI/B8	762,6 - 907,6	10	12	5	290	26
MSI/B8-a	848,3 - 881,3	20	12	5	290	20
MSI/B9	932 - 958	60	12	5	290	16

Fonte: Barsi et al. (2014), Ehipanio (2009) e Pahlevan et al. (2017b).

4 CALIBRAÇÃO DE MODELOS EMPÍRICOS UTILIZANDO R_{RS} *IN-SITU* SIMULADA PARA MULTI-SENSORES

4.1 Introdução

O conhecimento da dinâmica de troca de sedimentos entre o Rio Amazonas e suas planícies de inundação é de extrema importância na avaliação dos impactos que as mudanças climáticas e antropogênicas causam nestes ambientes (RUDORFF; DUNNE; MELACK, 2018). O transporte e a deposição de sedimentos na planície é influenciado por estes fatores, como a duração de cheias e secas, desflorestamento e criação de reservatórios (BARBOSA et al., 2010; BOURGOIN et al., 2007; CASTELLO et al., 2013; FORSBERG et al., 2017; RENÓ et al., 2011).

Na região do Baixo Amazonas, estações de monitoramento como as do ORE-HYBAM, em Óbidos, por exemplo, fornecem dados de TSS para o Rio Amazonas através de medições *in-situ* complementadas com estimativas de satélite através de modelos empíricos de refletância derivadas do sensor MODIS (MARTINEZ et al., 2009). Entretanto, não existe um monitoramento contínuo *in-situ* e nem por satélite de TSS e TSI nas planícies do baixo Amazonas, o que limita a avaliação do impacto desses fatores sobre a dinâmica as trocas de sedimento entre os lagos de planície e o Rio.

A partir dos anos 80, vários algoritmos empíricos foram estabelecidos e testados por diversos autores em águas interiores para a estimativa de TSS e TSI (DOXARAN; CHERUKURU; LAVENDER, 2005; KHORRAM, 1985; KNAEPS et al., 2015; MATTHEWS, 2011; MONTANHER et al., 2014; MUNDAY; ALFÖLDI, 1979; OLMANSON; BREZONIK; BAUER, 2013; WANG et al., 2017). Em geral, a Refletância de Sensoriamento Remoto (R_{rs}) apresenta alta correlação com o TSS e TSI nas faixas espectrais do verde, vermelho e infravermelho próximo (NIR) (MATTHEWS, 2011), embora esta relação dependa da proporção e tipos de constituintes opticamente ativos (COAs) na coluna d'água (GIARDINO et al., 2017; NECHAD et al. 2010). Para concentrações até $\sim 50 \text{ mgL}^{-1}$, (GIARDINO et al., 2017) algoritmos que utilizam

as faixas do verde e do vermelho apresentam melhores resultados (GIARDINO et al., 2017; LOBO; COSTA; NOVO, 2015; MATTHEWS, 2011; NOVOA et al., 2017). Com o aumento da concentração, devido à saturação das faixas espectrais do visível, as bandas localizadas no infravermelho próximo (IVP) tornam-se mais adequadas (DOXARAN et al., 2002; ESPINOZA VILLAR et al., 2013; NECHAD et al. 2010; PINET et al., 2017; YEPEZ et al., 2018).

Além disso, algoritmos que utilizam razões de banda são também amplamente utilizados devido à menor sensibilidade a variações de propriedades físicas das partículas presentes no corpo d'água, como o índice de refração e a distribuição de tamanho de partículas (PSD) (PINET et al., 2017). Entretanto, devido à complexidade óptica e variabilidade dos COAs nas planícies de inundação da Amazônia (AFFONSO; BARBOSA; NOVO, 2011; BARBOSA et al., 2010; JORGE et al., 2017; SANDER DE CARVALHO et al., 2015), torna-se um desafio o desenvolvimento de algoritmos universais (i.e. um modelo aplicável a todas as fases da hidrógrafa e até mesmo para todos os lagos) para a estimativa de TSS e TSI.

Alguns trabalhos relatam a aplicação de imagens de baixa resolução espacial (MODIS) para a estimativa de material em suspensão em rios da Bacia Amazônica e na planície de inundação de Curuai (ESPINOZA VILLAR et al., 2013; KILHAM; ROBERTS, 2011; MARTINEZ et al., 2009; PARK; LATRUBESSE, 2014). Entretanto, devido à resolução espacial (250 m nas faixas do vermelho e IVP e 500 m nas outras faixas) há uma dificuldade na observação dos pequenos canais que ligam o Rio Amazonas às planícies de inundação além de limitar a observação de plumas de sedimentos. Além disto, a heterogeneidade espacial intra-pixel é menos capturada em sensores com resolução espacial maiores (MOSES et al., 2009).

Buscando superar as limitações de resolução espacial, a utilização de satélites como o Landsat-8-OLI, Sentinel-2A e 2B-MSI e CBERS-4-WFI amplia a oportunidade de quantificar as concentrações de sedimentos em águas interiores para uma maior amplitude de tamanho de lagos e rios (BERNARDO et al., 2017; CABALLERO; STEINMETZ; NAVARRO, 2018; CLAVERIE et al.,

2018; LIU et al., 2017; LOBO; COSTA; NOVO, 2015; MONTANHER et al., 2014; PETERSON et al., 2018; YEPEZ et al., 2018).

Neste sentido, este capítulo tem como objetivo descrever o processo de calibração e validação de algoritmos empíricos de TSS e de TSI para os sensores OLI, WFI e MSI e seu resultado. Para isso os dados disponíveis foram organizados em três conjuntos diferentes de dados de entrada: Conjunto Completo, incluindo todos os dados radiométricos disponíveis; Conjunto por Campanha: incluindo dados obtidos em cada uma das quatro diferentes campanhas (Veja Figura 3.2) e Conjunto por Lagos, utilizando todos os dados obtidos no Lago Grande do Curuai e no Lago Monte Alegre (veja Figura 3.1 para localização).

4.2 Métodos

4.2.1 Modelos empíricos

Para este estudo, foram avaliados dois tipos de algoritmos empíricos (Tabela 4.1). Algoritmos de uma banda com transformação logarítmica e algoritmos de razões de banda.

Tabela 4.1 Tipos de equações utilizadas para os algoritmos empíricos.

Tipo de Algoritmo	Equação
Logarítmico	$\ln(Y) = a \cdot \ln(X) + b$
Razão de bandas	$Y = aRB^b$

Nas equações Y representa a concentração de TSS ou TSI e X representa a $R_{rs,sim}$ para as faixas espectrais dos sensores OLI, MSI e WFI. RB é a razão de bandas. a e b são os coeficientes da regressão.

Fonte: Produção do autor.

Foram avaliados modelos utilizando os valores de R_{rs} simulados (Veja a metodologia utilizada para a simulação na Seção 3.3) para todas as faixas espectrais do visível e NIR dos sensores OLI (e.g. $R_{rs,sim-OB2}$), MSI (e.g. $R_{rs,sim-$

R_{MB2}) e WFI (e.g. $R_{rs,sim-WB2}$) com transformação logarítmica. Razões de banda utilizando as faixas do azul ao NIR também foram avaliadas (DOXARAN et al., 2002; MARTINEZ et al., 2015). As razões de banda foram avaliadas por meio de regressões não lineares (DOXARAN et al., 2002; PINET et al., 2017) . Todas as análises estatísticas foram realizadas utilizando o software estatístico R versão 3.5.0 (R CORE TEAM, 2017).

4.2.2 Calibração e validação dos modelos empíricos

A validação dos algoritmos gerados para as estimativas de concentração de TSS e de TSI foi realizada utilizando simulação de Monte Carlo com 10.000 iterações, com 70% dos dados de R_{rs} *in-situ* usados para calibração e 30% para validação. Os seguintes conjuntos de dados foram utilizados: 1) Todos os dados referentes às campanhas e épocas (n = 94) que /serão chamados de Modelos Completos; 2) Por campanhas (Jun/15 n =31; Mar/16 n = 18; Jul/16 n = 27; Ago/17 n = 18), que serão chamados de Modelos por Campanhas; 3) Modelos em que os dados foram separados pelos dois maiores lagos em que o número de amostras de todas as campanhas era suficiente para as análises requeridas, (Curuai n = 66 e Monte Alegre n = 17) que serão chamados de Modelos por Lagos (Tabela 4.2). Os algoritmos foram separados nos diferentes conjuntos de dados afim de se avaliar se conjuntos mais homogêneos (e.g. mesmo lago ou campanha) poderiam apresentar maior acurácia.

Tabela 4.2 Conjunto de dados utilizados neste trabalho.

Conjunto de dados	Descrição	N
Completo	Todos os dados de R_{rs} e de concentração de sedimentos	94
Campanhas	Conjunto de dados separados por cada uma das quatro campanhas realizadas	Jun/15 =31; Mar/16 = 18; Jul/16 = 27; Ago/17 = 18
Lagos	Conjunto de dados separados para os Lagos Curuai e Monte Alegre	Curuai = 66; Monte Alegre = 17

Fonte: Produção do autor.

Para cada iteração da simulação de Monte Carlo, os valores de MAPE (*Mean Absolute Percentage Error* - Erro Médio Absoluto em Percentagem) (Equação 4.1), coeficiente de determinação (R^2) e RMSE (*Root Mean Square Error* – Raiz Quadrada do Erro Médio) (Equação 4.2) foram calculados.

$$MAPE = 100 * \frac{\sum_{i=1}^n \frac{|y_i - x_i|}{x_i}}{n} \quad (4.1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (x_i - y_i)^2}{n}} \quad (4.2)$$

O critério de seleção utilizado no processo de calibração baseou-se no cálculo da moda do MAPE gerada para cada modelo/sensor a partir dos 10.000 valores resultantes da simulação de Monte Carlo (AUGUSTO-SILVA et al., 2014). O MAPE foi escolhido por fornecer erros absolutos em percentagem e permitir a comparação de diferentes modelos desenvolvidos a partir de diferentes conjuntos de dados de entrada (MAKRIDAKIS, 1993). Os coeficientes do modelo calibrado (i.e. inclinação (slope) e intercepto) correspondem ao do modelo modal do MAPE.

Os resultados de validação obtidos para cada modelo baseado na $R_{rs,sim}$ foram comparados entre si (i.e. entre as bandas do sensor) e entre as faixas espectrais similares dos três sensores (i.e. faixas do verde, vermelho) através do teste não-paramétrico de soma de postos de Wilcoxon (WILCOXON, 1945). Entretanto, devido ao grande número de amostras (10.000) provenientes da simulação de Monte Carlo, realizou-se uma reamostragem ($n = 40$) aleatória 10.000 vezes (GANDY, 2009; LIN; LUCAS JR; SHMUELI, 2013; ZIMMERMAN, 2003). A partir de cada reamostragem, realizou-se o teste de Wilcoxon e o cálculo de 10.000 p-valores. Destes 10.000 valores foi calculado o número de vezes que o p-valor foi maior que 0.05. Se o p-valor é maior que 0.05 em 95% das iterações, a hipótese nula é aceita (CROWLEY, 1992).

A partir das 10.000 repetições da simulação de Monte Carlo foi também calculada a incerteza associada da inclinação e do intercepto das regressões

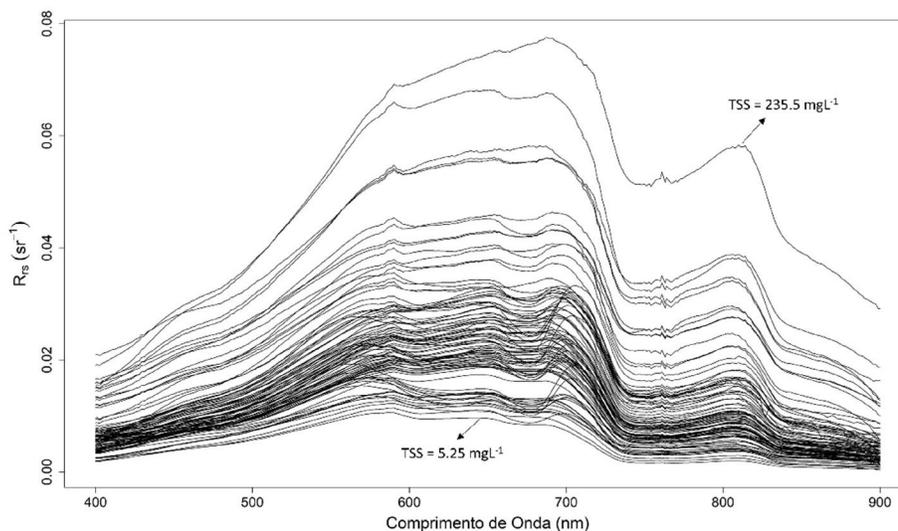
com transformações logarítmicas. As incertezas associadas as estimativas dos valores da inclinação e intercepto para os modelos de TSS e TSI com 95% de confiança e sua variação entre os três conjuntos de dados utilizados (Completo, Separados por campanhas e Separados por lagos). A incerteza associada ao conjunto de dados pode ser expressa com 68.27% de confiança, através do cálculo do desvio padrão (σ) pressupondo-se uma distribuição normal (ISO; OIML, 1995). O nível de confiança pode ser expandido multiplicando-se a incerteza expandida o valor de σ por um fator de abrangência (DAMASCENO; ANTONIO; DE OLIVEIRA, 2008) que para o nível de confiança adotado (95%) é igual a 1,965. A partir do cálculo da incerteza expandida, computou-se o coeficiente de variação (CV) para cada modelo e tipo de sedimento, já que o coeficiente de variação (σ / μ) pode ser utilizado como uma medida de incerteza de variáveis que possuem uma distribuição normal (GERGELY; ZIBORDI, 2014; HÅKANSON, 2000).

4.3 Resultados

4.3.1 Modelos com Dados Completos (MDC)

A variação da concentração dos COAs (veja os valores na Tabela 3.1) em todas as campanhas possibilitou uma avaliação através de um amplo conjunto de dados. Este conjunto de dados apresentou valores médios de 32,61 mgL⁻¹ e 22,83 mgL⁻¹ para TSS e TSI, respectivamente. Ainda, uma variabilidade nesta concentração é encontrada, com valores mínimos de 5,25 mgL⁻¹ e 2 mgL⁻¹ e máximos de 235,5 mgL⁻¹ e 218,5 mgL⁻¹ para TSS e TSI, respectivamente. A concentração de Chl-a apresentou uma variação entre 0,35 µgL⁻¹ e 85,04 µL⁻¹ e um valor médio de 17,2 µgL⁻¹. Esta variabilidade na concentração dos COAs provoca uma variabilidade nos espectros de R_{rs} obtidos (Figura 4.1), em que espectros característicos de águas com pouco sedimentos (Veja a seta com o menor valor de TSS na Figura 4.1) e característicos de altas concentrações (Veja a seta com o maior valor de TSS na Figura 4.1) são encontrados.

Figura 4.1 Espectros de R_{rs} *in-situ* para os dados de todas as campanhas. As setas indicam os pontos com maior e menor concentração de TSS.



Os mínimos de TSS também são os pontos com os valores mínimos de TSI (Veja na Tabela 3.1 os valores mínimos e máximos de TSI para todas as campanhas).

Fonte: Produção do autor.

Os resultados da simulação de Monte Carlo para os modelos empíricos (Tabela 4.3) baseados na $R_{rs,sim}$ para sensor OLI (R_{rs,sim_O}) apresentaram os melhores desempenhos com os modelos $\ln(R_{rs,sim_OB4})$ (MAPE = 24,8% para TSS e 31,93% para TSI) e valores de R^2 acima de 0,82 e RMSE < 11,72 mgL⁻¹. O teste de Wilcoxon (h_0 = Modelos possuem o mesmo valor de MAPE, h_1 = existe diferença significativa no valor de MAPE) apresentou p-valor significativo na comparação entre o modelo $\ln(R_{rs,sim_OB4})$ e os modelos com as outras faixas do OLI, indicando que com 95% de confiança os valores de MAPE obtidos para o modelo $\ln(R_{rs,sim_OB4})$ são menores. Os resultados para os modelos de razão de banda avaliados apresentaram bons valores de R^2 (> 0,81), porém, com maiores erros em relação a estimativa de TSS e TSI (MAPE > 41% e RMSE > 12,9 mgL⁻¹).

Para o sensor WFI menores erros para TSS na faixa do infravermelho próximo $\ln(R_{rs,sim_WB5})$ (MAPE = 24,41%, R^2 = 0,91, RMSE = 9,35 mgL⁻¹) foram

encontrados. Apesar da diferença nos valores de MAPE entre os modelos $\ln(R_{rs,sim_WB5})$ e $\ln(R_{rs,sim_WB4})$ ser de apenas 1%, o teste de Wilcoxon indicou maiores valores de MAPE para o modelo $\ln(R_{rs,sim_WB4})$ (p-valor < 0.05). Já para as estimativas de TSI, os melhores resultados foram obtidos para o modelo $\ln(R_{rs,sim_WB4})$ (p-valor < 0,05), com valores de MAPE = 31,93%, $R^2 = 0,82$ e RMSE = 10,85 mgL⁻¹.

Já para o MSI, os melhores resultados foram para o modelo $\ln(R_{rs,sim_MB5})$ (MAPE = 21,55% para TSS e 30,69% para TSI, com $R^2 > 0,86$ e RMSE < 9,5 mgL⁻¹). As outras faixas do infravermelho próximo do MSI também apresentaram bons resultados (MAPE < 25% para TSS, exceto para a banda 8A), entretanto, com valores de MAPE estatisticamente maiores que para o modelo que utiliza a banda 5 (p-valor < 0.05). As razões de banda para o MSI não apresentaram resultados tão satisfatórios (MAPE < 30%) quanto os resultados obtidos para os algoritmos com transformação logarítmica, tendo apresentado valores de MAPE acima de 32% para TSS e acima de 43% para as estimativas de TSI.

Quando observados os resultados para os três sensores vê-se que, nas faixas do visível, em que os três sensores possuem uma função de resposta espectral (FRE) equivalentes (Veja na Figura 3.4), os resultados são similares. Para os algoritmos de TSS na faixa espectral do verde, os valores de MAPE variaram entre 27,41% até 27,79% e os valores de R^2 foram de 0,79 para os três sensores. A comparação entre os valores obtidos de MAPE através do teste de Wilcoxon apresentou p-valor não significativo (> 0,05) na comparação entre os modelos gerados pelos três sensores na faixa do verde. Esta semelhança também ocorre na faixa do vermelho, apesar da diferença um pouco maior entre os valores de MAPE (24,81% até 25,67%) e R^2 variando entre 0,83-0,84, o teste de Wilcoxon também apresentou p-valor não significativo (> 0,05), indicando também a igualdade em relação aos modelos na faixa do vermelho.

Tabela 4.3 Resultados da simulação de Monte Carlo para o conjunto completo.

Sensor	Modelo	MAPE (%)		R ²		RMSE (mg L ⁻¹)	
		TSS	TSI	TSS	TSI	TSS	TSI
Landsat 8 - OLI	<i>ln (Rrs_sim_OB3)</i>	27,79	40,05	0,79	0,75	12,67	12,19
	<i>ln (Rrs_sim_OB4)</i>	24,81	31,93	0,83	0,82	11,72	10,85
	<i>ln (Rrs_sim_OB5)</i>	26,72	44,10	0,89	0,89	10,84	10,45
	<i>Rrs_sim_OB5/Rrs_sim_OB2</i>	35,67	62,94	0,89	0,90	14,73	13,37
	<i>Rrs_sim_OB5/Rrs_sim_OB3</i>	41,27	67,02	0,82	0,81	15,05	12,94
CBERS4 - WFI	<i>ln (Rrs_sim_WB3)</i>	27,46	41,12	0,79	0,78	12,81	16,64
	<i>ln (Rrs_sim_WB4)</i>	25,41	32,37	0,83	0,85	11,62	15,62
	<i>ln (Rrs_sim_WB5)</i>	24,41	38,86	0,91	0,94	9,35	14,87
	<i>Rrs_sim_WB5/Rrs_sim_WB2</i>	11,25	23,83	0,85	0,94	12,19	11,46
	<i>Rrs_sim_WB5/Rrs_sim_WB3</i>	28,96	42,03	0,87	0,89	18,37	25,27
Sentinel 2 - MSI	<i>ln (Rrs_sim_MB3)</i>	27,41	41,61	0,79	0,75	12,85	12,27
	<i>ln (Rrs_sim_MB4)</i>	25,67	32,20	0,84	0,83	11,64	10,72
	<i>ln (Rrs_sim_MB5)</i>	21,55	30,69	0,87	0,86	10,69	9,72
	<i>ln (Rrs_sim_MB6)</i>	24,15	37,02	0,91	0,91	9,46	9,21
	<i>ln (Rrs_sim_MB7)</i>	23,77	36,86	0,91	0,90	9,21	9,04
	<i>ln (Rrs_sim_MB8)</i>	24,86	39,61	0,91	0,91	9,44	9,25
	<i>ln (Rrs_sim_MB8A)</i>	30,15	48,13	0,89	0,89	10,75	10,29
	<i>Rrs_sim_MB5/Rrs_sim_MB2</i>	67,25	100,23	0,12	0,12	20,54	17,12
	<i>Rrs_sim_MB5/Rrs_sim_MB3</i>	41,43	54,31	0,37	0,38	20,72	34,37
	<i>Rrs_sim_MB6/Rrs_sim_MB2</i>	31,64	43,30	0,79	0,79	19,49	15,78
	<i>Rrs_sim_MB6/Rrs_sim_MB3</i>	32,91	45,69	0,88	0,89	12,70	11,60
	<i>Rrs_sim_MB7/Rrs_sim_MB2</i>	32,78	43,44	0,82	0,82	18,94	15,32
	<i>Rrs_sim_MB7/Rrs_sim_MB3</i>	35,89	47,73	0,85	0,85	11,45	10,38
	<i>Rrs_sim_MB7/Rrs_sim_MB4</i>	53,54	90,83	0,57	0,45	33,51	15,77
	<i>Rrs_sim_MB8/Rrs_sim_MB2</i>	32,42	47,93	0,85	0,86	16,25	14,55
	<i>Rrs_sim_MB8/Rrs_sim_MB3</i>	37,12	53,38	0,88	0,87	12,29	10,73
	<i>Rrs_sim_MB8A/Rrs_sim_MB3</i>	40,40	69,27	0,83	0,83	15,12	12,53

A escala de cores representa os melhores (em verde mais escuro) para os piores (em vermelho) resultados para cada estatística avaliada.

Fonte: Produção do Autor.

Esta semelhança de desempenho entre os sensores também é verificada na faixa do infravermelho próximo. Entretanto, nesta faixa, a FRE do OLI e do WFI são bem diferentes (Veja na Figura 3.4 **Erro! Fonte de referência não encontrada.**), o que faz com que os resultados para o OLI sejam piores (i.e. maior valor de MAPE) (p -valor < 0,05). A faixa do NIR do OLI é mais estreita e com ponto máximo de sensibilidade em 859 nm e cerca de 70 nm de resolução espectral (830 – 900 nm).

Já o sensor WFI possui seu máximo de sensibilidade em 775 nm com amplitude espectral de 740 a 900 nm. Esta diferença afeta de forma notável as estimativas de TSS e de TSI, com menores erros para o modelo $\ln(R_{rs,sim_WB5})$ já que esta abrange uma faixa espectral maior integrando mais energia que atinge o sensor, e assim reduzindo o efeito da absorção pela água no NIR na presença de baixas concentrações de TSS. Quando são comparados os sensores WFI e MSI, nota-se resultados equivalentes (p -valor > 0,05): MAPE = 24,41% para o modelo $\ln(R_{rs,sim_WB5})$, 23,77% para o modelo $\ln(R_{rs,sim_MB7})$ e 24,86 para o modelo $\ln(R_{rs,sim_MB8})$, todos com $R^2 = 0,91$, o que pode estar relacionado à semelhança entre a FRE destes sensores. O sensor OLI apresentou resultados equivalentes na faixa do NIR apenas com a banda 8A do MSI (p -valor > 0,05), devido à semelhança entre as respectivas FREs.

4.3.2 Modelos separados por campanhas

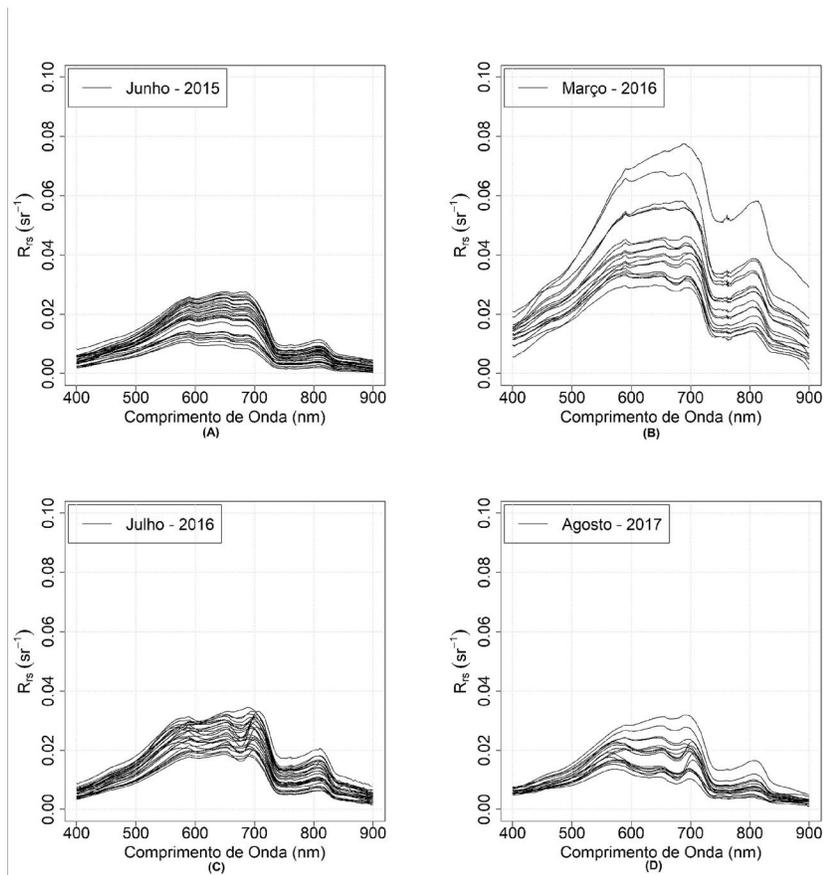
A utilização de modelos separados pelas quatro diferentes campanhas de campo realizadas possibilita a avaliação dos erros dos modelos em relação às características ópticas inerentes à cada fase do ano hidrológico em que as missões de campo foram realizadas.

As campanhas de junho de 2015 (cheia) e agosto de 2017 (vazante) apresentaram valores médios de TSS, TSI e TSO similares (Tabela 3.1). Entretanto, a concentração média de Chl-a foi bastante diferente entre estas campanhas: em agosto de 2017, a concentração média de Chl-a foi de 31,11 μgL^{-1} , enquanto que em junho de 2015 este valor foi aproximadamente 10 vezes menor (3,23 μgL^{-1}). As campanhas de 2016, contudo, apresentaram não só valores médios mais altos de concentração de sedimentos (74.46 mgL^{-1} e 32.86 mgL^{-1} para a concentração de TSS, em março (enchente) e julho (início da vazante) de 2016, respectivamente), como também uma maior amplitude de variação, cujo máximo ocorre na campanha de março de 2016, com valores de TSS e TSI alcançando 215 mgL^{-1} e 208 mgL^{-1} , respectivamente.

Esta variação se reflete também na R_{rs} , cujos maiores valores estão associados aos valores máximos de concentração de TSS e TSI (Figura 4.2),

obtidos na campanha de março de 2016. Ainda, é possível observar os máximos de absorção da Chl-a (~670 nm) e espalhamento do fitoplâncton (~700nm) presentes nos espectros das campanhas de julho de 2016 e agosto de 2017 – campanhas que apresentaram as maiores concentrações médias de Chl-a (29,97 e 31,11 μgL^{-1}). Os espectros da campanha de junho de 2015 apresentam um comportamento mais homogêneo no tocante à forma e à amplitude da R_{rs} , devido à baixa concentração de sedimentos e de clorofila.

Figura 4.2 Espectros separados por campanhas.



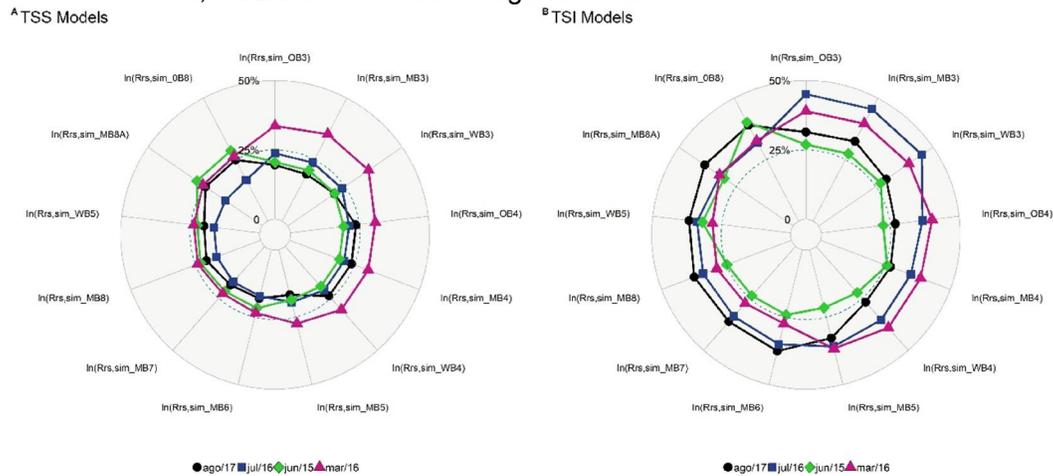
Fonte: Produção do autor.

Os modelos logarítmicos de TSS (Figura 4.3a) e TSI (Figura 4.3b) que apresentam os menores erros na faixa do visível (verde e vermelho) são os referentes às campanhas de campo caracterizadas pelas menores

concentrações de TSS (junho de 2015 e agosto de 2017). Já nas faixas do IVP, o que ocorre é o oposto, com as campanhas que possuem maiores concentrações de TSS e TSI apresentando melhores resultados nestas faixas.

Para a campanha de junho de 2015, os melhores resultados para TSS foram com o modelo $\ln(R_{rs,sim_MB5})$ para TSS (MAPE = 18,6%, $R^2 = 0,74$) e TSI (MAPE = 21,55%, $R^2 = 0,87$). Já para a campanha de agosto de 2017 o melhor resultado para TSS foi com o modelo $\ln(R_{rs,sim_MB5})$ (MAPE = 16,75%, $R^2 = 0,91$, $RMSE = 2,98 \text{ mgL}^{-1}$), enquanto para o TSI, obteve-se o melhor resultado com o modelo $\ln(R_{rs,sim_WB4})$ (MAPE = 22,32%, $R^2 = 0,84$, $RMSE = 8,42 \text{ mgL}^{-1}$). Nestas duas campanhas com valores de TSS e TSI menores, os valores de MAPE aumentam com o aumento do comprimento de onda.

Figura 4.3 Valores de MAPE (%) obtidos através da simulação de Monte Carlo para os dados de R_{rs} simulados para as faixas espectrais dos sensores OLI, WFI e MSI, utilizando os modelos logarítmicos.



A) Modelos para TSS; B) Modelos para TSI. Número de amostras de validação em cada campanha: Jun/15 n = 9; Mar/16 n = 5; Jul/16 n = 8; Ago/17 n = 5).

Fonte: Produção do autor.

Já nas campanhas com maiores concentrações de TSS e TSI (março e julho de 2016) os resultados são inversos: em março de 2016, o melhor resultado obtido foi com o modelo $\ln(R_{rs,sim_MB7})$ para TSS (MAPE = 22,79%, $R^2 = 0,96$) e

TSI (MAPE = 27,4%, $R^2 = 0,96$). Já em julho de 2016, o melhor resultado para TSS foi como modelo $\ln(R_{rs,sim_MB8A})$ (MAPE = 16,19%, $R^2 = 0,72$) e para TSI foi com o modelo $\ln(R_{rs,sim_WB5})$ (MAPE = 33,9%, $R^2 = 0,73$). Nestas campanhas, há uma diminuição do valor de MAPE com o aumento do comprimento de onda.

Estes resultados também demonstram semelhança nas estimativas utilizando as mesmas faixas espectrais para os três diferentes sensores: Para a faixa do verde, a maior diferença entre os três sensores foi observada no mês de março de 2016 com uma diferença de 1,63% nos valores de MAPE para TSS, enquanto para TSI, a maior diferença foi observada na campanha de agosto de 2017, 2,86%.

Nestes dois casos (TSS e TSI) as diferenças entre as concentrações calculadas através do teste de Wilcoxon não foram estatisticamente significativas (p -valor > 0,05). Já as diferenças nos valores de MAPE na faixa do vermelho para TSS não foram maiores que 1% em todas as campanhas enquanto que para TSI esta diferença foi maior em junho de 2015 (3,35%) entre o modelo $\ln(R_{rs,sim_WB4})$ (MAPE = 22,32%) e $\ln(R_{rs,sim_MB4})$ (MAPE = 25,67%). Entretanto, mesmo com esta diferença estes valores não são estatisticamente significativos (p -valor > 0,05) através do teste de Wilcoxon.

Em relação aos modelos baseados em razão de bandas (

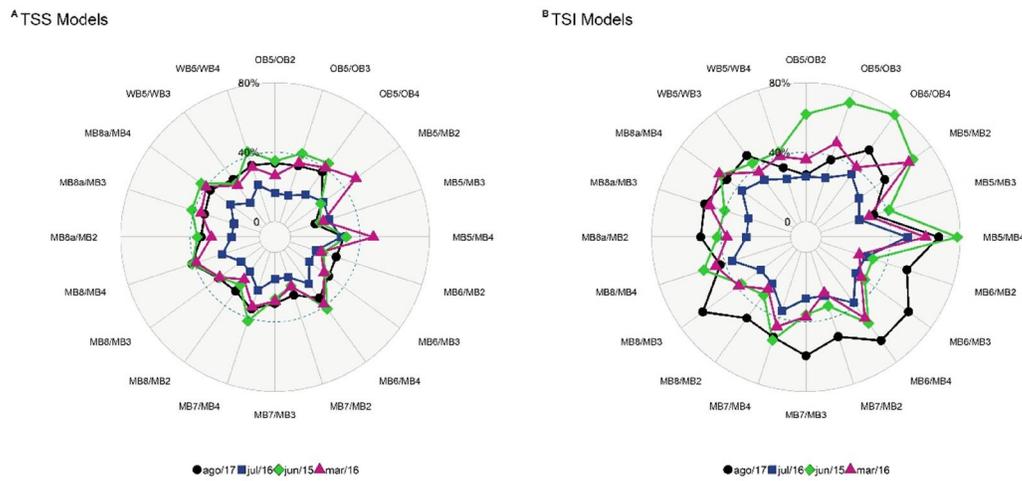
Figura 4.4) as estimativas de TSS apresentaram valores de MAPE inferiores a 40% para a maioria dos modelos, principalmente na campanha de julho de 2016. Contudo, valores de MAPE acima de 40% foram encontrados para as razões de banda $R_{rs,sim_OB5}/R_{rs,sim_OB3}$ e $R_{rs,sim_MB8A}/R_{rs,sim_MB3}$ para a campanha de junho de 2015 e a também para a razão $R_{rs,sim_MB5}/R_{rs,sim_MB2}$, para a campanha de março/2016.

A separação por épocas também apresentou melhores resultados de MAPE utilizando os modelos de razão de banda para estimativas de TSS para a maioria dos Modelos por Campanhas quando comparado aos Modelos com

Dados Completos, exceto para os modelos que usam banda centrada em 850 nm. Este efeito também foi observado para os modelos de TSI (

Figura 4.4b), em que valores de MAPE maiores que 50% foram encontrados para os modelos que utilizam a faixa espectral centrada em 850 nm, nas campanhas de julho de 2015 e agosto de 2017.

Figura 4.4 Valores de MAPE (%) obtidos através da simulação de Monte Carlo para os dados de R_{rs} *in situ* simulados para as bandas dos sensores OLI, WFI e MSI, utilizando os modelos de razão de bandas.



A) Modelos para campanhas separadas de TSS; B) Modelos para campanhas separadas de TSI. Número de amostras de validação em cada campanha: Jun/15 n =9; Mar/16 n = 5; Jul/16 n = 8; Ago/17 n = 5). Os modelos aplicados correspondem as razões de banda utilizando a $R_{rs,sim}$ para cada sensor.

Fonte: Produção do autor.

Os melhores resultados dos modelos de razão de banda de TSS e TSI foram encontrados para a razão $R_{rs,sim_MB5}/R_{rs,sim_MB3}$, com valores de MAPE menores que 24% para TSS nos quatro modelos e menores que 33% para TSI. Resultados de MAPE abaixo de 30% foram encontrados em todos os modelos

para estimativas de TSS e de TSI, avaliados para julho de 2016 além do que, estes modelos apresentaram pouca sensibilidade do MAPE às bandas utilizadas.

4.3.3 Modelos separados por lagos

A variabilidade dos COAs entre os lagos Curuai e Monte Alegre (Tabela 4.4) também é grande, à semelhança do que foi observado nos dados separados por campanhas. Os COAs no Lago de Curuai apresentam uma variação mais alta que os de Monte Alegre, com valores de TSI entre 2,29 – 218,5 mgL⁻¹ e de Chl-a entre 0,35 µgL⁻¹ a 85,04 µgL⁻¹. Já em Monte Alegre, estes valores ficam entre 25,8 – 78 mgL⁻¹ para TSI e entre 1,2 – 21,77 µgL⁻¹ de Chl-a.

Tabela 4.4 Análise estatística dos componentes opticamente ativos por lagos.

Lago	Número de Amostras	Estatística	TSS	TSI	TSO	Chl-a	Média TSI/TSS (%)
			(mg L ⁻¹)	(mg L ⁻¹)	(mg L ⁻¹)	(µg L ⁻¹)	
Curuai	64	Média	35.15	23.92	11.24	21.71	58.81
		Mínimo	7	2.29	3.62	0.35	
		Máximo	235.5	218.5	27	85.04	
		Desvio Padrão	35.76	32.78	5.67	19.31	
Monte Alegre	17	Média	32.09	25.8	6.29	6.74	72.72
		Mínimo	5.25	2	3	1.20	
		Máximo	97	78	19	21.77	
		Desvio Padrão	22.76	20.07	3.68	5.33	

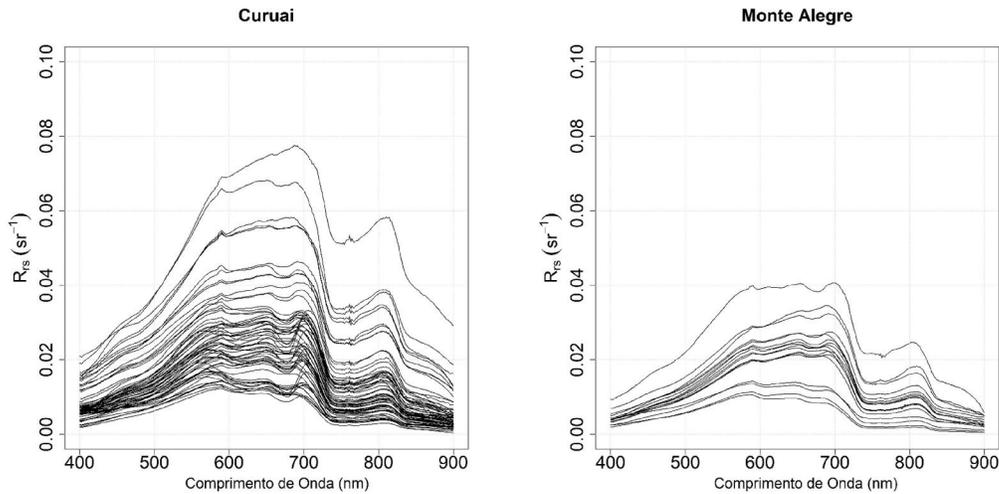
Fonte: Produção do autor.

Devido às variações de composição dos COAs entre os lagos, os espectros e R_{rs} também são distintos (Figura 4.5). No Lago Grande de Curuai é possível observar valores mais altos de R_{rs} em relação aos observados nos espectros de Monte Alegre, devido às maiores concentrações de TSS e TSI.

Também é possível observar as bandas características de absorção de Chl-a em Curuai, o que não acontece em Monte Alegre, sendo estes mais homogêneos em relação à forma. Assim, a influência na R_{rs} é mais ligada à

variação da concentração do material em suspensão, apresentando menor dependência com a Chl-a.

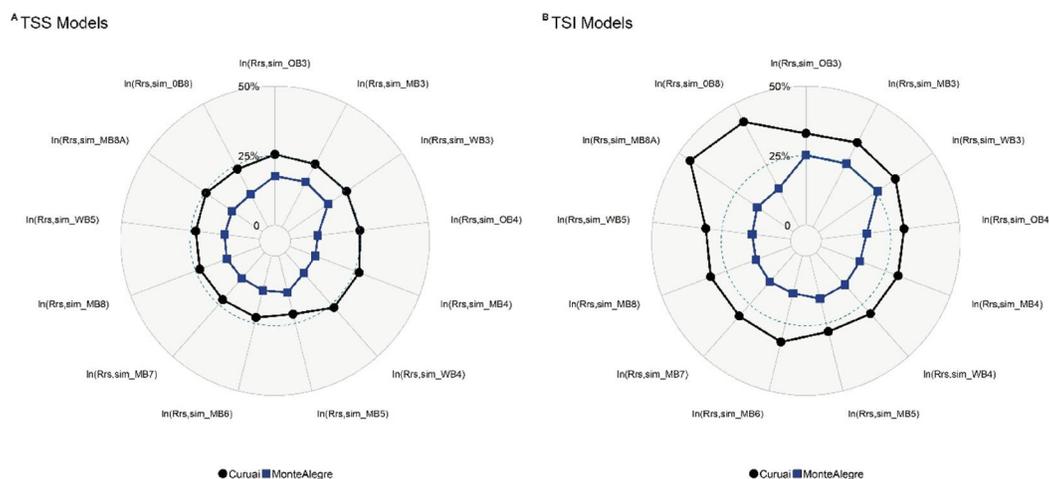
Figura 4.5 Espectros de R_{rs} para os lagos de Curuai e Monte Alegre.



Fonte: Produção do autor.

Os resultados da Simulação de Monte Carlo indicaram que os algoritmos logarítmicos separados por lagos apresentaram melhores resultados em relação aos modelos que utilizam o Conjunto Completo (Tabela 4.3 Resultados da simulação de Monte Carlo). Os algoritmos de TSS (Figura 4.6a) para o Lago de Monte Alegre apresentaram valores de MAPE menores que 20% para todos os algoritmos testados, com o melhor desempenho na faixa do vermelho (MAPE < 10,1% e $R^2 > 0,96$) para os três sensores, com valores de MAPE estatisticamente menores que os algoritmos que utilizam as outras faixas espectrais (Teste de Wilcoxon, p-valor < 0,05). Já para o TSI (Figura 4.6b), os melhores resultados de MAPE foram para a faixa do IVP para os três sensores. Para o MSI, como este possui mais faixas no IVP, o melhor resultado obtido foi para o algoritmo $\ln(R_{rs,sim_MB6})$ (MAPE = 13,86) (p-valor < 0,05).

Figura 4.6 Valores de MAPE (%) obtidos através da simulação de Monte Carlo para os dados de R_{rs} simulados para as faixas espectrais dos sensores OLI, WFI e MSI, utilizando os modelos logarítmicos.



A) Modelos de TSS para os lagos Curuai e Monte Alegre B) Modelos de TSI para os lagos Curuai e Monte Alegre. Número de amostras de validação: Curuai $n = 20$, Monte Alegre = 5.

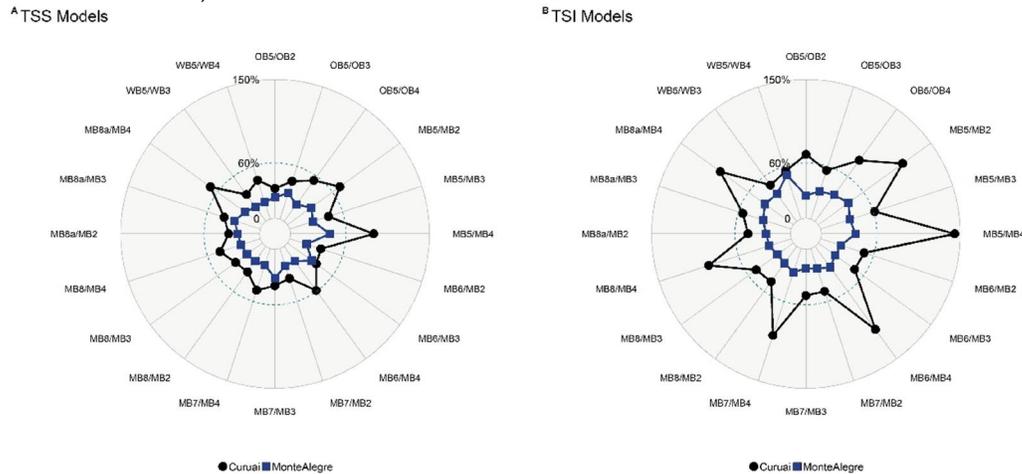
Fonte: Produção do autor.

Já para o lago de Curuai os erros para TSS e TSI são maiores que os encontrados para Monte Alegre, com o melhor desempenho para TSS obtido pelo modelo $\ln(R_{rs,sim_MB5})$ (MAPE = 21,6%, $R^2 = 0.92$, RMSE = 8,27 mgL^{-1}). Em relação aos modelos de TSI, valores de MAPE menores que 33% foram encontrados para todos os modelos, exceto para os modelos $\ln(R_{rs,sim_MB8A})$ e $\ln(R_{rs,sim_OB5})$. Novamente, o erro dos modelos para a estimativa de TSI são sempre maiores que aqueles apresentados pelos modelos de TSS. Para TSI, o algoritmo $\ln(R_{rs,sim_MB5})$ apresentou também melhor resultado para TSI (MAPE = 28,07%, $R^2 = 0,92$, RMSE = 7,67 mgL^{-1}). Nos dois casos (TSS e TSI), esses algoritmos apresentaram valores de MAPE estatisticamente menores que os outros algoritmos através do teste de Wilcoxon (p-valor <0,05).

Os modelos de razão de banda apresentaram resultados de estimativa de TSS (Figura 4.7a) e TSI (Figura 4.7b) em Monte Alegre menores que 30% (Figura 4.7). Entretanto, em Curuai estes resultados foram sempre maiores que 30%,

com valores mínimos de MAPE de 32,24% para TSS (Modelo $R_{rs,sim_OB5}/R_{rs,sim_OB2}$) e 47,13% para TSI (Modelo $R_{rs,sim_MB8}/R_{rs,sim_MB2}$).

Figura 4.7 Valores de MAPE (%) resultantes da simulação de Monte Carlo para os dados de R_{rs} simulados para as faixas espectrais dos sensores OLI, WFI e MSI, utilizando os modelos de razão de bandas.



A) Modelos de TSS para os lagos Curuai e Monte Alegre B) Modelos de TSI para os lagos Curuai e Monte Alegre. Número de amostras de validação: Curuai $n = 20$, Monte Alegre = 5. Os modelos aplicados correspondem as razões de banda utilizando a $R_{rs,sim}$ para cada sensor.

Fonte: Produção do autor.

Menores valores de MAPE foram encontrados para os algoritmos logarítmicos em relação aos modelos de razão de bandas, tanto para Curuai quanto para Monte Alegre. Em Curuai, os melhores resultados foram para o modelo $\ln(R_{rs,sim_MB5})$ (MAPE = 21,6%, $R^2 = 0,92$, RMSE = 8,55 mgL^{-1} e MAPE = 28,07%, $R^2 = 0,93$ e RMSE = 7,67 mgL^{-1} para TSS e TSI, respectivamente). Já em Monte Alegre, os modelos $\ln(R_{rs,sim_MB4})$ (MAPE = 9,93%, $R^2 = 0,96$, RMSE = 3,85 mgL^{-1}) e $\ln(R_{rs,sim_MB8})$ (MAPE = 13,66%, $R^2 = 0,97$, RMSE = 4,19 mgL^{-1}) apresentaram os melhores resultados para TSS e TSI, respectivamente.

4.3.4 Variabilidade do *slope* e intercepto das regressões

Através da simulação de Monte Carlo, a avaliação da variação dos coeficientes das regressões geradas pelos modelos logarítmicos e suas incertezas (à 95% de confiança) mostrou que a menor variação e conseqüentemente a menor incerteza foi observada para o Conjunto Completo. Para os modelos de TSS, valores de CV menores que 8% foram obtidos para o intercepto da regressão (Tabela 4.5) e menores que 5,5% para a inclinação (Tabela 4.6) quando foram calibrados com o conjunto de dados Completo.

Tabela 4.5 Coeficiente de variação (CV, em %) calculado a partir da incerteza expandida (95% de confiança) para o intercepto das regressões utilizando os modelos logarítmicos para as faixas espectrais do WFI, OLI e MSI.

	WB3	WB4	WB5	OB3	OB4	OB5	MB3	MB4	MB5	MB6	MB7	MB8	MB8A
Todas As Campanhas (n = 94)	7,7	6,7	6	7,7	6,8	7,3	7,9	6,8	6,4	6,1	6	6,1	7,2
ago/17 (n =18)	25,3	30,9	36,8	25,2	31,3	113	25,3	31,1	23,4	30,4	30,7	40,9	111,5
jul/16 (n = 27)	37,2	35,7	15,7	36,8	36,8	16,1	36,4	36,8	19,1	16,5	16,3	15,6	15,9
mar/16 (n = 18)	31,7	23,6	16,7	31,6	24,3	22,4	31,9	23,2	20,2	15,9	14,9	17,8	22,1
jun/15 (n = 31)	16,6	14,5	21,4	16,5	14,6	34,9	16,6	14,6	13,5	19,3	19,5	22,5	34,7
Curuai (n = 64)	8,9	8,3	7,7	8,9	8,4	9,4	9,1	8,4	8	7,8	7,7	7,8	9,4
Monte Alegre (n = 17)	10,1	6,8	8,2	10,1	6,4	8,3	10,8	7	7,8	7,8	7,7	8,6	8,2

Fonte: Produção do autor.

A separação do conjunto por campanhas provocou um aumento no CV em cerca de 3 vezes. Já para o conjunto separado por lagos, os valores de CV foram maiores que o do conjunto completo, porém, menores do que os observados com os modelos separados por campanhas. Mesmo para Monte Alegre, em que o número de amostras é reduzido, estes valores ficaram abaixo de 11%.

Tabela 4.6 Coeficiente de variação (CV, em %) calculado a partir da incerteza expandida (95% de confiança) para a inclinação das regressões utilizando os modelos logarítmicos para as faixas espectrais do WFI, OLI e MSI.

	WB3	WB4	WB5	OB3	OB4	OB5	MB3	MB4	MB5	MB6	MB7	MB8	MB8A
Todas As Campanhas (n = 94)	5,3	4,4	3,7	5,3	4,4	4,4	5,4	4,4	4,1	3,7	3,6	3,7	4,4
ago/17 (n =18)	18,8	18,8	23,6	18,8	19,2	62,9	19	18,8	15,2	19,6	19,9	26,1	62,3
jul/16 (n = 27)	20,5	21	8,8	20,2	21,7	9	19,6	21,5	11,5	9,1	9	8,7	8,9
mar/16 (n = 18)	20,1	14,1	8,8	20	14,6	11,3	20,3	13,8	12,2	8,6	8	9,3	11,2
jun/15 (n = 31)	11,7	9,5	13,5	11,6	9,6	20	11,7	9,5	8,8	12,3	12,4	14,1	19,9
Curuai (n = 64)	6,1	5,3	4,6	6,1	5,3	5,6	6,2	5,3	5	4,6	4,5	4,6	5,5
Monte Alegre (n = 17)	7,6	4,9	4,9	7,6	4,7	5,1	8,1	5	5,2	4,7	4,6	5,2	5

Fonte: Produção do autor.

4.4 Discussão

4.4.1 Variabilidade da concentração dos COAs e R_{rs} entre as campanhas e lagos

As concentrações de TSS, TSI e Chl-a, além da R_{rs} obtidas neste estudo apresentaram dependência em relação à fase da hidrógrafa em que foram realizadas as campanhas de campo (Tabela 3.1) e também em função dos lagos em que foram realizadas estas campanhas (Tabela 4.4), assim como mostrado por outros estudos na mesma região (BARBOSA, 2005; BARBOSA et al., 2010; BOURGOIN et al., 2007). Menores concentrações de TSS e de TSI foram encontradas para as campanhas de junho de 2015 (Cheia) e agosto de 2017 (Vazante), o que é refletido também nos espectros de R_{rs} com valores mais baixos (Figura 4.2).

Na campanha de março de 2016 (Enchente), maiores concentrações de TSS foram encontradas e, conseqüentemente, houve maior magnitude nos valores de R_{rs} . Além disto (Figura 4.2b) é possível diferenciar dois grupos de espectros em função da variabilidade na concentração dos COAs (Tabela 3.1). Ainda, a

relação TSI/TSS média nesta campanha é de cerca de 72%, indicando alta concentração de material inorgânico em relação ao orgânico, o que favorece o aumento da intensidade da R_{rs} devido ao maior índice de refração destas partículas (KOBAYASHI et al., 2010; ROESLER; BOSS, 2008). Esta alta carga inorgânica é característica desta fase da hidrógrafa devido à entrada deste tipo de sedimento oriundo do Rio Amazonas (MEADE, 1994; RUDORFF; DUNNE; MELACK, 2018).

Já a campanha de julho de 2016 (Início da vazante) apresentou maiores valores de concentração de TSS e TSI em relação à campanha de agosto de 2017, apesar da similaridade da fase da hidrógrafa. Esta diferença pode ser atribuída à seca ocorrida em 2016, relacionada ao fenômeno El-Niño (JIMÉNEZ-MUÑOZ et al., 2016), que reduziu o nível da água na planície. Já na campanha de agosto de 2017, a hidrógrafa já apresenta um comportamento próximo à média histórica, com os valores de TSS e TSI começando a aumentar devido à diminuição do nível do lago.

A concentração de Chl-a apresentou os valores mais baixos na campanha de junho de 2015, o que é notado também no espectro de R_{rs} , no qual não se observam as bandas de absorção da Chl-a (Figura 4.2a). A baixa concentração média de Chl-a nesta época ($3,23 \mu\text{gL}^{-1}$) pode ser atribuída ao alto nível do Rio Amazonas (Figura 3.2) (BARICHIVICH et al., 2018) que provoca maior fluxo de água para o interior da planície, aumentando a turbulência e dificultando a floração de algas (CASALI et al., 2011; MOREIRA-TURCQ et al., 2013; MUNDIAL; DIREITO, 2005). Além disto, há entrada de material orgânico dissolvido e também material em suspensão orgânico e inorgânico nesta época (MOREIRA-TURCQ et al., 2013), o que reduz a disponibilidade de luz na faixa do azul para a fotossíntese neste período (BARBOSA et al., 2010; DUNNE et al., 1998b; RUDORFF; DUNNE; MELACK, 2018).

A campanha de agosto de 2017 apresentou valores médios mais altos de Chl-a, seguido pela campanha de julho de 2016. Estes maiores valores na época de vazante podem ser atribuídos ao maior aporte de nutrientes vindo do Rio

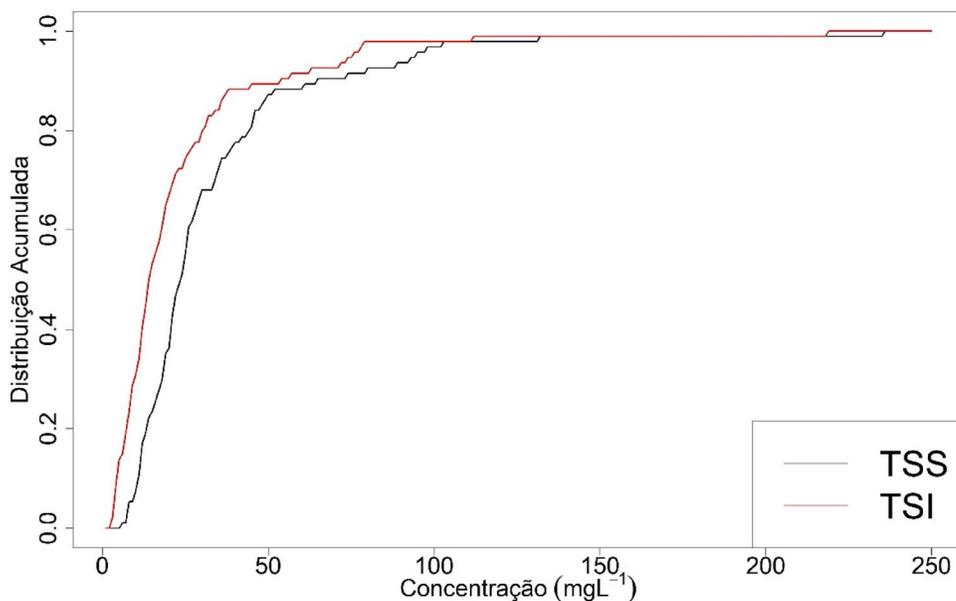
Amazonas durante os períodos de enchente e cheia (BARBOSA et al., 2010; BONNET et al., 2017; SILVA; MELACK; NOVO, 2013).

4.4.2 Acurácia da predição para os modelos utilizando dados de todas as campanhas

Os resultados dos modelos gerados com dados de todas as campanhas apresentaram valores de MAPE indicativos de maior exatidão das estimativas dos modelos logarítmicos em relação às dos modelos de razão de banda independente do sensor utilizado (Tabela 4.3). Os valores de MAPE para os modelos logarítmicos de TSS ficaram abaixo de 35% para todos os modelos dos três sensores, com os melhores resultados obtidos para os modelos $\ln(R_{rs,sim_OB4})$ (OLI), $\ln(R_{rs,sim_WB5})$ (WFI) e $\ln(R_{rs,sim_MB5})$ (MSI) (MAPE < 25%, $R^2 > 0,83$), sendo o modelo $\ln(R_{rs,sim_MB5})$ o que apresentou o melhor resultado (p-valor < 0,05 na comparação com os modelos gerados para o OLI e a WFI).

O melhor resultado de TSS para o modelo $\ln(R_{rs,sim_MB5})$ pode ser atribuído à ausência do sinal de absorção de Chl-a na faixa de 705 nm e à dependência desta faixa espectral em relação ao retroespalhamento pelo fitoplâncton e pelo material em suspensão (OLMANSON; BREZONIK; BAUER, 2013). Os piores resultados de MAPE e R^2 (27,79% e 0,79, respectivamente) na faixa do verde são atribuídos principalmente à saturação desta faixa espectral com o aumento da concentração de sedimentos (DOXARAN et al., 2002; GIARDINO et al., 2017; NECHAD et al. 2010; ROESLER; BOSS, 2008). Já os erros na faixa do infravermelho próximo, principalmente em maiores comprimentos de onda (~850 nm) são atribuídos à quantidade de pontos com menores concentrações de TSS e TSI (80% dos pontos apresentam concentração de TSS menor que 45 mgL^{-1}) (Figura 4.8), em que o retroespalhamento pelas partículas não é capaz de superar a alta absorção da água em comprimentos de onda maiores (NECHAD et al. 2010).

Figura 4.8 Distribuição acumulada das concentrações de TSS (linha preta) e de TSI (linha vermelha) dos dados utilizados no modelo com todos os dados (n = 94).



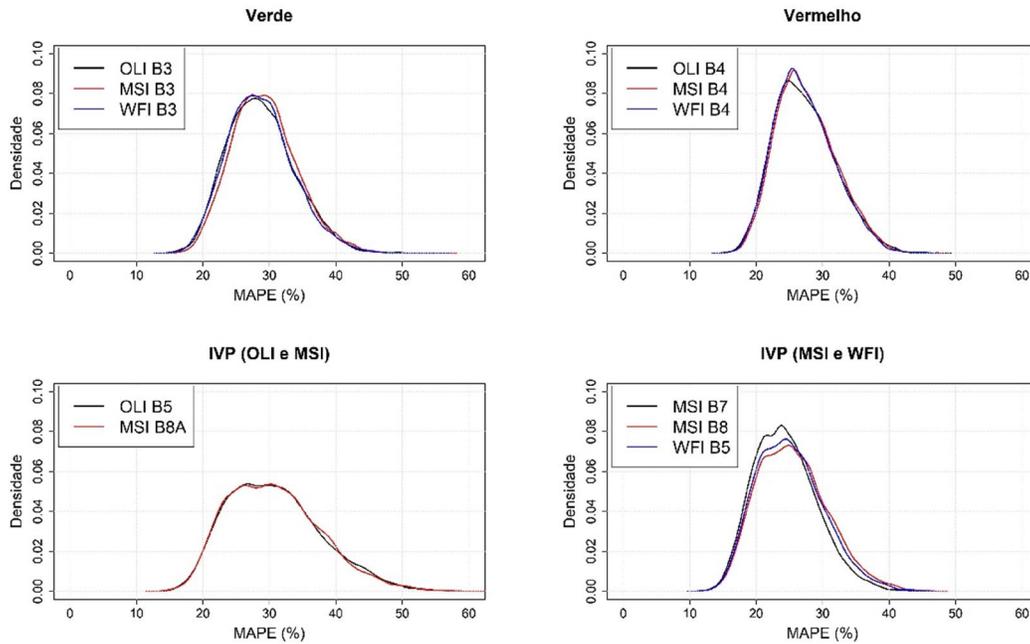
Fonte: Produção do autor.

Em relação ao TSI, os melhores resultados foram encontrados também para os modelos logarítmicos $\ln(R_{rs,sim_OB4})$ e $\ln(R_{rs,sim_MB5})$ para o OLI e MSI, respectivamente, porém, para o sensor WFI o melhor modelo encontrado foi para a faixa do vermelho $\ln(R_{rs,sim_WB4})$. Entretanto, ao serem comparados com os modelos para TSS, os modelos para TSI apresentam valores de MAPE mais altos (> 30%). Estes maiores erros para as estimativas de TSI podem ser atribuídos às contribuições de sedimentos orgânicos ao retroespalhamento que, mesmo com menor intensidade (KOBAYASHI et al., 2010), ainda assim podem afetar a acurácia (SNYDER et al., 2008).

Os resultados também demonstram a convergência dos modelos gerados em relação às faixas espectrais existentes em ambos os sensores (verde, vermelho e IVP (B5-OLI e B8A-S2 – B7 e B8 (MSI) e B5 (WFI); veja a proximidade das FRE na Figura 3.4), com os valores de estatísticas de validação bem próximos. Ou seja, em faixas espectrais próximas os resultados

dos modelos são convergentes, o que é provado através do teste de Wilcoxon (Veja na Seção 4.3.1).

Figura 4.9 Função de Distribuição de Probabilidades obtidas através da simulação de Monte Carlo para os modelos de TSS nas faixas espectrais que possuem uma FRE próxima.

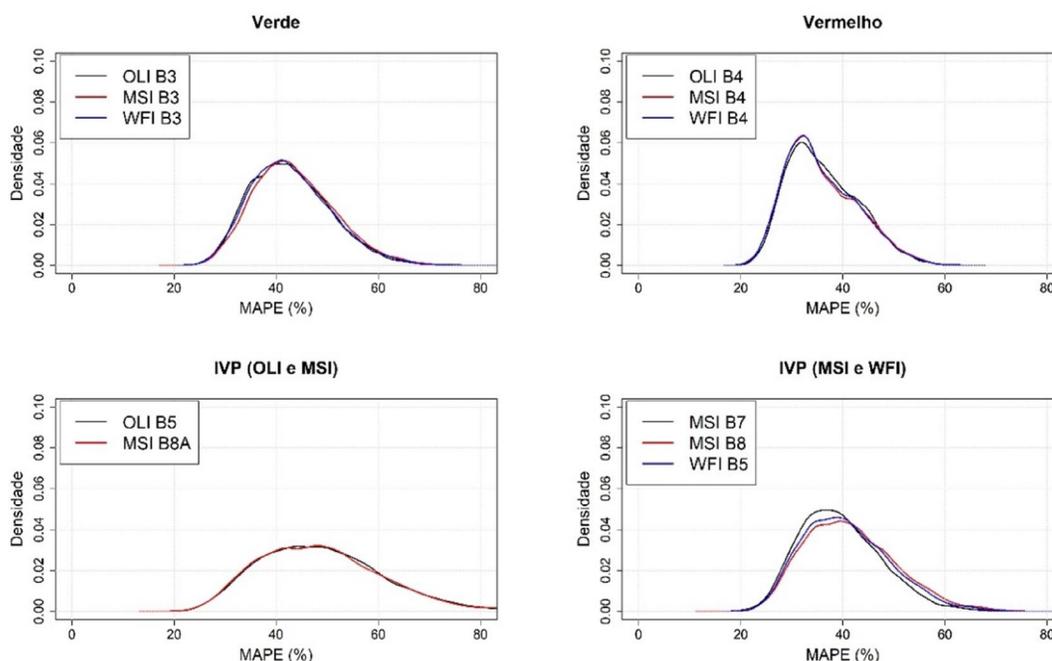


Fonte: Produção do autor.

A avaliação desta similaridade também pode ser observada graficamente (Figura 4.9) através da plotagem da função de distribuição de probabilidades (FDP) dos valores de MAPE obtidos para cada modelo através da simulação de Monte Carlo ($n = 100000$) e levando em consideração que resultados próximos possuem uma função parecida.

O comportamento próximo da FDP para TSS também é observado para os modelos de TSI (Figura 4.10). Ainda, é possível observar que para a FDP de TSI os valores de MAPE tem o mesmo comportamento, porém, com valores mais altos.

Figura 4.10 Função de Distribuição de Probabilidades obtidas através da simulação de Monte Carlo para os modelos de TSI nas faixas espectrais que possuem uma FRE próxima.

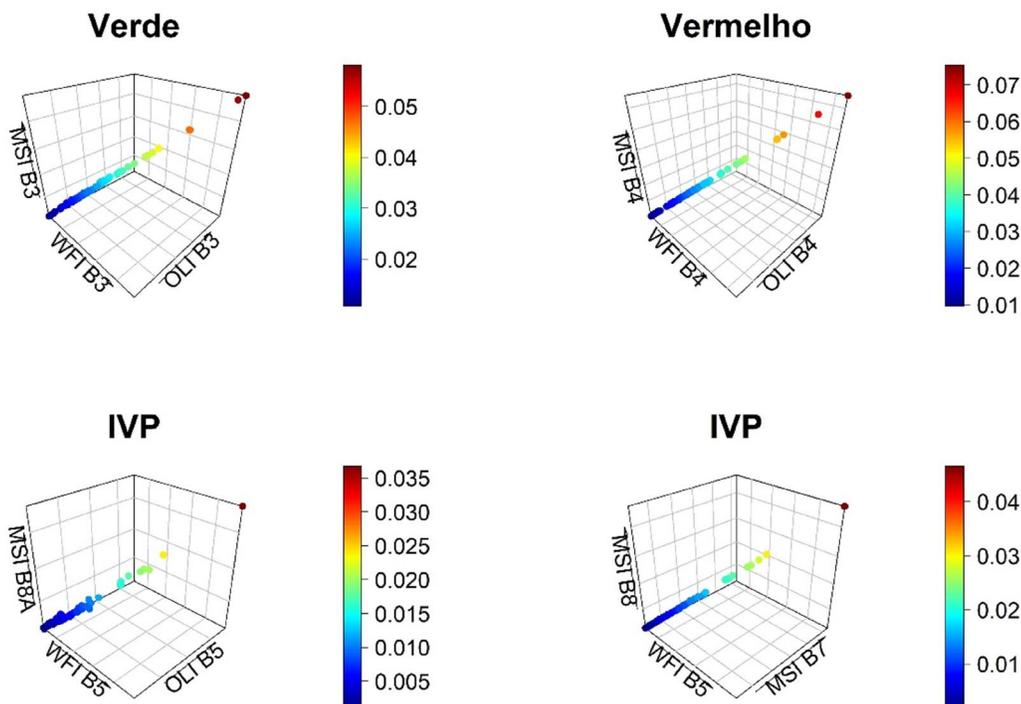


Fonte: Produção do autor.

Estes resultados iniciais da convergência dos valores de MAPE para as faixas similares dos sensores demonstram a viabilidade da utilização concomitante do OLI, da WFI e do MSI para estimativa de TSS e de TSI com resultados equivalentes. Estes resultados próximos são atribuídos à semelhança da $R_{rs,sim}$ nas faixas espectrais com FRE próxima, o que faz com que a diferença nos valores de $R_{rs,sim}$ sejam próximos (Figura 4.11).

Em uma comparação entre a R_{rs} simulada nas bandas com a FRE próxima, estas também se mostram equivalentes, com as maiores diferenças sendo visíveis onde a FRE possui maiores diferenças, como na comparação entre os valores de $R_{rs,sim}$ para as faixas: R_{rs,sim_OB5} , R_{rs,sim_MB8A} e R_{rs,sim_WB5} .

Figura 4.11 Comparação das R_{rs} simulada nas faixas espectrais que possuem FRE próximas (valores em sr^{-1}).



A paleta de cores indicam os valores mínimos (em azul) e máximos (em vermelho) da $R_{rs, sim}$. ($n = 94$).

Fonte: Produção do autor.

A similaridade nas estimativas dos modelos de TSS e de TSI estão ligadas também à dependência da $R_{rs, sim}$ à similaridade da FRE das bandas. A Tabela 4.7 evidencia a similaridade no tocante ao coeficiente angular, intercepto e à diferença média entre as $R_{rs, sim}$.

Diferenças menores que $10^{-3} sr^{-1}$ foram encontradas nas faixas do visível, com a inclinação da regressão variando entre 0,98749 a 1,01795, indicando alta relação entre as duas variáveis. Já na faixa do infravermelho próximo, devido à diferença entre a FRE na banda 5 do OLI e da WFI, maiores valores de inclinação (1,48982) e diferença média ($-0,00371 sr^{-1}$) foram encontrados. Em relação às outras comparações na faixa do infravermelho próximo, esta

diferença volta a apresentar resultados similares aos das faixas do visível dos três sensores.

Tabela 4.7 Estatísticas das faixas espectrais com FRE próximas utilizadas na Figura 4.11.

	Estatística	Coefficiente Angular	Intercepto	Diferença Média (sr⁻¹)
Faixa do verde	OB3- MB3	1,01187	-0,00027	0,00003
	OB3 - WB3	1,01795	0,00028	0,00071
	WB3 - MB3	1,00548	0,00055	0,00068
Faixa do vermelho	OB4 - MB4	0,98749	0,00081	0,00047
	OB4 - WB4	0,99146	0,00047	0,00024
	MB4 - WB4	1,00378	-0,00033	-0,00023
Faixa do infravermelho	OB5 - WB5	1,48982	0,01089	-0,00371
	OB5 - MB8A	0,9953	0	-0,00004
	WB5 - MB8	1,05573	0,00015	0,00071
	WB5 - MB7	0,89722	-0,00158	-0,0003

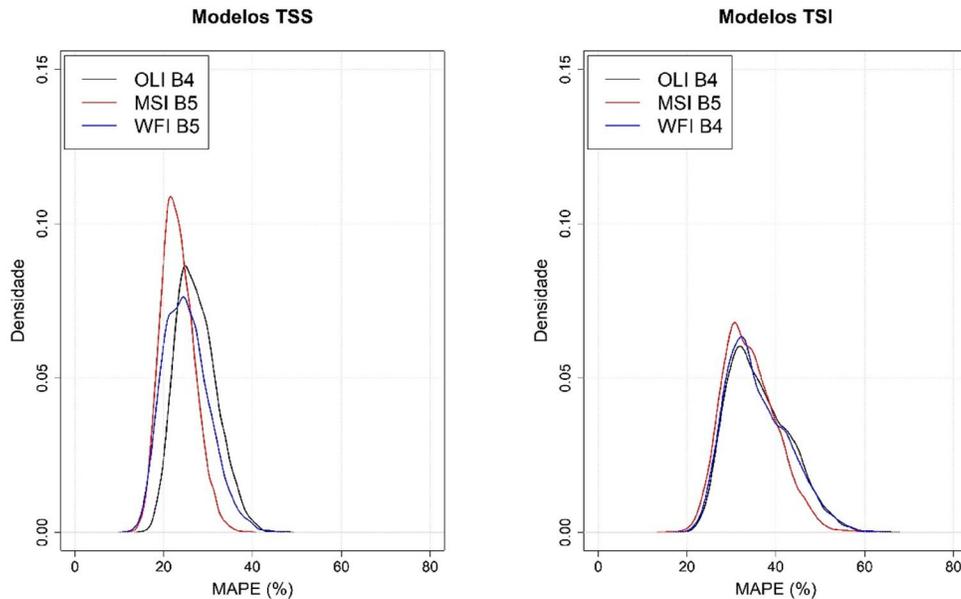
Fonte: Produção do autor.

Entretanto, vale lembrar que devido às diferentes características dos sensores (Relação Sinal Ruído (SNR), resoluções espectrais, radiométricas e espaciais, geometrias de visada), a avaliação da convergência entre os modelos aplicados nas imagens também é de grande necessidade, já que a utilização de dados simulados demonstra o efeito da FRE na variação da $R_{rs,sim}$.

Além dos resultados para bandas próximas, foram comparadas as FDPs dos resultados para os melhores modelos obtidos para TSS ($\ln(R_{rs,sim_OB4})$, $\ln(R_{rs,sim_WB5})$, $\ln(R_{rs,sim_MB5})$) e para TSI ($\ln(R_{rs,sim_OB4})$, $\ln(R_{rs,sim_WB4})$, $\ln(R_{rs,sim_MB5})$) (Figura 4.12). Nos dois casos (TSS e TSI) o teste de Wilcoxon indicou que o melhor algoritmo foi o $\ln(R_{rs,sim_MB5})$ em relação aos outros avaliados. Este resultado pode ser observado na variação dos resultados da

FDP, que apresentou um comportamento mais à esquerda, indicando menores valores de MAPE para o algoritmo $\ln(R_{rs,sim_MB5})$ (Figura 4.12).

Figura 4.12 Função de Distribuição de Probabilidades para os melhores modelos encontrados para cada sensor, tanto para TSS quanto para TSI.



Fonte: Produção do autor.

Zheng et al. (2015) utilizando a $R_{rs,sim}$ para o sensor OLI no Lago Dongting, na China, para uma amplitude de concentração de TSS variando entre 4-101 mgL^{-1} (média = 36,4 mgL^{-1}) e de TSI variando entre 2,3-93,3 mgL^{-1} (Média = 27,5 mgL^{-1}) encontraram bons valores de MAPE (18,6%) para as estimativas de TSS utilizando a faixa do IVP. Liu et al. (2017) também encontraram bons resultados de validação para a utilização da $R_{rs,sim}$ do sensor MSI na estimativa de TSS no Lago Poyang, na China, para uma concentração média de TSS de 76,05 mgL^{-1} . Devido à maior amplitude e valores médios de concentração, estes autores encontraram melhores resultados de MAPE para as bandas 6, 7, 8 e 8A do MSI (MAPE < 20%). Já neste estudo, como a concentração de TSS é mais baixa e a amplitude menor, os resultados seguem a tendência de serem

melhores em faixas de comprimento de onda menores (GIARDINO et al., 2017; LIU et al., 2017).

4.4.3 Variação da acurácia dos modelos de TSS e TSI ao longo das campanhas

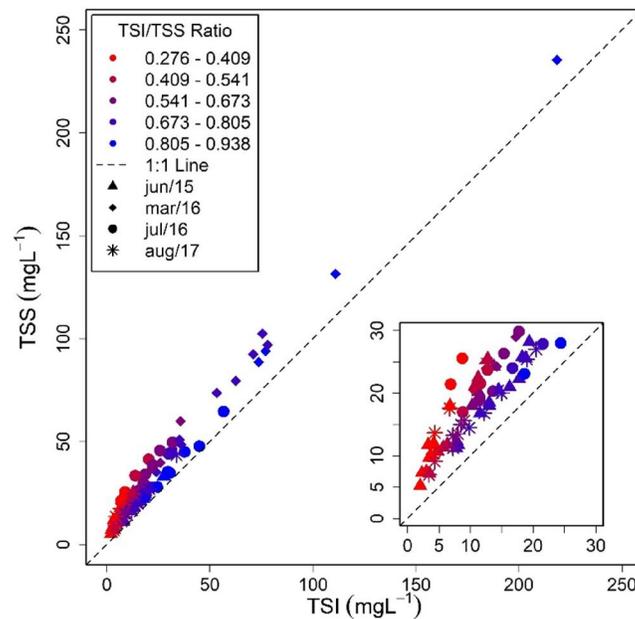
Quanto aos modelos separados por campanhas, estes apresentaram variações de acordo com a fase da hidrógrafa, como esperado devido à variação dos COAs (BARBOSA et al., 2010) (Tabela 3.1). Esta variação fez com que na campanha de junho de 2015, os erros aumentassem com o comprimento de onda, assim como em agosto de 2017. Nas campanhas de 2016, o contrário acontece e os erros diminuem com o comprimento de onda.

Na campanha de junho de 2015, os melhores resultados das estimativas de TSS e TSI para os modelos logarítmicos foram observadas nos comprimentos de onda menores (verde e vermelho para o OLI e WFI e a faixa do *red-edge* (B5) do MSI devido à menor concentração de TSS e TSI (GIARDINO et al., 2017), enquanto que para os modelos de razão de banda, os melhores resultados foram para $R_{rs,sim_MB5}/R_{rs,sim_MB3}$. Em relação às estimativas de TSS, a amplitude do MAPE nestas faixas foi de 18,3% (para o modelo $\ln(R_{rs,sim_MB5}/R_{rs,sim_MB3})$) a 20,5% (para o modelo $\ln(R_{rs,sim_MB3})$). Entretanto, os modelos logarítmicos de TSI apresentaram valores de MAPE maiores do que os de TSS, principalmente na faixa do verde. Este resultado pode ser atribuído ao material orgânico em suspensão e à Chl-a presente nesta campanha (Razão TSI/TSS = 55,93%, Figura 4.13) contribuindo para o espalhamento na faixa do verde (ROESLER; BOSS, 2008).

Já nos modelos da faixa do vermelho e do red-edge, a diferença nos valores de MAPE para TSS e TSI não foi superior a 5%, já que, nestas faixas, o espalhamento por partículas orgânicas tem menos influência do que o das partículas inorgânicas (SNYDER et al., 2008). Além disso, devido à baixa concentração de Chl-a, o espectro de R_{rs} não apresenta as feições de absorção no vermelho, o que favorece a utilização desta faixa espectral para estimativa de TSI (ROESLER; BOSS, 2008; SNYDER et al., 2008). Já com o

aumento do comprimento de onda, devido à baixa concentração de TSS e TSI, os valores de MAPE tendem a aumentar, até o máximo valor na faixa de 850 nm (B5 OLI e B8A MSI) (MAPE > 28% para TSS e MAPE > 39,9% para TSI), devido ao retroespalhamento pelas partículas não ser suficiente para sobrepor à alta absorção pela água nesta faixa espectral (MOBLEY, 1994). Os modelos de razão de banda também seguem o observado para os logarítmicos, com as razões de banda que utilizam faixas de comprimento de onda maiores (e.g. $R_{rs,sim_MB8}/R_{rs,sim_MB3}$, MAPE = 30,5% para TSS e 48,79% para TSI), tendo piores resultados devido à baixa sensibilidade da R_{rs} (DOXARAN; DEVRED; BABIN, 2015).

Figura 4.13 Relação TSI/TSS.



As cores representam os valores da relação TSI/TSS e a forma dos pontos a campanha de campo em que as concentrações de sedimentos foram obtidas.

Fonte: Produção do autor.

A campanha de agosto de 2017 também apresentou baixas concentrações de TSS e de TSI, com valores médios similares aos de junho de 2015. Entretanto,

esta campanha apresentou valores médios maiores de Chl-a ($31,11 \mu\text{gL}^{-1}$). Este efeito é visível na diferença dos resultados de MAPE se comparados aos modelos de julho de 2015.

Para os modelos logarítmicos de TSS, os melhores resultados foram encontrados para a faixa do verde (OLI), do *red-edge* (B5 –MSI) e do IVP (MSI) (MAPE < 21%) devido principalmente, à contribuição tanto das partículas inorgânicas presentes quanto das células fitoplanctônicas (este apenas na faixa do verde e do red-edge) ao espalhamento (BLAUSTEIN et al., 1992; DALL'OLMO; GITELSON, 2006; OLMANSON; BREZONIK; BAUER, 2013).

Já o modelo de razão de bandas $R_{rs,sim_MB5}/R_{rs,sim_MB3}$ apresentou novamente bons resultados para TSS (MAPE = 15,4%). Para as estimativas de TSI, os melhores resultados foram para a faixa do vermelho para os três sensores (MAPE < 28%), principalmente devido ao menor efeito de retroespalhamento pela Chl-a (KOBAYASHI et al., 2010; ROESLER; BOSS, 2008). O modelo de razão de bandas $R_{rs,sim_MB5}/R_{rs,sim_MB3}$ também apresentou melhores resultados de MAPE para TSI. Entretanto, diferentemente do modelo de Junho/2015, nesta campanha os valores de MAPE foram maiores (32,27%), devido provavelmente à fluorescência da Chl-a em 705 nm (BLAUSTEIN et al., 1992; MATTHEWS, 2017).

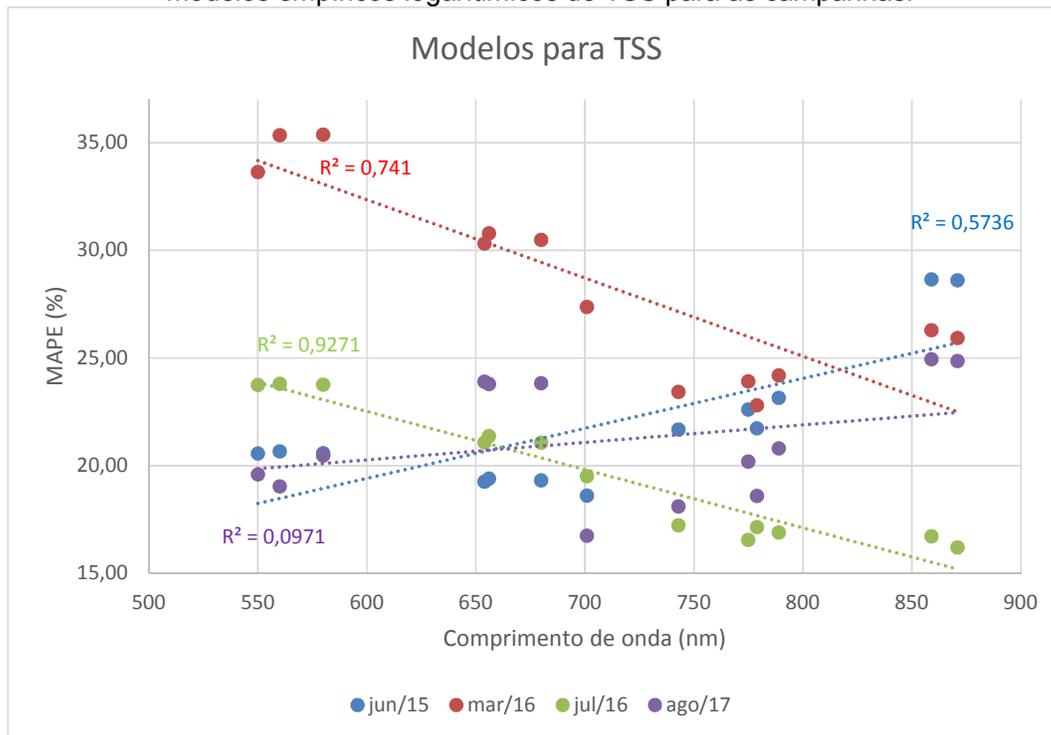
Já nas campanhas que apresentaram maior concentração de TSS e de TSI (março e julho de 2016), os modelos apresentaram resultados opostos aos encontrados nas campanhas com menor concentração. Maiores valores de MAPE foram encontrados para a faixa do verde e do vermelho, devido à saturação destas faixas espectrais causada por altas concentrações de TSS e TSI (NOVOA et al., 2017) e também pela maior proporção de sedimentos inorgânicos que aumentam o espalhamento (Relação TSI/TSO =71,58% e 64,40% para março e julho de 2016, respectivamente, Figura 4.13) (KOBAYASHI et al., 2010; MATTHEWS, 2011; NECHAD et al. 2010; ROESLER; BOSS, 2008).

Nestas duas campanhas houve diminuição dos erros dos modelos logarítmicos com o aumento do comprimento de onda tanto para TSS quanto para TSI

conforme observado por diversos autores com maiores concentrações de sedimentos (LIU et al., 2017; NECHAD et al. 2010; NOVOA et al., 2017; YEPEZ et al., 2018). Os resultados dos modelos de razão de bandas também apresentaram bons resultados, principalmente para a campanha de Julho/2016 para as razões que utilizam comprimentos de onda maiores que 740 nm (B6, MSI) (MAPE < 17%) para TSS.

Nota-se que, em todas as campanhas observou-se relação de aumento ou diminuição nos valores de MAPE com o comprimento de onda, exceto pela campanha de agosto de 2017 (Figura 4.14). Na campanha de julho de 2015, foram observadas menores concentrações de TSS, apresentando uma correlação positiva com o aumento do comprimento de onda (Pearson $r = 0,757$), enquanto que nas campanhas em que há maiores concentrações ocorreu uma correlação negativa: março de 2016 apresentou valores de Pearson r de $-0,86$. Em julho de 2016, este valor foi de $-0,96$. Apenas agosto de 2017 não apresentou correlação com o aumento do comprimento de onda ($R^2 = 0,09$ e Pearson $r = 0,311$).

Figura 4.14 Relação do aumento do comprimento de onda com a acurácia dos modelos empíricos logarítmicos de TSS para as campanhas.

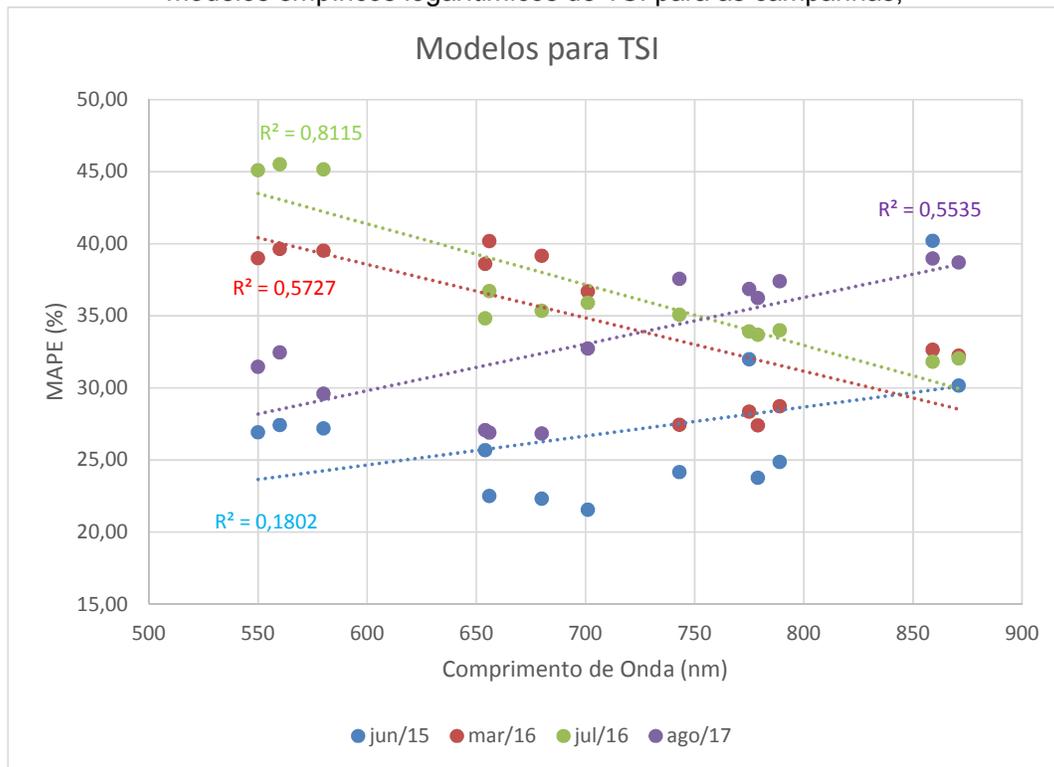


Fonte: Produção do autor.

Para a estimativa de TSI (Figura 4.15) a acurácia dos algoritmos também apresentou dependência com o comprimento de onda em função das campanhas. Diferentemente dos algoritmos para TSS, para TSI a campanha de junho de 2015 não apresentou dependência da acurácia em relação ao comprimento de onda (Pearson $r = 0,42$, $p\text{-valor} > 0,05$).

Para março de 2016, o valor de R^2 sobe para 0,57, com uma correlação de Pearson de -0,76 e um $p\text{-valor}$ significativo ($< 0,05$). Julho de 2016 também apresenta correlação negativa, assim como nos modelos de TSS (Pearson $r = -0,9$, $p\text{-valor} < 0,05$). Para TSI, a campanha para agosto de 2017 apresentou dependência em relação ao comprimento de onda (Pearson $r = 0,74$, $p\text{-valor} < 0,05$).

Figura 4.15 Relação do aumento do comprimento de onda com a acurácia dos modelos empíricos logarítmicos de TSI para as campanhas;



Fonte: Produção do autor.

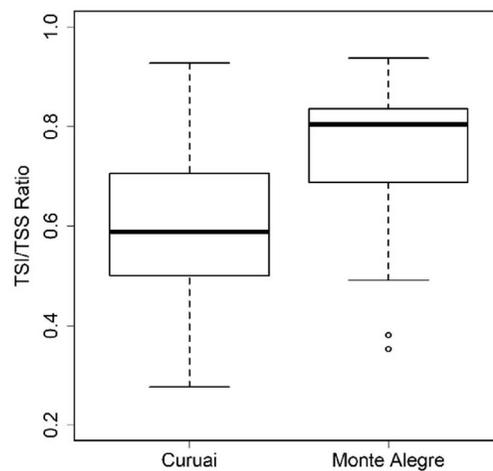
Esta variação da acurácia dos modelos em relação ao comprimento de onda demonstra novamente que eles são dependentes da fase da hidrógrafa em que foram obtidos, já que os erros tendem a diminuir/aumentar em dependência da concentração de material em suspensão existente no corpo d'água.

4.4.4 Variação da acurácia para os lagos de Curuai e Monte Alegre

Em relação aos modelos separados por lagos (Curuai e Monte Alegre), o desempenho foi melhor principalmente para Monte Alegre. Estes resultados podem ser atribuídos à maior homogeneidade dos COAs (Veja na Figura 4.5), sendo que em Monte Alegre a concentração média de clorofila é de $6,74 \mu\text{L}^{-1}$ e em Curuai esta concentração média aumenta para $21,76 \mu\text{L}^{-1}$. Ainda, Monte Alegre possui uma relação TSI/TSS mais alta que em Curuai e menor

variabilidade nesta relação (Figura 4.16). Para Monte Alegre, os resultados de estimativa de TSS e de TSI foram bem similares, com valores mais altos para a faixa do verde independentemente dos sensores, sendo estes resultados atribuídos à saturação desta faixa espectral (GIARDINO et al., 2017). Os resultados dos modelos de razão de banda não foram melhores do que os dos logarítmicos.

Figura 4.16 Razão TSI/TSS para Curuai e Monte Alegre.



Fonte: Produção do autor.

Já em Curuai, devido à maior variação dos COAs ao longo do ano hidrológico, os valores de MAPE para a validação apresentaram erros maiores. Entretanto, estes valores de MAPE não são superiores a 30% para TSS em Curuai independentemente dos modelos avaliados, sendo o melhor resultado novamente atribuído ao modelo $\ln(R_{rs, sim_MB5})$. Diferentemente de Monte Alegre, os valores de MAPE para as estimativas de TSI aumentam em cerca de 10% em relação às de TSS nas faixas do verde e do IVP. Este resultado pode ser influenciado pela diferença na concentração de material orgânico em suspensão nestes dois lagos, o que ocasiona uma mudança na relação entre TSI/TSS (Figura 4.16). Os modelos de Razão de Banda para Monte Alegre

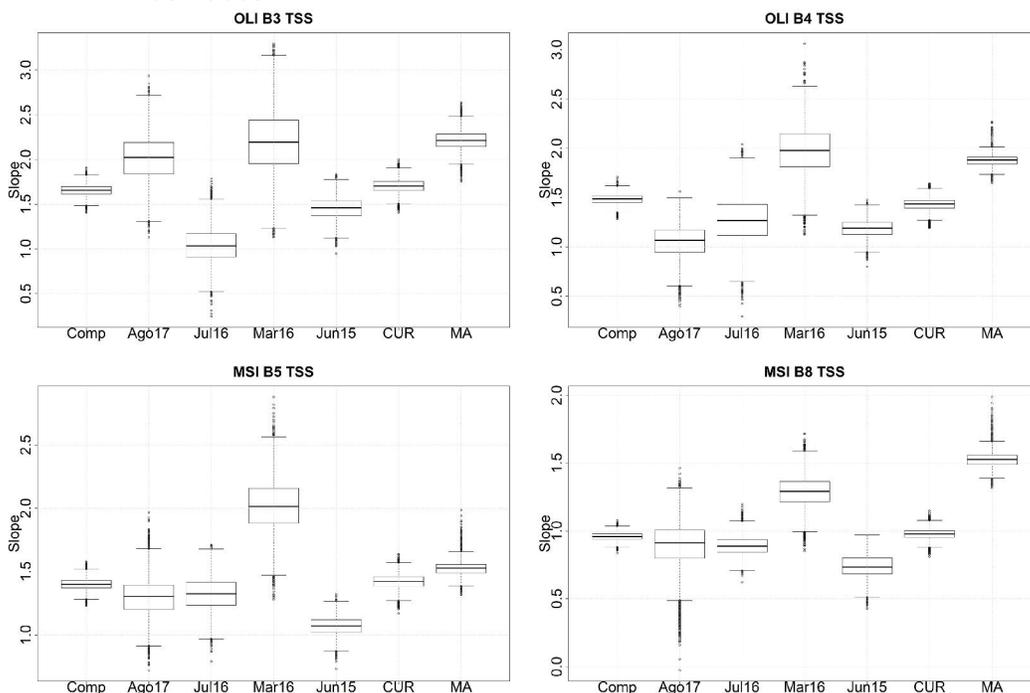
apresentaram melhores resultados ao serem comparados com os modelos de Curuai e com o conjunto Completo. Entretanto, estes valores são maiores do que os dos modelos logarítmicos. Para Curuai, os modelos de razão de banda apresentaram resultados mais parecidos aos obtidos para o conjunto completo.

4.4.5 A incerteza nas estimativas dos coeficientes das regressões

A avaliação das incertezas através do coeficiente de variação da inclinação da reta (Tabela 4.6) e do intercepto (Tabela 4.5) das regressões para os modelos logarítmicos mostram que apesar de valores de MAPE menores, ao se utilizar modelos separados por campanhas, aumenta a variação nos valores de inclinação e do intercepto. Assim, uma maior incerteza é atribuída aos algoritmos que são mais restritivos. Devido ao resultado para Monte Alegre (CV < 10.1% para *slope* e intercepto), pode-se deduzir que o menor número de amostras nas campanhas (entre 18-31) pode não ter sido o responsável pelo aumento da incerteza, já que em Monte Alegre foram utilizadas 17 amostras (Figura 4.17).

Quando comparadas as bandas com FRE próximas, as incertezas para a inclinação e o intercepto também apresentam valores equivalentes. Na faixa do verde, por exemplo, para o conjunto com todos os dados os valores variaram entre 6.6% e 6.7% para o intercepto e entre 5.3% a 5.4% para o coeficiente angular, indicando pouca variação entre os três sensores (veja todos os valores na Tabela 4.5 e Tabela 4.6). Esta comparação entre os resultados também é possível de ser observada avaliando o boxplot e comparando a variação da inclinação (Figura 4.17) com os tipos de conjunto de dados utilizados. As maiores variações, assim como observado para os valores de CV (Tabela 4.5 e Tabela 4.6) aparecem ao utilizarmos os modelos separados por campanhas.

Figura 4.17 Variação dos valores de *slope* obtidos pela simulação de Monte Carlo (n = 10000) para os modelos de TSS em relação aos vários conjuntos de dados utilizados.



Comp é o modelo para todos os dados, CUR é o modelo para o Lago de Curuai e MA é o modelo para Monte Alegre. As datas (Ago17, Jul16, Mar16 e Jun15) são para os modelos separados por campanhas.

Fonte: Produção do autor.

4.5 Conclusões

Os resultados indicaram que os modelos logarítmicos tiveram o melhor desempenho, mas que sua acurácia foi afetada pelas fases da hidrógrafa. Os resultados indicam também que as propriedades óticas dos lagos afetam a acurácia dos modelos, porque a composição da água muda ao longo do ano hidrológico. Independentemente da variação das acurácias, todos os modelos tiveram erros absolutos inferiores a 30 %. Esta calibração e validação utilizando os dados de R_{rs} *in-situ* simulada permite concluir que as faixas espectrais do OLI, WFI e MSI são aptas e permitem a estimativa de TSS e TSI com alta qualidade. Também foi possível observar a congruência entre a R_{rs} simulada nas faixas do verde, vermelho e IVP em bandas com FRE próximas, o que

permite também a conclusão que a resposta dos três sensores em faixas semelhantes é equivalente. Finalmente, pode-se obter incertezas associadas às estimativas do coeficiente angular e do intercepto das regressões logarítmicas, são menores que 8% se utilizam modelos calibrados com o conjunto Completo de dados. Estes resultados possibilitam assim a aplicação dos algoritmos de TSS e TSI desenvolvidos neste capítulo em imagens orbitais dos sensores OLI, WFI e MSI.

5 CALIBRAÇÃO DE MODELOS SEMI-ANALÍTICOS UTILIZANDO R_{rs} *IN-SITU* SIMULADA PARA MULTI-SENSORES

5.1 Introdução

Como visto no Capítulo 4, existem diversos estudos voltados para a utilização de algoritmos empíricos para as estimativas de TSS e TSI através de imagens provenientes de sensores remotos (MATTHEWS, 2011; MONTANHER et al., 2014; NOVOA et al., 2017). Estes algoritmos empíricos, entretanto, possuem em sua maioria limitações relativas ao conjunto de dados e características ópticas em que foram calibrados e tendem a serem aplicados com alta acurácia apenas em conjuntos de dados que possuam características similares. Neste sentido, algoritmos que tenham menos dependência das condições em que foram gerados são necessários visando uma aplicação mais global (LEE et al., 2002)

Diferentemente dos modelos empíricos, os modelos analíticos são baseados em soluções simplificadas das equações de transferência radiativa. Isto, geralmente, requer aproximações ou calibrações com coeficientes obtidos através de métodos empíricos (ODERMATT et al., 2012). Nesta abordagem, os coeficientes de espalhamento e absorção são expressos pela soma de seus coeficientes específicos (i.e. por massa). Assim, o coeficiente de absorção total é estimado pela soma dos coeficientes de absorção da água, fitoplâncton, partículas não algais inorgânicas e orgânicas e CDOM. O mesmo acontece para o coeficiente de retroespalhamento, apenas retirando a contribuição do CDOM para o espalhamento, que é negligenciável (OGASHAWARA; MISHRA; GITELSON, 2017).

Diversos modelos semi-analíticos foram propostos na literatura para a estimativa de TSS, (BRAMANTE; SIN, 2015; CHEN et al., 2013; DORJI et al. 2016; HAN et al., 2016; NECHAD et al., 2010). O embasamento teórico desses modelos parte das equações propostas por Gordon et al. (1975, 1988) segundo as quais, os valores de R_{rs} e r_{rs} são dependentes dos coeficientes de absorção e espalhamento da água, o que torna crucial a obtenção desses parâmetros

para sua aplicação. Dentre os modelos disponíveis, pode-se citar o modelo semi-analítico de uma banda desenvolvido por Nechad et al. (2010) como um dos mais utilizados para estimativas de TSS (NOVOA et al., 2017; PAHLEVAN et al., 2018). Este algoritmo foi inicialmente desenvolvido para a estimativa de material em suspensão total, mas já foi adaptado também para estimativa de turbidez (DOGLIOTTI et al., 2015).

Knaeps et al. (2015) compararam um modelo empírico nas faixas de 1020 e 1070 nm para altas concentrações de material em suspensão total com o modelo semi-analítico proposto por Nechad et al. (2010), extrapolado para as faixas em 1020 e 1070. Os autores encontraram melhores resultados para os modelos que utilizaram a relação empírica (MAPE = 25%) do que os da relação semi-analítica (MAPE = 29 a 31%). Segundo Knaeps et al. (2015), esta diferença está diretamente relacionada a necessidade da calibração empírica de A^p . Vê-se assim, que o desempenho deste tipo de algoritmo é dependente dos modelos espectrais gerados para os coeficientes de retroespalhamento e absorção e também da calibração correta do coeficiente A^p do C^p . Erros nestes valores irão afetar a acurácia da obtenção dos valores de sólidos em suspensão através dos dados de sensoriamento remoto.

Portanto, este capítulo teve como objetivo a calibração do modelo proposto por Nechad et al. (2010) utilizando dados de R_{rs} *in-situ* e também a comparação dos resultados dos modelos calibrados com os coeficientes propostos em Nechad et al. (2010). Para isto, o mesmo conjunto de dados e metodologia do Capítulo 4 foi adotada: Avaliou-se os resultados para o conjunto completo, para as campanhas separadas e para lagos separados.

5.2 Métodos

5.2.1 O algoritmo de Nechad

O modelo proposto por Nechad et al. (2010), que será referido a partir de agora como NC, é baseado em quatro premissas: 1) o coeficiente de retroespalhamento por partículas é proporcional à concentração de material em suspensão em função do coeficiente de retroespalhamento específico; 2) a

variação espaço-temporal de absorção por material não particulado (e.g. CDOM) pode ser negligenciada na faixa espectral utilizada; 3) a absorção por partículas é proporcional à concentração de material em suspensão, em função do coeficiente de absorção específico por partículas; 4) O retroespalhamento pelo material não particulado pode ser negligenciado.

A partir destas quatro premissas e de simplificações das equação de Gordon et al. (1998), os autores derivam a Equação 5.1, que relaciona a refletância da água ($\rho_w(\lambda) = \pi * R_{rs}$) com a concentração de material em suspensão (S) através dos coeficientes A^p e C^p definidos nas Equações 5.2 e 5.3. O B^p é utilizado para evitar: i) que um corpo d'água com $S = 0 \text{ mgL}^{-1}$ resulte em valores de refletância igual a zero; ii) para considerar os erros das medidas de refletância e material em suspensão. Considerando $\gamma = \pi R^f / Q = 0,216$, sendo R o efeito de refração e da reflexão da superfície da água, f um coeficiente que depende dos coeficientes de retroespalhamento e absorção e Q a razão entre a irradiância ascendente e a radiância ascendente. (MOREL; GENTILI, 1991, 1996; NECHAD et al. 2010) tem-se:

$$S = A^p \left(\frac{\rho_w}{1 - \frac{\rho_w}{C^p}} \right) + B^p \text{ (gm}^{-3}\text{)} \quad (5.1)$$

$$A^p = \frac{a_{np}}{b_{np}^* \gamma} \text{ (gm}^{-3}\text{)} \quad (5.2)$$

$$C^p = \frac{\gamma \frac{b_{bp}^*}{a_p^*}}{1 + \frac{b_{bp}^*}{a_p^*}} \text{ (Sem Dimensão)} \quad (5.3)$$

Segundo Nechad et al. (2010) o parâmetro C^p pode ser calibrado através de dados de IOPs disponíveis na literatura. Assim, Nechad et al. (2010) fornecem o valor de C^p para a faixa de 520 a 885 nm, com uma resolução espectral de 2.5 nm. Já o coeficiente A^p e B^p pode ser obtido também através dos resultados tabelados por Nechad et al. (2010) ou também pode ser calibrado a partir do próprio conjunto de dados, o que é mais indicado (KNAEPS et al., 2015).

Devido ao seu embasamento teórico a partir das IOPs, o intuito deste algoritmo é apresentar uma aplicação mais universal do que os algoritmos empíricos.

5.2.2 Calibração e validação do Modelo Semi-analítico

Neste trabalho os coeficientes A^p , C^p e B^p foram calibrados com base na equação não linear proposta por Nechad et al. (2010) utilizando a função *lms* do pacote *stats* (R CORE TEAM, 2017) do *software* R. Esta calibração baseada em dados *in-situ* foi realizada também por diversos autores (CABALLERO et al. 2018; SANDER DE CARVALHO, 2016).

Os valores iniciais de A^p , C^p e B^p foram os adotados por Nechad et al. (2010) para a faixa central de cada faixa espectral (i.e. verde, vermelho) para cada sensor. A mesma metodologia utilizada no Capítulo 4 para calibração e validação também foi utilizada neste capítulo. Como o algoritmo NC tem como entrada valores de refletância da água (ρ_w), multiplicou-se a $R_{rs,sim}$ por π .

A simulação de Monte Carlo foi realizada, com 10.000 repetições para que fosse obtida a moda dos valores de MAPE, R^2 e RMSE, similarmente ao realizado para os algoritmos empíricos. Os coeficientes A^p , C^p e B^p para cada modelo também foram obtidos a partir da moda das repetições derivadas da simulação Monte Carlo. Entretanto, diferentemente da abordagem utilizada para a calibração dos modelos empíricos, o algoritmo NC foi calibrado apenas para o conjunto completo de dados (MDC), ou seja, para o conjunto equivalente aos MDC referido na Seção 4.3.1., devido ao baixo conjunto de dados para os conjuntos separados por campanha e também devido aos resultados obtidos para o MDC terem apresentado melhores resultados na calibração para os algoritmos empíricos.

Os algoritmos calibrados a partir da R_{rs} medida *in-situ* foram comparados com os resultados obtidos pelo algoritmo NC sem calibração, utilizando assim os coeficientes propostos por Nechad et al. (2010) para avaliar a eficiência da calibração. Para a utilização do A^p , C^p e B^p tabelados por Nechad et al. (2010) para cada faixa espectral do OLI, WFI e MSI, estes coeficientes foram simulados baseados nas FREs para cada faixa espectral de cada sensor, à

similaridade do que foi realizada para a R_{rs} . As incertezas nas estimativas de A^p , C^p e B^p também foram calculadas conforme descrito na Seção 4.2.2, baseadas na simulação de Monte Carlo.

Apesar da calibração ter sido realizada para o conjunto completo (MDC), ele foi aplicado também aos demais conjuntos de dados (Separados por campanhas e Separados por Lagos) afim de avaliar seu desempenho. Esta metodologia foi utilizada devido aos resultados obtidos no Capítulo 4 em que, observou-se: i) maiores incertezas para as regressões nos conjuntos mais restritos; ii) melhores resultados para o MDC.

5.3 Resultados

5.3.1 Calibração e validação – MDC

Os resultados obtidos para as faixas espectrais do OLI, WFI e MSI a partir do modelo NC seguiram também o comportamento dos modelos empíricos para todas as campanhas (Tabela 5.1). Maiores erros ($MAPE > 29\%$, $R^2 < 0,8$ e $RMSE > 15 \text{ mgL}^{-1}$) para os algoritmos que utilizaram a faixa do verde dos três sensores. Já na faixa do vermelho, os erros são menores (em relação à faixa do verde) porém maiores em relação às faixas do IVP (exceto para as faixas centradas em aproximadamente 850 nm ($\rho_{w,OB5}$ e $\rho_{w,MB8A}$)). Diferentemente dos modelos empíricos, o modelo NC apresentou os melhores resultados para TSS utilizando a banda 7 do sensor MSI ($MAPE = 23,15\%$, $R^2 = 0,95$, $RMSE = 9,09 \text{ mgL}^{-1}$), com diferença significativa em relação às outras faixas espectrais avaliadas ($p\text{-valor} < 0,05$).

Tabela 5.1 Valores de moda para o MAPE (%), R² e RMSE (mgL⁻¹) obtidos através da simulação de Monte Carlo (95% de confiança) para os algoritmos NC.

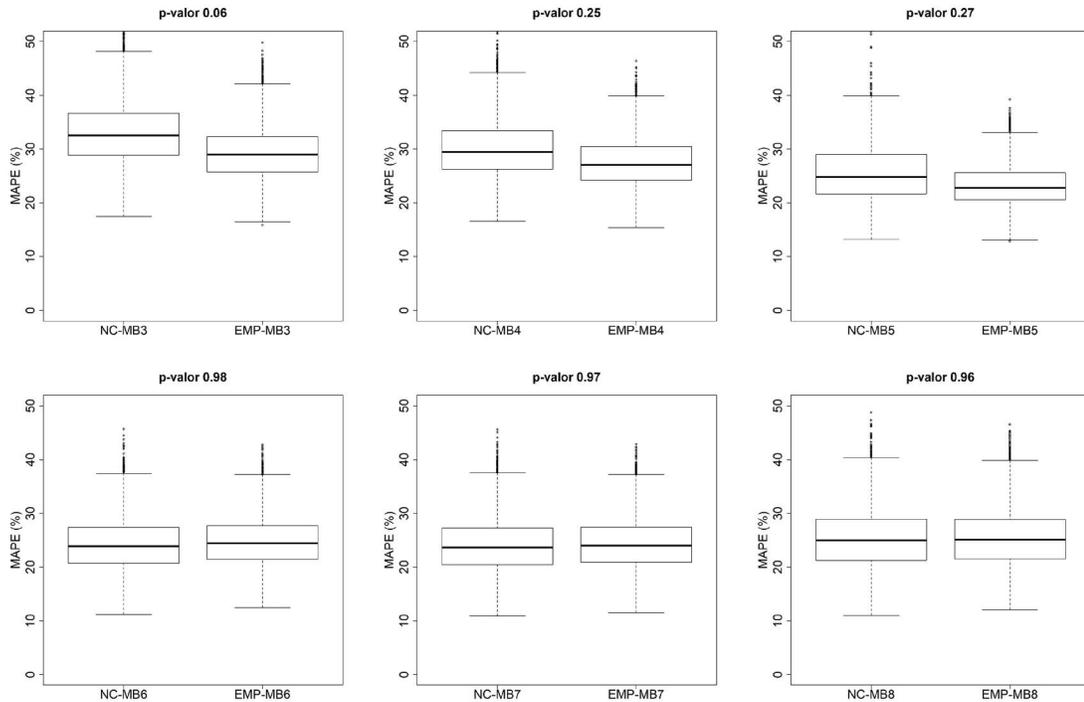
Modelo	MAPE (%)		R ²		RMSE (mgL ⁻¹)	
	TSS	TSI	TSS	TSI	TSS	TSI
$\rho_{w,OB3}$	29,68	47,88	0,79	0,77	24,08	23,77
$\rho_{w,MB3}$	30,45	54,45	0,79	0,77	24,35	24,09
$\rho_{w,WB3}$	29,61	53,39	0,79	0,77	24,06	23,74
$\rho_{w,OB4}$	27,73	43,13	0,86	0,85	10,92	16,32
$\rho_{w,MB4}$	27,86	41,75	0,87	0,86	16,98	15,48
$\rho_{w,WB4}$	27,64	42,00	0,87	0,86	17,28	15,73
$\rho_{w,MB5}$	23,48	39,77	0,91	0,78	13,95	12,67
$\rho_{w,MB6}$	23,75	39,87	0,90	0,85	9,26	9,22
$\rho_{w,MB7}$	23,12	40,87	0,95	0,86	9,04	9,07
$\rho_{w,MB8}$	24,90	42,20	0,95	0,85	9,91	9,23
$\rho_{w,OB5}$	30,52	49,93	0,93	0,92	11,17	10,17
$\rho_{w,MB8A}$	30,54	49,81	0,93	0,92	11,14	10,17
$\rho_{w,WB5}$	24,28	41,75	0,95	0,86	9,31	9,47

Fonte: Produção do autor.

Já os modelos de TSI apresentaram melhores resultados com as variáveis $\rho_{w,MB6}$ e $\rho_{w,MB7}$ (MAPE < 41%, R² > 0,85, RMSE < 9,3 mgL⁻¹). Embora os algoritmos selecionados como melhores não tenham apresentado diferença significativa nos valores de MAPE com o algoritmo $\rho_{w,MB5}$, eles apresentaram valores de R² significativamente maiores (p < 0,05) que o algoritmo $\rho_{w,MB5}$.

Em suma, os resultados de validação para o algoritmo NC utilizando os dados de campo apresentaram resultados similares, porém, significativamente piores em comparação aos modelos empíricos obtidos no Capítulo 4 para as faixas do do visível (verde e vermelho) e na faixa do red-edge (B5) do MSI. Já nas outras faixas do infravermelho próximo do MSI, não houve diferença significativa na estimativa de TSS pelos dois tipos de algoritmos, atestada pelo teste de Wilcoxon.

Figura 5.1 Comparação dos valores de MAPE (%) obtidos para o algoritmo NC e para os algoritmos empíricos (EMP) desenvolvidos no Capítulo 4 para as faixas espectrais do sensor MSI. O p-valor no título de cada figura demonstra a probabilidade do p-valor ser maior que 0,05, conforme descrito na Seção 4.2.2.



Fonte: Produção do autor.

A variação dos coeficientes do algoritmo NC também apresentou dependência em relação ao comprimento de onda, assim como apresentado em Nechad et al. (2010). Entretanto, o coeficiente A^p resultante da calibração com os dados *in-situ* apresentou valores menores na faixa do IVP do que os publicados por Nechad et al. (2010).

Tabela 5.2 Valores dos coeficientes A^p , C^p e B^p calibrados através da simulação Monte Carlo a partir dos dados de ρ_w para os sensores OLI, WFI e MSI, tanto para TSS quanto para TSI.

Modelo	A^p (mgL ⁻¹)		C^p		B^p (mgL ⁻¹)	
	TSS	TSI	TSS	TSI	TSS	TSI
$\rho_{w,OB3}$	278,186	194,274	0,236	0,221	-0,608	-1,972
$\rho_{w,MB3}$	275,168	188,388	0,231	0,217	-0,461	-1,778
$\rho_{w,WB3}$	281,883	197,610	0,230	0,215	-0,108	-1,594
$\rho_{w,OB4}$	291,502	187,957	0,337	0,302	-1,672	-1,489
$\rho_{w,MB4}$	294,144	192,961	0,346	0,307	-0,980	-1,478
$\rho_{w,WB4}$	293,930	191,798	0,345	0,306	-1,341	-1,584
$\rho_{w,MB5}$	291,510	218,319	0,348	0,311	-0,986	-3,005
$\rho_{w,MB6}$	674,009	501,801	0,323	0,268	3,150	-0,202
$\rho_{w,MB7}$	649,713	478,007	0,316	0,265	4,404	0,789
$\rho_{w,MB8}$	824,105	611,291	0,305	0,248	4,398	0,866
$\rho_{w,OB5}$	1090,567	804,299	0,253	0,201	7,102	2,845
$\rho_{w,MB8A}$	1083,578	800,197	0,254	0,201	7,117	2,857
$\rho_{w,WB5}$	763,017	566,942	0,310	0,255	4,265	0,644

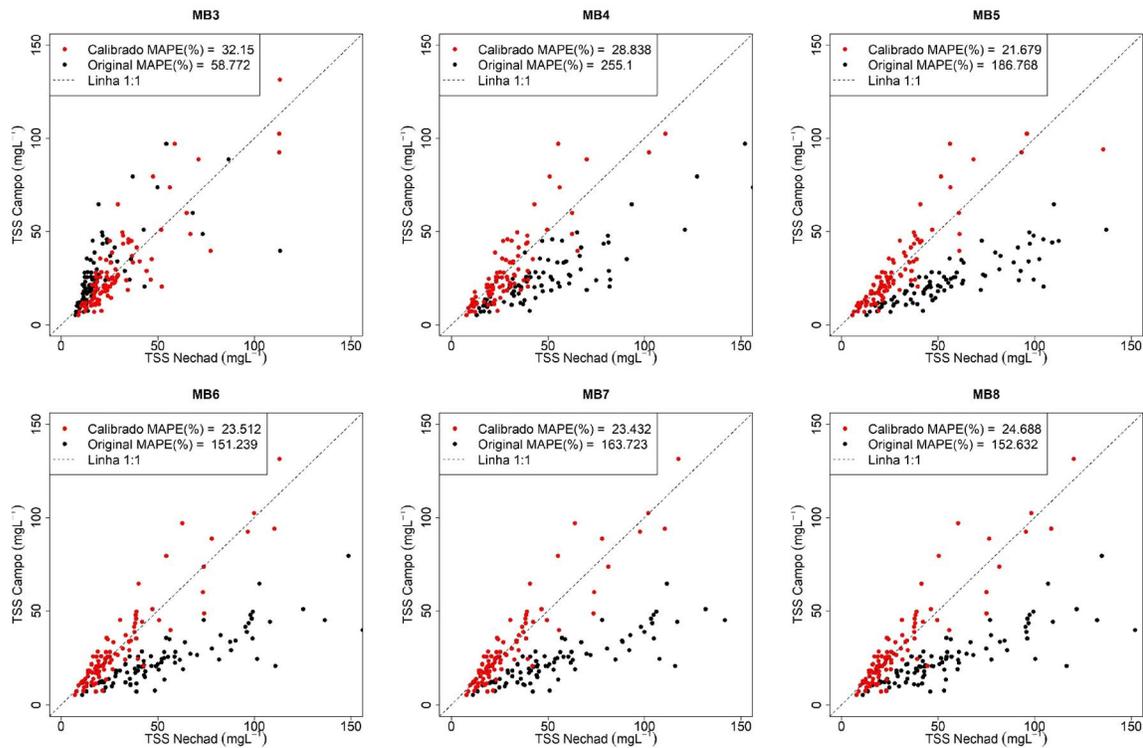
Fonte: Produção do autor.

Os valores de C^p , contudo, apresentaram valores mais altos em relação aos publicados por Nechad et al. (2010) em todos os comprimentos de onda. Esse aumento nos valores de C^p em relação ao comprimento de onda foi observado até o algoritmo que utiliza a $\rho_{w,MB5}$, após isto, os valores de C^p apresentam uma diminuição, comportamento distinto do observado em Nechad et al. (2010), que notaram um aumento proporcional com o comprimento de onda do valor de C^p . Já os valores de B^p ficaram todos abaixo de 7,2 mgL⁻¹, indicando erros relativamente mais baixos nestas estimativas, já que este parâmetro tem relação com as incertezas nas estimativas de concentração de sedimentos e também na ρ_w .

A comparação entre os resultados do NC calibrado com base na ρ_w das bandas simuladas e dos dados de TSS *in-situ* com o NC não calibrado (utilizando os coeficientes propostos por Nechad et al. (2010)), indica que há grande diferença entre eles. Os resultados obtidos a partir dos modelos calibrados com os dados *in-situ* apresentaram em todos os casos resultados melhores de MAPE, com valores menores que 33% em todas as faixas espectrais. Já os

valores de MAPE utilizando os coeficientes propostos por Nechad et al. (2010) apresentaram valores acima de 58% em todas as faixas do MSI.

Figura 5.2 Dispersão dos pontos (n = 93) para os modelos de TSS obtidos através do algoritmo NC calibrados com os dados *in-situ* (pontos vermelhos) e com os coeficientes propostos por Nechad et al. (2010) (pontos pretos).



Fonte: Produção do autor.

A avaliação das incertezas nas estimativas dos coeficientes A^p , B^p e C^p mostrou que, para os valores de A^p tanto para TSS quanto TSI, a menor variação é observada nas faixas espectrais do infravermelho próximo (a partir do algoritmo $\rho_{w,MB6}$), com CV < 11% para estes algoritmos. Já as incertezas na faixa do visível e do red-edge do MSI (B5) não foram menores que 20% em todos os modelos, tanto para TSS quanto para TSI. Já para os valores de C^p , o CV na faixa do IVP apresentou valores menores que 40%, exceto para as faixas de 850 nm do OLI e do MSI ($\rho_{w,OB5}$ e $\rho_{w,MB8A}$).

Apesar de valores de MAPE semelhantes nas faixas do verde e do NIR ($\rho_{w,OB3}$ e $\rho_{w,MB8A}$, MAPE ~20%) a incerteza das estimativas na região do visível pode reduzir a acurácia das predições. O B^p foi o que apresentou maior variação entre os três coeficientes do algoritmo NC (de -198,5% até 1554,3%). Para o B^p , maiores incertezas também são encontradas na faixa do visível. Já para o C^p , o menor CV foi observado nas faixas do IVP, exceto para os modelos $\rho_{w,OB5}$ e $\rho_{w,MB8A}$ (CV > 400% para TSS e CV > 47% para TSI).

Tabela 5.3 Coeficiente de variação (%) do modelo NC para os parâmetros A^p , B^p , C^p para os algoritmos de TSS e de TSI.

Faixa	TSS			TSI		
	A^p	B^p	C^p	A^p	B^p	C^p
$\rho_{w,OB3}$	33,6	-167,3	95,7	43,4	-231	49,9
$\rho_{w,MB3}$	33	-170,6	78,5	41,4	-217,1	45,4
$\rho_{w,WB3}$	33,8	-187,2	98,8	42,9	-241,1	50
$\rho_{w,OB4}$	27,8	-174,4	68,6	36,3	-131,5	56,2
$\rho_{w,MB4}$	26,5	-198,5	63,1	34	-123,5	53,8
$\rho_{w,WB4}$	26,9	-181,8	65	34,5	-123,4	54,3
$\rho_{w,MB5}$	39,8	1554,3	37,5	23,1	-84,8	26,5
$\rho_{w,MB6}$	8,4	40	14,2	10,6	1608,5	10,8
$\rho_{w,MB7}$	8,4	28,5	17,6	10,1	126,9	10,7
$\rho_{w,MB8}$	8,8	30,8	33,4	10,3	140,1	12,8
$\rho_{w,OB5}$	11	21,3	405	11,7	41,6	49,1
$\rho_{w,MB8A}$	11	21,3	588	11,7	41,6	47,7
$\rho_{w,WB5}$	8,6	30,3	23,6	10,3	145,4	12

Fonte: Produção do autor.

5.3.2 Variação dos resultados do algoritmo NC para os modelos separados por campanhas

O algoritmo NC calibrado para cada faixa dos sensores OLI, WFI e MSI aplicado aos dados separados pelas campanhas de campo apresentaram resultados semelhantes aos obtidos pelos algoritmos empíricos. Os algoritmos de TSS (Tabela 5.4) apresentaram resultados melhores nas faixas do infravermelho do MSI em todas as campanhas, diferindo apenas de uma campanha para outra a faixa específica. Nas campanhas de junho de 2015 e

agosto de 2017, o modelo $\rho_{w,MB5}$ (MAPE < 23%, $R^2 > 0,64$, RMSE < 4,25 mgL⁻¹), apresentou o melhor desempenho, como também observado em relação aos modelos empíricos separados por campanhas (Figura 4.3). Já nas campanhas de campo de 2016, o algoritmo NC apresentou os melhores resultados nas faixas de maior comprimento de onda do IVP ($\rho_{w,MB7}$ e $\rho_{w,MB8}$) (MAPE < 25%, $R^2 > 0,69$ e RMSE < 15,25 mgL⁻¹), à semelhança do que ocorreu com os modelos empíricos, exceto que na campanha de julho de 2016, o melhor algoritmo empírico utilizou a variável preditora $\ln(R_{rs,sim_MB8A})$. Os erros resultantes da divisão dos dados por campanhas também são semelhantes aos obtidos pela simulação Monte Carlo utilizando o conjunto completo (MDC). Ainda, é possível observar que em todos os casos valores de MAPE < 25% podem ser encontrados, principalmente nas faixas do IVP do MSI.

Tabela 5.4 Valores de MAPE (%), R^2 e RMSE (mgL⁻¹) para os algoritmos de TSS para o modelo NC aplicado nos dados separados por campanhas.

Modelo	MAPE (%)				R^2				RMSE (mgL ⁻¹)			
	jun/15	mar/16	jul/16	ago/17	jun/15	mar/16	jul/16	ago/17	jun/15	mar/16	jul/16	ago/17
$\rho_{w,OB3}$	28,88	42,17	24,38	34,9	0,57	0,65	0,24	0,75	4,9	34,29	11,56	5,81
$\rho_{w,MB3}$	28,59	42,98	24,64	37,02	0,57	0,64	0,23	0,75	4,87	35,25	11,61	6,03
$\rho_{w,WB3}$	29,85	42,09	24,24	34,7	0,57	0,65	0,24	0,75	4,97	34,1	11,58	5,79
$\rho_{w,OB4}$	33,33	32,44	21,78	24,83	0,62	0,76	0,39	0,7	5,96	24,95	9,98	4,79
$\rho_{w,MB4}$	34,99	31,12	22,11	24,81	0,63	0,78	0,4	0,7	6,2	23,81	9,9	4,73
$\rho_{w,WB4}$	33,68	31,5	21,79	24,71	0,63	0,77	0,41	0,7	6,01	24,1	9,85	4,73
$\rho_{w,MB5}$	22,77	27,58	17,26	19,87	0,64	0,82	0,61	0,85	4,25	21,21	8,06	3,74
$\rho_{w,MB6}$	25,76	25,38	16,14	27,56	0,54	0,9	0,63	0,79	4,78	15,78	7,78	4,5
$\rho_{w,MB7}$	26,14	24,92	14,98	28,68	0,54	0,91	0,67	0,79	4,8	15,25	7,58	4,66
$\rho_{w,MB8}$	27,93	26,63	14,65	30,86	0,49	0,89	0,69	0,72	5,01	16,39	7,42	5,07
$\rho_{w,OB5}$	36,81	29,11	15,96	42,96	0,33	0,87	0,66	0,43	5,93	18,11	8,5	6,96
$\rho_{w,MB8A}$	36,74	28,97	16,07	42,88	0,34	0,87	0,66	0,44	5,91	18,03	8,51	6,94
$\rho_{w,WB5}$	27,12	25,88	14,83	29,64	0,51	0,9	0,68	0,75	4,93	15,93	7,51	4,86

Valores em negrito representam os melhores em cada coluna. (Veja o número de amostras em cada campanha na Tabela 3.1). A paleta de cores representa os melhores (em verde) para os piores (em vermelho) resultados para cada coluna.

Fonte: Produção do autor.

Já os algoritmos NC para estimativa de TSI apresentaram erros maiores do que os dos algoritmos para estimativa de TSS. Apesar dos erros maiores, os padrões de desempenho dos algoritmos de TSI são similares aos observados nos algoritmos para TSS. Em junho de 2015 o melhor desempenho foi observado com a variável $\rho_{w,MB5}$ (MAPE = 34,85%, $R^2 = 0,68$, RMSE = 3,51 mgL^{-1}). Na campanha de março de 2016 o melhor desempenho também foi para a faixa $\rho_{w,MB7}$ (assim como observado nos algoritmos de TSS) (MAPE = 36,6%, $R^2 = 0,91$, RMSE = 14,44 mgL^{-1}).

Já as campanhas de julho de 2016 e agosto de 2017 os melhores resultados para TSI foram diferentes do observado para TSS, porém, em faixas espectrais semelhantes. Em julho de 2016 para algoritmo de TSI o melhor desempenho é do algoritmo que utiliza a variável $\rho_{w,OB5}$ (semelhante à faixa $\rho_{w,MB8}$, de melhor desempenho para os modelos de TSS). Este resultado, contudo, apresentou baixa correlação com os valores *in-situ* de TSI (MAPE = 31,63%, $R^2 = 0,39$, RMSE = 9,25 mgL^{-1}). Já em agosto de 2017, o melhor resultado foi obtido para a $\rho_{w,MB4}$ (MAPE = 31,61%, $R^2 = 0,8$, RMSE = 3,47 mgL^{-1}).

Tabela 5.5 Valores de MAPE (%), R^2 e RMSE (mgL^{-1}) para os algoritmos de TSI para o modelo NC aplicado nos dados separados por campanhas

Modelo	MAPE (%)				R^2				RMSE (mgL^{-1})			
	jun/15	mar/16	jul/16	ago/17	jun/15	mar/16	jul/16	ago/17	jun/15	mar/16	jul/16	ago/17
$\rho_{w,OB3}$	57,25	57,86	43,87	59,4	0,58	0,66	0,05	0,74	4,33	31,96	12,09	5,16
$\rho_{w,MB3}$	55,26	56,96	43,67	60,9	0,57	0,65	0,04	0,71	4,28	32,05	12,28	5,3
$\rho_{w,WB3}$	60,41	58,55	43,78	59,86	0,58	0,66	0,06	0,75	4,42	32,26	12,03	5,15
$\rho_{w,OB4}$	65,98	41,61	37,16	33,02	0,65	0,78	0,34	0,8	4,77	22,58	10,07	3,59
$\rho_{w,MB4}$	65,71	40,3	35,81	31,61	0,66	0,79	0,39	0,8	4,81	21,79	9,86	3,47
$\rho_{w,WB4}$	64,42	40,85	36,26	31,97	0,66	0,79	0,37	0,8	4,73	22,03	9,89	3,49
$\rho_{w,MB5}$	34,85	40,06	37,1	39,9	0,68	0,84	0,35	0,8	3,51	19,13	9,43	3,75
$\rho_{w,MB6}$	44,06	37,28	35,5	51,12	0,58	0,91	0,33	0,75	4,07	14,88	9,63	4,2
$\rho_{w,MB7}$	46,7	36,6	32,79	52,69	0,58	0,91	0,38	0,76	4,11	14,44	9,4	4,28
$\rho_{w,MB8}$	51,87	37,81	32,85	57,35	0,53	0,9	0,39	0,7	4,25	15,29	9,25	4,6
$\rho_{w,OB5}$	70,89	40,57	31,63	74,95	0,36	0,88	0,35	0,43	5	16,66	9,9	5,96
$\rho_{w,MB8A}$	70,89	40,59	31,65	74,9	0,36	0,88	0,35	0,44	4,99	16,62	9,89	5,95
$\rho_{w,WB5}$	48,64	37,07	32,76	54,68	0,55	0,9	0,39	0,72	4,19	14,94	9,32	4,43

Valores em negrito representam os melhores em cada coluna. (Veja o número de amostras em cada campanha na Tabela 3.1). A paleta de cores representa os melhores (em verde) para os piores (em vermelho) resultados para cada coluna.

Fonte: Produção do autor.

5.3.3 Resultados do algoritmo NC aplicado aos lagos Curuai e Monte Alegre

O algoritmo NC, quando aplicado aos dados separados entre os lagos de Curuai e Monte Alegre apresentou melhor desempenho, tanto para TSS quanto para TSI, com menores valores de MAPE para o modelo $\rho_{w,MB5}$ (MAPE < 23% para TSS e MAPE < 43% para TSI) (Tabela 5.6), à semelhança do que foi observado para os algoritmos empíricos separados por lagos.

Os modelos de TSI apresentaram valores de MAPE mais altos do que os computados para os modelos de TSS, como também observado nos algoritmos empíricos. Apesar dos maiores erros observados para a faixa do verde, seus resultados ainda são satisfatórios para as estimativas de TSS, com valores de R^2 acima de 0,8.

Tabela 5.6 Valores de MAPE (%), R^2 e RMSE (mgL^{-1}) para os algoritmos de TSS e TSI para o modelo NC aplicado nos dados separados pelos lagos de Curuai e Monte Alegre.

Modelo	Algoritmos de TSS						Algoritmos de TSI					
	MAPE (%)		R^2		RMSE (mgL^{-1})		MAPE (%)		R^2		RMSE (mgL^{-1})	
	Curuai	MA	Curuai	MA	Curuai	MA	Curuai	MA	Curuai	MA	Curuai	MA
$\rho_{w,OB3}$	32,95	31,27	0,8	0,92	18,23	15,32	59,99	51,73	0,79	0,89	16,86	16,39
$\rho_{w,MB3}$	33,65	31,71	0,8	0,91	18,72	15,44	59,13	52,58	0,79	0,88	16,88	16,77
$\rho_{w,WB3}$	33,04	32	0,8	0,92	18,12	15,38	61,28	53,19	0,79	0,89	17,02	16,34
$\rho_{w,OB4}$	29,53	20,66	0,86	0,93	13,62	12,65	50,33	44,01	0,87	0,95	11,76	14,49
$\rho_{w,MB4}$	29,73	20,86	0,87	0,93	13,08	12,55	49,14	42,71	0,88	0,95	11,33	14,29
$\rho_{w,WB4}$	29,38	20,45	0,87	0,93	13,17	12,6	49,18	42,47	0,88	0,96	11,44	14,35
$\rho_{w,MB5}$	22,39	19,63	0,91	0,95	10,72	13,12	42,17	31,07	0,91	0,97	9,9	13,5
$\rho_{w,MB6}$	23,48	24,56	0,95	0,97	8,19	12,37	45,97	39,78	0,95	0,96	7,82	13,75
$\rho_{w,MB7}$	23,15	25,75	0,95	0,97	7,98	12,08	45,66	42,67	0,95	0,96	7,51	13,74
$\rho_{w,MB8}$	24,66	26,08	0,95	0,96	8,46	12,54	49,19	44,09	0,95	0,97	7,91	13,84
$\rho_{w,OB5}$	30,94	34,24	0,93	0,95	9,78	13,89	59,13	58,16	0,93	0,93	8,77	15,12
$\rho_{w,MB8A}$	30,87	34,26	0,93	0,95	9,75	13,87	59,13	58,15	0,93	0,93	8,76	15,08
$\rho_{w,WB5}$	23,9	25,96	0,95	0,97	8,23	12,43	47,09	42,75	0,95	0,97	7,72	13,85

Veja o número de amostras em cada campanha na Tabela 4.2. A paleta de cores representa os melhores (em verde) para os piores (em vermelho) resultados para cada coluna.

Fonte: Produção do autor.

5.4 Discussão

Os modelos NC calibrados com os dados de todas as campanhas para estimar TSS e TSI apresentaram melhor desempenho nas faixas do IVP. Tanto para TSS quanto para TSI, o coeficiente de determinação (R^2) resultante da validação por simulação Monte Carlo apresentou valores acima de 0,77, indicando alta correlação entre a concentração de sedimentos estimada pelo algoritmo NC com os dados observados *in-situ*. Nechad et al. (2010) também encontraram coeficientes de correlação elevados (entre 0,537 em 560 nm a 0,82 em 708 nm) ao utilizar a p_w simulada para as faixas espectrais do sensor MERIS, para uma amplitude de concentração entre 0 ~ 100 mgL^{-1} ($R^2 \sim 0.89$), com o melhor desempenho observado na faixa espectral do MERIS centrada em 708 nm. Em comprimentos de onda maiores, há maiores incertezas nas medidas de refletância (RUDDICK et al., 2006) nesta amplitude de variação de TSS e, em comprimentos de onda menores (e.g. faixa do verde) há a saturação para concentrações acima de 30 mgL^{-1} (ELEVELD et al., 2008).

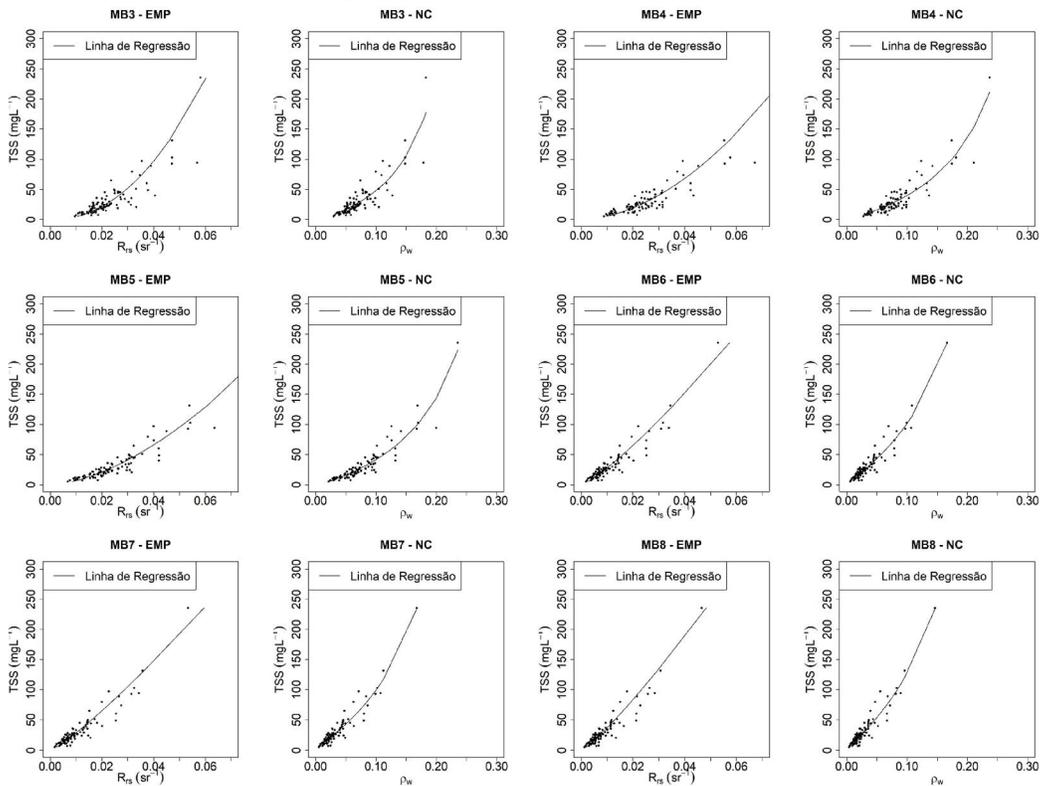
Neste trabalho, observou-se que comprimentos de onda mais longos apresentaram melhores resultados, o que ocorreu devido a maior amplitude de concentração que as observadas por Nechad et al. (2010). Os maiores erros na faixa do verde podem ser atribuídos ainda à variabilidade no a_{np} , principalmente relacionada à absorção pelo CDOM e também à variabilidade da absorção específica do TSS (NECHAD; RUDDICK; PARK, 2010). Estas duas fontes de incertezas podem ser corretamente atribuídas a este conjunto de dados visto que, no decorrer das campanhas há uma variação na concentração de CDOM (veja em Silva, 2018, com valores médios de $a_{CDOM}(440)$ de 1,60 m^{-1} , 1,06 m^{-1} e 1,89 m^{-1} para as campanhas de junho/2015, março/2016 e julho/2016) e também na relação TSI/TSS (Veja na Tabela 3.1), indicando diferentes origens e características físicas dos sedimentos.

Os modelos NC e empíricos apresentam valores de MAPE semelhantes nas faixas do IVP. Entretanto, nas faixas do visível (verde e vermelho) e na faixa do red-edge (B5 MSI) o algoritmo NC apresentou maiores erros que os algoritmos empíricos. Esta diferença principalmente na faixa do visível pode estar

relacionada com o comportamento assintótico da R_{rs} (ou da ρ_w) (Figura 5.3) na medida que aumenta a concentração de TSS e TSI e também com as premissas físicas do algoritmo proposto por Nechad et al. (2010).

Como os algoritmos empíricos utilizam a R_{rs} e a concentração de TSS e TSI com transformação logarítmica, esta linearização tende a reduzir o erro a eles associados, apesar da modelagem não-linear utilizada pelo NC com o intuito de diminuir este efeito. Pode se observar na Figura 5.3 que a relação entre a R_{rs} e a ρ_w com a concentração de TSS tende a se tornar linear com o aumento dos comprimentos de onda devido à menor saturação destas faixas espectrais com o aumento da concentração de sedimentos (GIARDINO et al., 2017).

Figura 5.3 Dispersão dos pontos de TSS e modelagem para os algoritmos empíricos (EMP) e pelo algoritmo NC (NC) para as faixas do MSI.

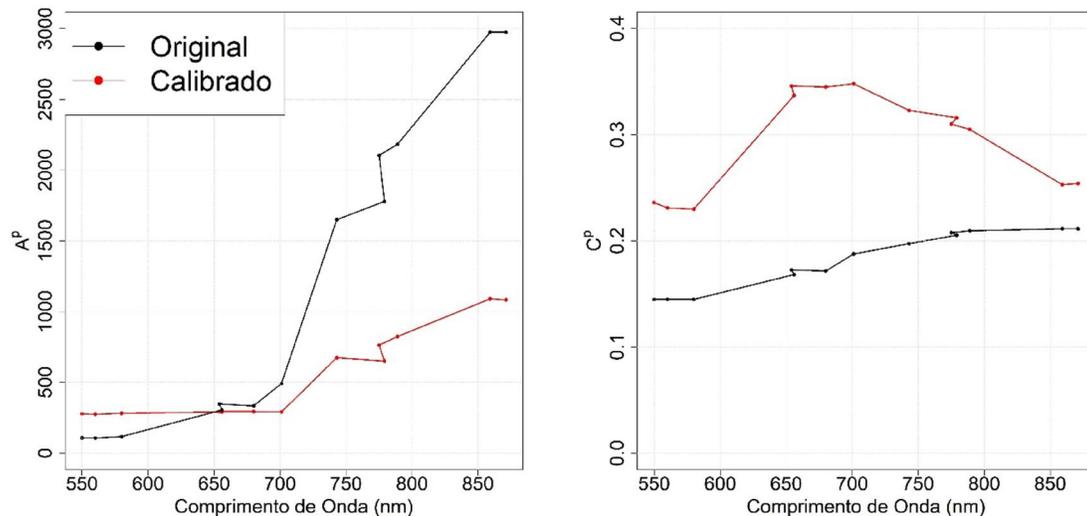


Fonte: Produção do autor.

Já em relação aos coeficientes obtidos por meio da calibração do algoritmo NC para as faixas espectrais do OLI, WFI e MSI, estes apresentaram valores diferentes daqueles obtidos por Nechad et al. (2010). Como estes coeficientes são dependentes das IOPs, é de se esperar diferenças em cada calibração.

Esta diferença fica clara ao se observar a aplicação do algoritmo NC com os coeficientes propostos por Nechad et al. (2010) nas estimativas de TSS (Veja na Figura 5.2). Há uma superestimativa da concentração de TSS em todos os comprimentos de onda quando se utiliza o NC original em relação ao algoritmo calibrado para a região de estudo. Como o regime linear do algoritmo NC é dependente principalmente do coeficiente A^P (NECHAD et al. 2010; SANDER DE CARVALHO, 2016), vê-se que a calibração foi necessária para a correta linearização do algoritmo NC em relação aos dados *in-situ*, o que não ocorria com os coeficientes originais (Figura 5.4). Esta superestimativa nas faixas do vermelho ao IVP fez com que os erros fossem extremamente altos para o algoritmo NC original (MAPE > 150%).

Figura 5.4 Variação do coeficiente A^P e C^P do algoritmo NC em relação aos valores calibrados *in-situ* e o original publicado por Nechad et al. (2010) para os comprimentos de onda centrais dos sensores OLI, WFI e MSI.



Fonte: Produção do autor.

Já o coeficiente C^p apresentou valores maiores que os determinados por Nechad et al. (2010). Ainda, os valores calibrados de C^p foram maiores que os valores de γ (0,2156). Estes maiores valores de γ sugerem que para o conjunto de dados utilizados nesse estudo, não é possível supor a relação $\gamma = \pi R f / Q = 0,216$ (Veja na Seção 5.2.1).

Como o valor de A^p é dependente da absorção pelo material não particulado (a_{np}), pode-se considerar que em comprimentos de onda maiores (e.g. 780, 850 nm) esta absorção é equivalente à absorção da água pura, devido ao elevado valor de a_w em relação ao a_{np} . Considerando assim, por exemplo, que na banda 5 do OLI ($a_w^{OB5} = 4,601 \text{ m}^{-1}$ (POPE; FRY, 1997) = a_{np}^{OB5}), a absorção é apenas pela água, pela Equação 5.2 e isolando-a em relação ao b_{bp}^* , tem-se que:

$$b_{bp}^* = \frac{a_w^{OB5}}{A^p \cdot \gamma} \quad (5.4)$$

Sendo $a_w^{OB5} = 4,601 \text{ m}^{-1}$, $A^{p,OB5} = 1090,567 \text{ mgL}^{-1}$, $C^{p,OB5} = 0,253$ (A^p e C^p obtidos dos coeficientes calibrados com os dados *in-situ*), é possível determinar o valor de b_{bp}^* . O valor de b_{bp}^* em 865 nm obtido através da Equação 5.4 foi de $0,01956 \text{ m}^2\text{g}^{-1}$, valores condizentes com os obtidos *in-situ* no Lago Grande de Curuai durante outras campanhas de campo por Sander de Carvalho (2016). Com o uso dos parâmetros propostos por Nechad et al. (2010) o valor estimado de $b_{bp}^* = 0,00731 \text{ mg}^2\text{g}^{-1}$, seria 2,27 vezes menor que os valores de b_{bp}^* de Sander de Carvalho (2016) para o Lago Grande de Curuai.

O papel da variação do coeficiente A^p para o aumento dos erros pode ser também observado ao se avaliar a variação nos valores de MAPE e R^2 com a variação do valor de A^p e de C^p . A variação no valor de A^p causa um impacto nos valores de MAPE maior do que a variação do C^p (Figura 5.5). Entretanto, os valores de A^p não são responsáveis pela variação na correlação entre o TSS estimado pelo algoritmo NC e os valores de TSS obtidos *in-situ*.

Na Figura 5.5b é possível observar uma dependência dos valores de R^2 apenas para a variação do C^p . Assim, pode-se supor que a calibração realizada possibilitou melhores resultados já que os coeficientes obtidos foram maiores e

seguem a tendência observada na Figura 5.5. Ainda, vê-se que o valor de C^p influenciou mais em comprimentos de onda menores, com sua influência diminuindo com o aumento do comprimento de onda. De fato, isto é explicitado por Nechad et al. (2010), os quais pontuam que o coeficiente C^p apresenta menor sensibilidade desde que o limite assintótico da p_w seja evitado. Os maiores erros neste conjunto de dados para o C^p utilizando os valores tabelados pode ser atribuído à esta diferença. Ainda, estes resultados demonstram a necessidade da calibração também do C^p para o conjunto de dados utilizado neste trabalho (diferentemente do observado por Nechad et al. (2010)), já que este coeficiente é dependente do coeficiente de retroespalhamento e absorção específico pelo particulado.

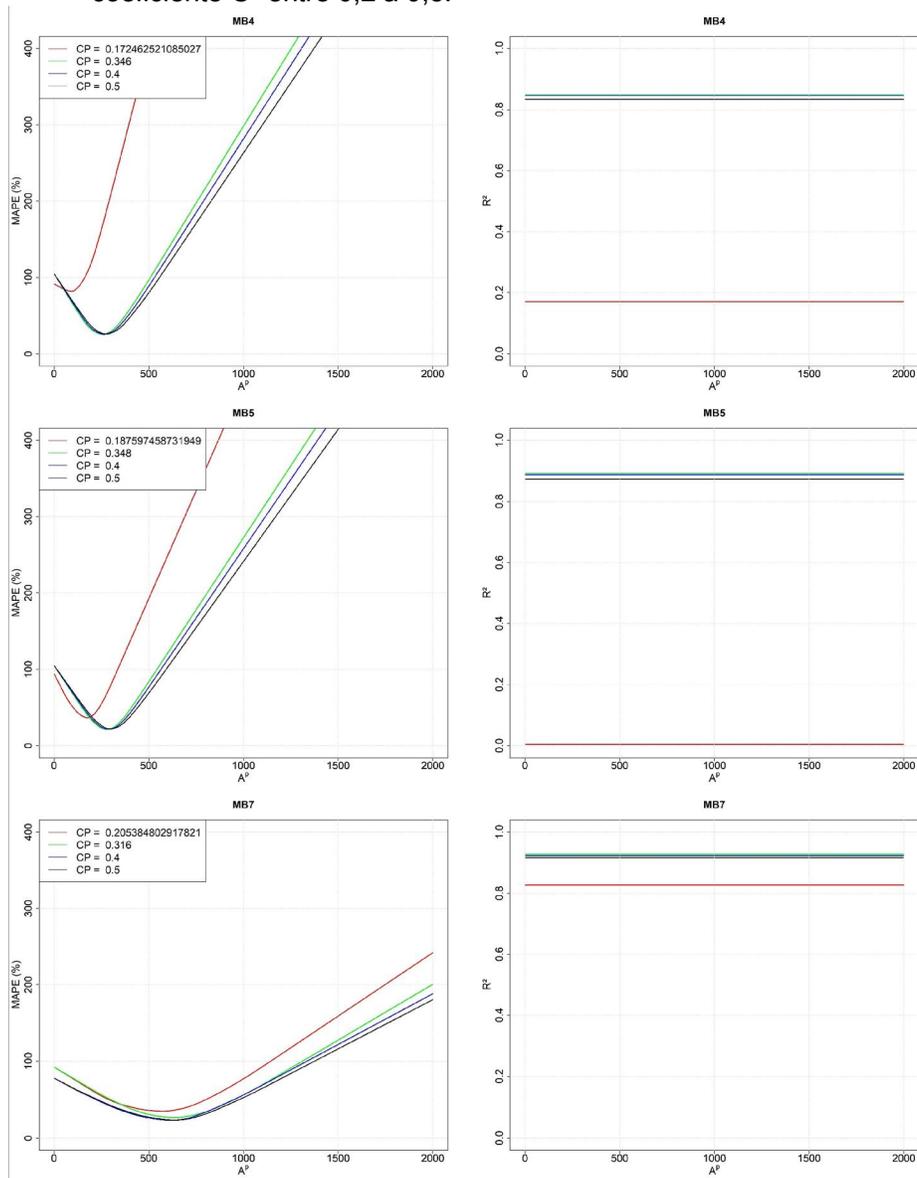
Em relação às incertezas obtidas através do cálculo do coeficiente de variação (CV) para os coeficientes A^p , C^p e B^p , estas foram maiores nas faixas do visível. Esta maior incerteza nas estimativas dos coeficientes pode estar associada à variação na absorção por CDOM, pela variação na absorção e espalhamento do material particulado em suspensão nestas faixas e também à saturação destas faixas em concentrações de TSS e TSI mais altas (NECHAD et al. 2010). Estas variações ferem algumas das premissas do algoritmo NC levando a este aumento de incertezas, principalmente em relação à absorção pelo CDOM e variação da absorção e retroespalhamento específico do material particulado.

As incertezas na faixa do vermelho e também na faixa do red-edge do MSI (B5) podem ser associadas à variação da concentração de Chl-a durante as campanhas (Veja nos arquivos suplementares WA1 em NECHAD et al. 2010). Já as faixas do IVP apresentaram menor variação entre as 10000 simulações de Monte Carlo, indicando que a variação do conjunto de dados de entrada do algoritmo nesta faixa espectral não teve grande influência (CV < 10%) na estimativa dos valores de A^p e C^p .

A variação dos erros (MAPE) do algoritmo NC ao ser aplicado a ambientes diferentes também depende da fase da hidrógrafa e dos lagos estudados (Veja os resultados nas seções 5.3.2 e 5.3.3), assim como o observado nos

algoritmos empíricos. Entretanto, é importante salientar, que nesse caso o algoritmo NC não foi calibrado para os diferentes tipos de dados (Separados por Campanhas e Por Lagos), tendo sido apenas aplicados os valores de A^p , C^p e B^p resultantes da calibração por simulação de Monte Carlo usando o conjunto completo (MDC). As estimativas de TSS apresentaram melhores resultados para a faixa $\rho_{w,MB5}$ nas campanhas de junho de 2015 e agosto de 2017.

Figura 5.5 Valores de MAPE (%) e R² para a variação do coeficiente A^p para a faixa $\rho_{w,MB4}$, $\rho_{w,MB5}$ e $\rho_{w,MB7}$ para valores entre 1 e 2000 de A^p e para variações no coeficiente C^p entre 0,2 a 0,5.



As linhas em vermelho e verde representam os valores de C^p e A^p obtidos através dos coeficientes originais do algoritmo NC e da calibração com os dados *in-situ*, respectivamente. As linhas azuis e pretas são para C^p = 0,4 e 0,5, respectivamente.

Fonte: Produção do autor.

Nechad et al. (2010) também encontraram melhores resultados de validação para uma concentração de sedimentos média de 26,2 mgL⁻¹ na faixa de 708

nm, próxima do comprimento de onda central da $\rho_{w,MB5}$ (~705 nm). Já com o aumento da concentração de TSS, como é observado nas campanhas de março e julho de 2016, os melhores resultados são para faixas espectrais com comprimentos de onda maiores, assim como observado por alguns estudos (CABALLERO; STEINMETZ; NAVARRO, 2018; NOVOA et al., 2017).

Já os resultados de TSI, apresentaram maiores valores de MAPE, como também observado nos algoritmos empíricos. Ainda, os melhores resultados seguiram o observado para os modelos de TSS, com menores valores de MAPE para comprimentos de onda menores nas épocas com baixas concentrações e menores valores de MAPE em comprimentos de onda maiores nas campanhas com maiores concentrações. Para as campanhas separadas para os lagos de Curuai e Monte Alegre, os melhores valores de MAPE foram observados para o modelo $\rho_{w,MB5}$ em ambos os lagos.

5.5 Conclusões

A calibração e validação do algoritmo NC para as faixas espectrais dos sensores OLI, WFI e MSI permitiu a obtenção de valores de TSS com acurácia adequada para estimativas por sensoriamento remoto (MAPE < 25%) utilizando as faixas do IVP do MSI (B5, B6, B7, B8) e da WFI (B5). Entretanto, os valores de MAPE para as estimativas de TSI foram sempre maiores que 39%, indicando maiores erros nestas estimativas, o que pode inviabilizar a utilização deste algoritmo por sensoriamento remoto. Os resultados também demonstraram que, na faixa do visível (faixas do verde e vermelho) e do red-edge do MSI (705 nm) os algoritmos empíricos apresentaram resultados de MAPE melhores do que os obtidos com o NC. Já nas outras faixas do IVP do MSI, os algoritmos não apresentaram diferenças estatisticamente significativas entre os valores de MAPE. Ainda, foi possível observar que os coeficientes tabelados propostos por Nechad et al. (2010) não foram adequados à área de estudo. Assim, a calibração do algoritmo NC foi necessária e apresentando sensível melhor de desempenho.

6 ESTIMATIVA DE TSS E TSI POR SATÉLITE

6.1 Introdução

Nas últimas décadas, o uso de sensores remotos para o monitoramento da concentração de sólidos em suspensão na água está aumentando, sendo muito utilizado para ampliar o conhecimento sobre as propriedades de corpos d'água e também para avaliar padrões regulatórios de qualidade de água (LEPOT; AUBIN; BERTRAND-KRAJEWSKI, 2013). Esse aumento foi muito dependente do avanço na tecnologia dos sensores remotos orbitais nos últimos 30 anos, principalmente com o advento dos novos sensores de observação da terra como o Landsat-8/OLI, CBERS-4/WFI e Sentinel-2/MSI. Estes sensores proporcionam alta resolução espacial e boa relação sinal-ruído (SNR, da sigla em inglês), o que torna sua aplicação em ambientes aquáticos propícia, mesmo que estes sensores não tenham sido desenvolvidos para esta finalidade (AQUINO DA SILVA et al., 2015; PAHLEVAN et al., 2018). Ainda, a combinação destes sensores propicia um aumento na frequência de aquisição em ambientes que possuem uma dinâmica hidrológica grande ou alta cobertura de nuvens, como é o caso da bacia Amazônica (ASNER, 2001; LI; ROY, 2017; MARTINS et al., 2018a; PAHLEVAN et al., 2018).

Entretanto, o uso R_{rs} derivada de sensores orbitais demanda a realização da correção atmosférica para a quantificação acurada dos COAs, já que ela remove efeitos atenuantes dos constituintes presentes, na atmosfera e que alteram o sinal registrado pelo sensor como gases (e.g. vapor d'água, oxigênio, ozônio e dióxido de carbono) e aerossóis (VERMOTE et al., 1997; ZULLO-JUNIOR, 1994). Devido ao baixo sinal refletido pelos corpos d'água, a contribuição total da atmosfera no sinal recebido pelo sensor remoto pode chegar à 95% em faixas com comprimento de onda mais curtos (e.g. azul, 400-500 nm) (MARTINS et al., 2017). Neste sentido, o uso preciso da informação obtida por sensoriamento remoto (geralmente a R_{rs}) para avaliação dos COAs é dependente da minimização destes efeitos atmosféricos. Diversas metodologias de correção atmosférica já foram desenvolvidas, como algoritmos

baseados na imagem (LOUIS et al., 2016; VANHELLEMONT; RUDDICK, 2016), que extraem da própria imagem as informações sobre o espalhamento atmosférico e os baseados em Equações de Transferência Radiativa (ETR) que, a partir de dados físicos de entrada simulam a REM espalhada e absorvida pela atmosfera (VERMOTE et al., 1997; ZULLO-JUNIOR, 1994).

Apesar dos vários métodos existentes, ainda não há um consenso sobre os mais adequados para cada tipo de água e seu desempenho é bastante variável em função das características da atmosfera (MARTINS et al., 2018b; VANHELLEMONT; RUDDICK, 2015; VERMOTE et al., 2016) e do tipo de água (DE KEUKELAERE et al., 2018; MARTINS et al., 2017; WEI et al., 2018).

Além dos efeitos da atmosfera, outro fator que influencia diretamente no sinal recebido pelo sensor é a reflexão especular da água (*glint*) (MOBLEY, 1994). Esta reflexão pode ser proveniente de uma reflexão direta especular da luz do sol (*sunglint*) ou uma reflexão difusa de todo o céu (*skyglint*), demandando assim correção também de seus efeitos (HARMEL et al., 2018). A incidência de *glint* é dependente principalmente de fatores de geometria de aquisição dos dados (e.g. FOV – *field of view*, ângulo de visada, ângulo azimutal e zenital do sol) (HARMEL et al., 2018; HOCHBERG; ANDRÉFOUËT; TYLER, 2003; STREHER et al., 2014a) e velocidade do vento, que provoca ondas capilares e afeta a rugosidade da superfície da água (COX; MUNK, 1954; MOBLEY, 2015).

Como a radiância refletida pela superfície da água não carrega informação acerca dos COAs nela presentes, ela também – assim como o espalhamento e absorção pelos constituintes atmosféricos – deve ser removida. Existem diversos métodos para a remoção de *glint* e podem ser encontrados em diversos trabalhos na literatura (COX; MUNK, 1954; HARMEL et al., 2018; HOCHBERG; ANDRÉFOUËT; TYLER, 2003; KAY; HEDLEY; LAVENDER, 2009; STREHER et al., 2014b; WANG; SHI, 2007). Este sinal de *glint* pode ser aproximado através da utilização da R_{rs} em faixas do infravermelho médio se considerarmos que após a correção atmosférica todo o sinal nesta faixa espectral é proveniente da interface ar-água (WANG; SHI, 2007).

Neste sentido, este capítulo teve como objetivo a validação de métodos de correção atmosférica para os sensores OLI, WFI e MSI e de uma correção de *glint* (WANG; SHI, 2007) utilizando dados de R_{rs} *in-situ* simulada para estes três sensores. Além disto, os algoritmos empíricos (Capítulo 4) e o algoritmo semi-analítico (Capítulo 5) calibrados com os dados de $R_{rs,sim}$ e ρ_w *in-situ* para TSS e TSI foram aplicados nas imagens corrigidas para a validação dos modelos a avaliação de sua acurácia.

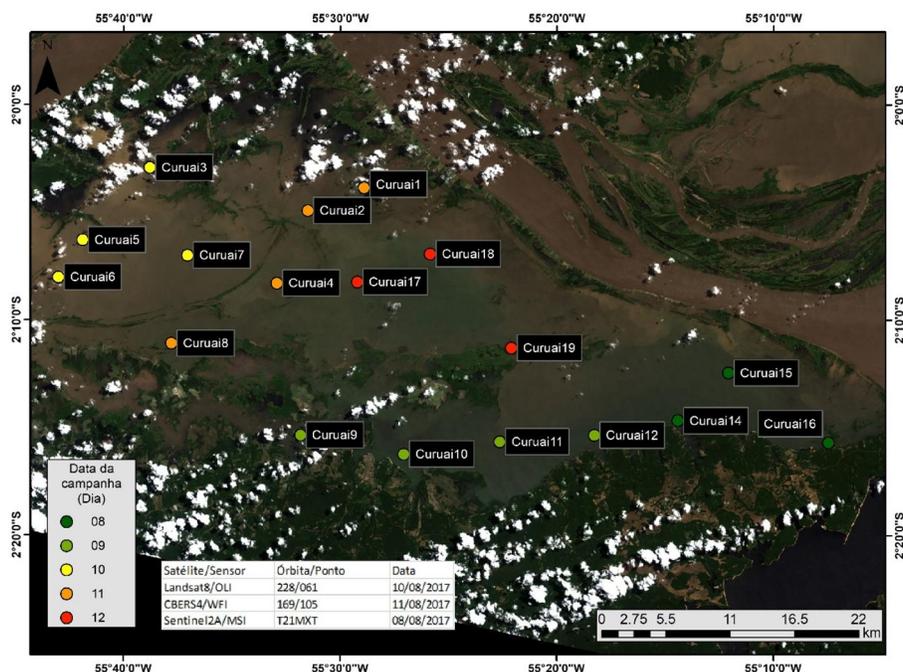
6.2 Materiais e métodos

6.2.1 Dados orbitais

Neste trabalho foram utilizados dados orbitais provenientes dos sensores OLI, a bordo do satélite Landsat-8, WFI, a bordo do satélite CBERS-4 e do sensor MSI, a bordo do satélite Sentinel 2A. Estes três sensores possuem características distintas (Tabela 3.2) no tocante à resolução espacial, espectral, radiométrica, largura de faixa e relação sinal ruído (SNR). Apesar das características distintas, diversos autores mostram a acurácia na estimativa de TSS a partir dos sensores OLI e MSI (NOVOA et al., 2017; PAHLEVAN et al., 2017; VANHELLEMONT; RUDDICK, 2014, 2016). Entretanto, a utilização do sensor WFI para estimativa de TSS e TSI ainda não é documentado na literatura.

Nesta análise, foram utilizados apenas os dados da campanha de agosto de 2017, devido à proximidade com a passagem dos três satélites e à baixa cobertura de nuvens. As imagens obtidas correspondem à órbita-ponto 228/61 (OLI), datada de 10 de agosto de 2017. Para a WFI, a imagem obtida é de 11 de agosto de 2017 para a órbita ponto 169/105. Já a imagem Sentinel 2A foi obtida para o tile T21MXT em 08 de agosto de 2017. A campanha de campo de agosto de 2017 foi realizada entre os dias 08-12 de agosto (Veja a relação entre as datas realizadas a coleta em cada estação na Figura 6.1).

Figura 6.1 Localização das estações amostrais e datas em que foram realizadas as coletas em Curuai para a campanha de agosto de 2017.



Fonte: Produção do autor.

6.2.2 Correção atmosférica e de glint

Três métodos de correção atmosférica foram testados para os sensores OLI e MSI e um para o sensor WFI: Para o sensor OLI foram utilizados:

a) O produto fornecido pela NASA - Landsat 8 Surface Reflectance – em refletância de superfície baseado no código *Land Surface Reflectance Code* (LaSRC – código disponível em: <https://github.com/USGS-EROS/espa-surface-reflectance/tree/master/lasrc>) (VERMOTE et al., 2016) e cujo bom desempenho em águas interiores encontra-se bem documentado (BERNARDO et al., 2017; WEI et al., 2018; YEPEZ et al., 2018);

b) O código de transferência radiativa 6S (*Second Simulation Of The Satellite Signal In The Solar Spectrum*) (VERMOTE et al., 1997) com os parâmetros físicos de entrada baseados em Martins et al. (2017b). O 6S é um código que resolve a equação de transferência radiativa com base em dados físicos que

descrevem a composição da atmosfera e sua eficiência depende da qualidade dos dados atmosféricos necessários para simular a transferência radiativa na atmosfera. Utilizou-se uma versão modificada do Py6S (WILSON, 2013) desenvolvida pelo Laboratório de Instrumentação em Sistemas Aquáticos do INPE (LabISA - <http://www.dpi.inpe.br/labisa>) para rodar o 6S ((CARLOS; DE SOUZA MARTINS; BARBOSA, 2019));

c) O ACOLITE (VANHELLEMONT; RUDDICK, 2014, 2015), um método de correção atmosférica baseado na própria imagem, neste estudo utilizou o SWIR para o cálculo do espalhamento por aerossol nas outras faixas espectrais (MARTINS et al., 2017; NOVOA et al., 2017) visto que devido à alta concentração de sedimentos, o sinal do NIR é excessivamente alto e a água não se comporta como um objeto escuro.

Com o sensor MSI foram utilizados: a) 6S; b) ACOLITE; c) Sen2Cor, o qual este último também se baseia em medidas obtidas das imagens para modelar o efeito da atmosfera (LOUIS et al., 2016). Já para o sensor WFI, foi avaliada apenas a utilização do 6S. A conversão dos dados em número digital da WFI para refletância no topo de atmosfera foi realizada a partir dos coeficientes de ganho e *offset* propostos por Pinto et al. (2016) e, em seguida, os parâmetros obtidos pelo 6S foram aplicados para obtenção da refletância de superfície, conforme descrito em (MARTINS et al., 2018b).

Após a correção atmosférica, obteve-se a reflectância de superfície, a qual foi então dividida por π para se obter a R_{rs,sat_ac} . Também foi realizada a correção dos efeitos de glint a partir da metodologia proposta por Wang e Shi (2007), em que a reflectância na faixa do infravermelho médio (SWIR, da sigla em inglês *Short-wave Infrared*) é subtraída das faixas do visível e do infravermelho próximo (VNIR, da sigla em inglês *Visible and Near-Infrared*), conforme Equação 6.1.

$$R_{rs,sat_ac_deglint}(VNIR) = R_{rs,sat_ac}(VNIR) - R_{rs,sat_ac}(SWIR) \quad (6.1)$$

6.2.3 Validação da correção atmosférica e de glint e dos algoritmos empíricos e semi-analíticos

Para avaliar o desempenho dos diferentes métodos de correção atmosférica com e sem remoção do glint, a R_{rs,sat_ac} e a $R_{rs,sat_ac_deglint}$ foi comparada com a $R_{rs,sim}$ para os sensores OLI, WFI e MSI. Foram removidos os pontos com contaminação por nuvens através de análise visual e posteriormente foi computado o valor de R_{rs,sat_ac} e $R_{rs,sat_ac_deglint}$ para cada estação da campanha de Agosto/2017 a partir da média de uma janela 3x3 pixels. Os resultados foram avaliados por faixa espectral e também para todo o conjunto de dados, de modo similar ao realizado por Wei et al. (2018), em que todo o conjunto de bandas é avaliado. As estatísticas R^2 e MAPE foram utilizadas para avaliar os resultados das correções atmosférica e de glint para os sensores OLI ($n = 17$), WFI ($n = 11$) e MSI ($n = 14$). Foi também avaliada a igualdade entre os dados de $R_{rs,sim}$ e R_{rs,sat_ac} e $R_{rs,sat_ac_deglint}$ através da aplicação do teste-t.

Os algoritmos empíricos e semi-analíticos calibrados pela simulação Monte Carlo foram então aplicados às imagens corrigidas e as estatísticas R^2 e MAPE foram computadas com base nos valores de $R_{rs,sat_ac_deglint}$ e R_{rs,sat_ac} das cenas OLI, WFI e MSI submetidas aos diferentes métodos de correção atmosférica, com esta validação realizada utilizando como referência os dados de TSS e TSI obtidos *in-situ*. A partir disto, o algoritmo com o melhor resultado encontrado foi selecionado para a espacialização e geração dos mapas de TSS e TSI para cada um dos três sensores.

6.3 Resultados

6.3.1 Correção atmosférica e de glint

As três metodologias de correção atmosférica avaliadas para o sensor OLI (Figura 6.2) apresentaram valores de MAPE menores que 40% para as faixas do visível para os três métodos de correção atmosférica avaliados. Entretanto, valores de MAPE maiores que 150% foram encontrados para a faixa do IVP. Quando todas as faixas espectrais do OLI foram avaliadas em conjunto (Veja

na caixa inferior à direita da Figura 6.2), os valores de MAPE foram de cerca de 50%.

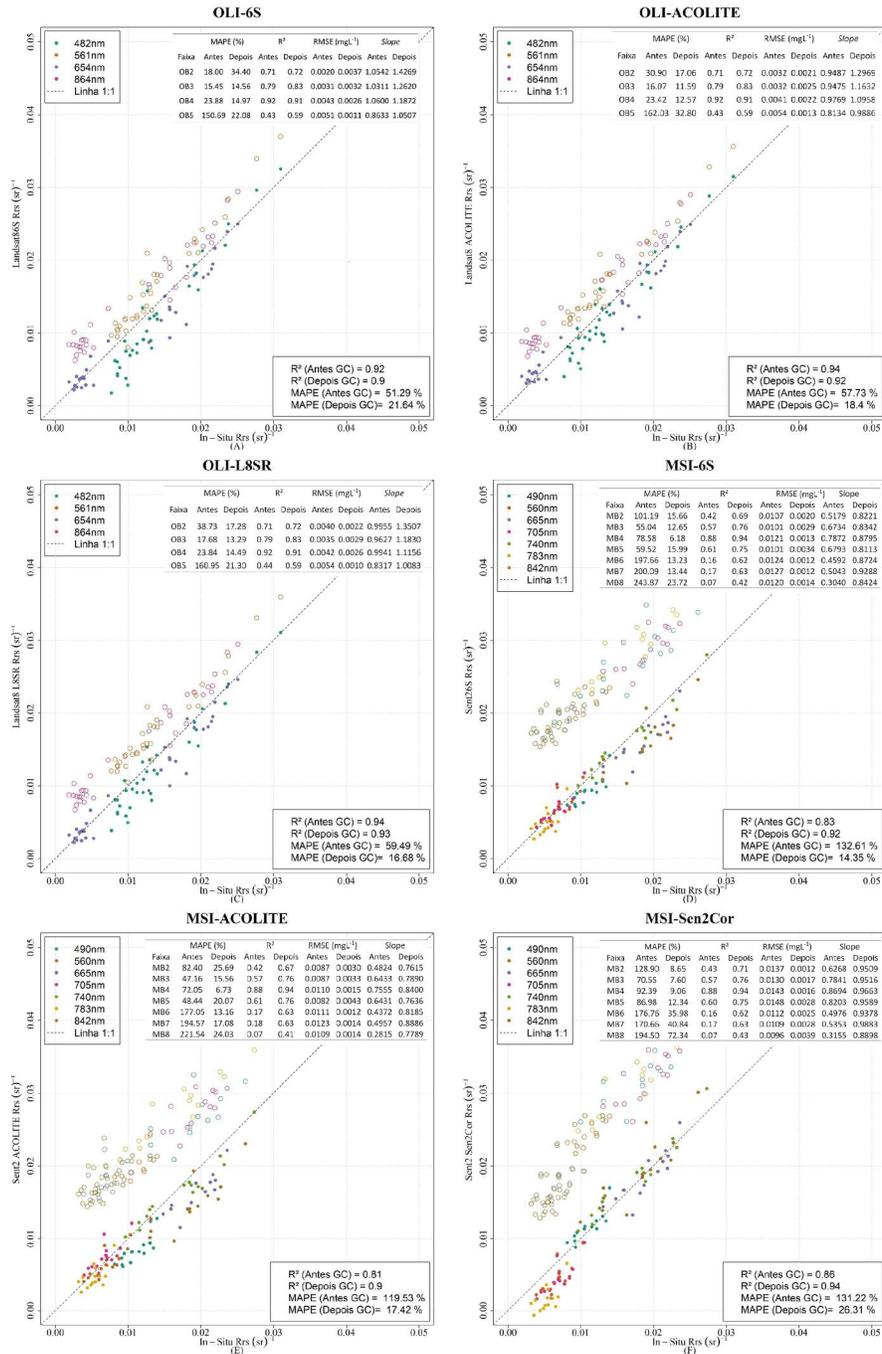
As diferenças nos valores de R^2 são negligenciáveis (~1%) quando comparadas todas as faixas do OLI. Comparativamente, o L8SR ($R_{rs,OLI_L8SR_deglint}$) (Figura 6.2c) após a correção do glint resultou no melhor desempenho para o conjunto das bandas do OLI (MAPE = 16,68%, $R^2 = 0,93$). A avaliação por faixa espectral (Veja a tabela superior à direita nas Figura 6.2a,b e c) mostra que, para o OLI os valores de MAPE na faixa do azul aumentaram após a correção por glint quando se utilizou a correção atmosférica pelo 6S ($R_{rs,OLI_6S_deglint}$). Já nas outras faixas espectrais, a correção do glint diminuiu os valores de MAPE, que foram menores que 15% para as faixas do verde e vermelho independentemente do método de correção atmosférica e menores que 23% para o $R_{rs,OLI_6S_deglint}$ e $R_{rs,OLI_L8SR_deglint}$ na faixa do IVP. O impacto neste caso da correção dos efeitos de glint apresentou resultados satisfatórios, com reduções nos valores de MAPE em todas as faixas espectrais do OLI (exceto a faixa do azul para a correção atmosférica pelo 6S) e também no conjunto com todas as faixas.

Através do teste-t, pode ser avaliada a igualdade entre os valores de R_{rs,sim_OLI} e os valores de $R_{rs,OLI_deglint}$. Para a faixa do azul e verde, os três métodos apresentaram valores significativos (p -valor < 0.05) indicando que à 95% de confiança há diferenças entre os dados de R_{rs} *in-situ* e os obtidos pelo sensor OLI. Já na faixa do vermelho, o 6S e o ACOLITE apresentaram valores não significativos indicando igualdade entre os valores (p -valor > 0.05). No IVP, o 6S e o L8SR apresentaram valores não significativos.

Para o MSI, os resultados mostram que a interferência do sinal do glint foi grande em todas as faixas espectrais (Figura 6.2), com valores de MAPE acima de 119% para todas as faixas do VNIR. Observaram-se reduções do valor de MAPE superiores a 100% para todas as faixas espectrais após a correção do glint independentemente do método de correção atmosférica utilizado. Além disso, a correção pelo glint propiciou um aumento nos valores de R^2 independentemente também do método de correção. O modelo de correção

atmosférica com melhor desempenho foi obtido pelo 6S (Figura 6.2d) após a correção do glint ($R_{rs,MSI_6S_deglint}$), com valores de MAPE = 14,35% e $R^2 = 0,92$ para as faixas espectrais do VNIR. Para as faixas espectrais separadas do sensor MSI (Veja a tabela superior à direita nas Figura 6.2d, e e f), a correção de glint mostrou bons resultados, com uma grande diminuição nos valores de MAPE (> 100% em alguns casos). Nos comprimentos de onda do azul, verde e do red-edge (B2, B3, B5) do MSI o método Sen2Cor ($R_{rs,MSI_S2C_deglint}$) obteve o melhor desempenho. Já nas faixas do vermelho e do IVP em 783 e 842 nm (B4, B7, B8) o melhor desempenho foi observado com método 6S ($R_{rs,MSI_6S_deglint}$). O ACOLITE ($R_{rs,MSI_ACO_deglint}$) somente apresentou o melhor desempenho para a B6 (740 nm), porém com pequena diferença em relação ao 6S.

Figura 6.2 Resultados da correção atmosférica e correção do *glint* avaliados com relação à dados de R_{rs} obtidos *in-situ*.



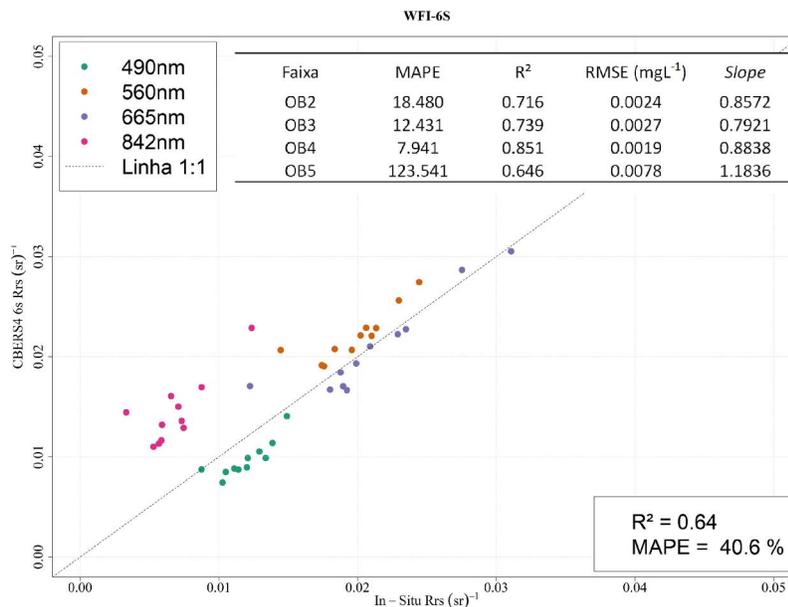
Caixa superior à esquerda se refere ao comprimento de onda central das faixas do OLI (em nm) enquanto que a caixa superior a direita se refere aos valores de MAPE, R^2 , RMSE e *Slope* para cada faixa espectral dos sensores OLI e MSI antes e depois da correção por *glint*. Valores de R^2 e MAPE (%) na caixa inferior à direita são relativos a todos os dados antes (Antes GC) e depois (Depois GC) da correção por *glint*.

Fonte: Produção do autor.

A comparação entre os dados de R_{rs} *in-situ* e os obtidos pelos três métodos de correção atmosférica mostrou que, para as bandas do azul, verde e red-edge (B5) apenas o Sen2Cor apresentou p-valor não significativo (> 0.05). Já na banda do vermelho e nas outras bandas do IVP, apenas o 6S e o ACOLITE apresentaram valores não significativos, indicando igualdade nos dados de R_{rs} .

Os resultados para o sensor WFI (Figura 6.3) mostraram uma boa relação nas faixas do visível (MAPE $< 20\%$, $R^2 > 0.7$), com maiores erros na faixa do IVP (MAPE $> 100\%$). Ainda, os erros para todas as faixas fossem menores (menores valores de MAPE) que os observados para o OLI e o MSI antes da correção por glint. Porém, os valores de R^2 foram menores que os obtidos para o OLI e MSI antes da correção por glint, principalmente devido aos maiores erros na faixa do IVP. Para as faixas da WFI, apenas a faixa do vermelho apresentou p-valor não significativo (> 0.05) indicando igualdade entre as médias à 95% de confiança.

Figura 6.3 Resultados da correção atmosférica avaliados com relação à dados de R_{rs} obtidos *in-situ* para o sensor WFI.



Caixa superior à esquerda se refere ao comprimento de onda central das faixas do WFI (em nm) enquanto que valores de R^2 e MAPE (%) na caixa inferior à direita são relativos a todos os dados.

Fonte: Produção do autor.

6.3.2 Aplicação dos algoritmos empíricos de TSS e de TSI nas imagens

A aplicação dos algoritmos empíricos para o sensor OLI (Tabela 6.1) utilizando as faixas do visível apresentaram bons resultados, sendo que a região do verde apresentou valores de MAPE menores que 21% independentemente do método de correção atmosférica utilizado, tanto para TSS quanto para TSI. As faixas do vermelho e do IVP apresentaram resultados satisfatórios para os modelos $\ln(R_{rs,OLI-6S-deg\text{lint}})$ e $\ln(R_{rs,OLI-L8SR-deg\text{lint}})$ (MAPE < 35% para TSS e TSI). Entretanto, os valores de MAPE aumentam quando se utiliza o ACOLITE (MAPE > 48%). Já os modelos com razão de banda apresentaram valores de MAPE maiores que 60% (Resultados não mostrados aqui). O melhor resultado para TSS utilizando o sensor OLI foi com o modelo $\ln(R_{rs,OB3-L8SR-deg\text{lint}})$ (MAPE = 16,68%, $R^2 = 0,71$), enquanto que para o TSI, o melhor resultado foi utilizando o $\ln(R_{rs,OB3-ACO-deg\text{lint}})$ (MAPE = 18,16, $R^2 = 0,86$).

Tabela 6.1 Valores de MAPE (%), R^2 , RMSE (mgL^{-1}) e *Slope* para os algoritmos empíricos de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor OLI (n = 16).

Atm.Cor	Banda	MAPE (%)		R2		RMSE (mgL^{-1})		Slope	
		TSS	TSI	TSS	TSI	TSS	TSI	TSS	TSI
L8SR	B3	16.68	19.78	0.71	0.86	3.50	2.31	0.95	0.78
	B4	29.06	33.16	0.62	0.74	5.37	3.64	1.08	0.90
	B5	27.63	35.98	0.63	0.76	4.21	2.73	0.69	0.60
6S	B3	18.53	20.64	0.71	0.86	3.73	2.34	1.01	0.83
	B4	30.31	32.66	0.62	0.74	5.56	3.53	1.16	0.99
	B5	27.96	36.03	0.63	0.76	4.31	2.71	0.71	0.63
ACOLITE	B3	16.79	18.16	0.71	0.86	3.47	2.08	0.95	0.79
	B4	26.64	29.52	0.62	0.75	5.07	3.33	1.08	0.92
	B5	48.73	61.53	0.62	0.76	6.95	4.18	0.65	0.59

Fonte: Produção do autor.

A comparação com os dados de TSS e TSI estimados utilizando a faixa do verde com os três métodos de correção atmosférica apresentou diferença significativa ($p\text{-valor} < 0.05$) através do teste-t pareado, indicando que houve, à 95% de confiança, diferença na utilização destes três métodos de correção

atmosférica para as estimativas de TSS e TSI na faixa do verde. Já na faixa do vermelho, os algoritmos de TSS e TSI obtidos através da correção atmosférica pelo 6S e ACOLITE apresentaram p-valor não significativo, indicando igualdade entre as duas estimativas nesta faixa. Na faixa do IVP, as comparações dos três métodos apresentaram diferença significativa à 95% de confiança (p -valor < 0.05). Entre os diversos algoritmos (i.e. bandas), a única combinação à apresentar igualdade foram entre os algoritmos que utilizam a banda 3 e 4 após a correção atmosférica pelo 6S e correção de glint.

Como o melhor resultado para o OLI foi obtido para a faixa do verde, foram comparados os algoritmos empíricos gerados através do conjunto de dados separados por campanha (utilizando os coeficientes para Agosto/2017) e para o conjunto separado por Lagos (utilizando os coeficientes para Curuai) usando o método de correção atmosférica 6S. Estes resultados mostram que, em relação aos valores de MAPE o conjunto de dados completo ainda apresentou o melhor resultado em relação aos outros conjuntos avaliados.

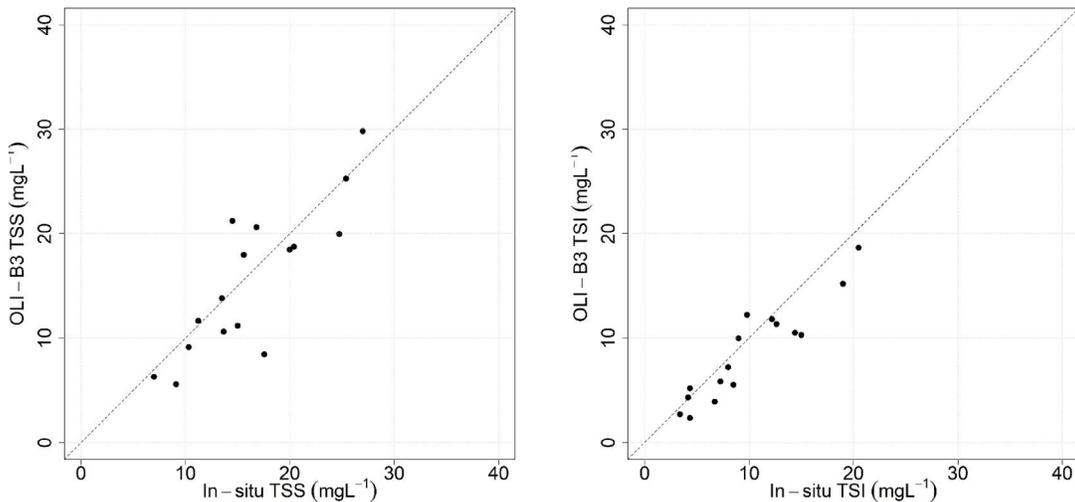
Tabela 6.2 Valores de MAPE, R^2 , RMSE e *Slope* para os algoritmos empíricos obtidos através do conjunto de dados completo, apenas para a campanha de agosto de 2017 e apenas para o Lago de Curuai para o sensor OLI.

Modelo	Banda	MAPE (%)		R2		RMSE (mgL ⁻¹)		Slope	
		TSS	TSI	TSS	TSI	TSS	TSI	TSS	TSI
Completo	B3-6S	18.53	20.63	0.71	0.86	3.73	2.34	1.01	0.82
Agosto/17	B3-6S	28.45	33.86	0.71	0.86	4.99	3.24	1.00	0.94
Curuai	B3-6S	21.26	29.97	0.71	0.86	4.05	3.52	0.94	0.71

Fonte: Produção do Autor.

O bom resultado da utilização da faixa 3 do OLI também pode ser visualizado pela dispersão dos valores de TSS e TSI em relação aos dados *in-situ* (Figura 6.4). A proximidade com a linha 1:1 mostra que os valores de TSS e TSI foram estimados com uma boa acurácia.

Figura 6.4 Dispersão dos dados de TSS e TSI para o algoritmo empírico $\ln(R_{rs,OB3_6S_deglint})$ utilizando a correção atmosférica pelo 6S aplicado ao sensor OLI.



Fonte: Produção do Autor.

Em relação ao MSI (Tabela 6.3) os valores de MAPE foram semelhantes aos do OLI para a faixa do verde utilizando o 6S e o ACOLITE (MAPE ~17%). Já na faixa do vermelho, os resultados para o MSI foram melhores tanto para TSS quanto para TSI em relação aos do OLI (MAPE < 24%). Os modelos usando a faixa do IVP em 705 nm (B5) e 740 nm (B6) também apresentaram bons resultados com o 6S e ACOLITE (MAPE < 22%). Exceto em relação aos modelos $\ln(R_{rs,MB4_6S_deglint})$ e $\ln(R_{rs,MB6_6S_deglint})$ para a estimativa de TSS, o método de correção atmosférica de melhor desempenho foi o 6S.

Tabela 6.3 Valores de MAPE (%), R², RMSE (mgL⁻¹) e *Slope* para os algoritmos de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor MSI (n = 14).

Atm. Cor	Faixa	MAPE (%)		R ²		RMSE (mgL ⁻¹)		<i>Slope</i>	
		TSS	TSI	TSS	TSI	TSS	TSI	TSS	TSI
Sen2Cor	B3	25.31	29.21	0.59	0.73	4.81	2.84	0.85	0.71
	B4	21.11	20.92	0.56	0.68	4.97	3.17	1.01	0.88
	B5	26.71	27.28	0.68	0.81	5.83	3.02	1.12	0.96
	B6	30.01	36.35	0.62	0.68	5.96	4.99	0.80	0.58
	B7	32.29	39.45	0.63	0.69	6.23	5.07	0.86	0.63
	B8	65.91	73.43	0.34	0.40	12.14	8.52	0.62	0.43
6S	B3	17.64	22.12	0.59	0.72	3.62	3.27	0.69	0.55
	B4	21.96	22.94	0.56	0.68	4.54	3.50	0.89	0.74
	B5	17.80	20.80	0.68	0.80	3.76	3.30	0.86	0.68
	B6	17.56	27.54	0.61	0.68	3.67	2.95	0.74	0.59
	B7	22.67	30.74	0.62	0.69	4.29	2.91	0.80	0.65
	B8	24.49	36.83	0.36	0.41	4.97	4.10	0.63	0.50
ACOLITE	B3	17.83	22.61	0.59	0.72	3.90	3.69	0.63	0.50
	B4	21.51	22.75	0.56	0.68	4.47	3.59	0.84	0.70
	B5	21.74	27.67	0.68	0.80	4.50	4.09	0.79	0.60
	B6	14.93	25.63	0.62	0.68	3.41	3.17	0.69	0.54
	B7	30.17	39.77	0.62	0.69	5.25	3.32	0.76	0.63
	B8	23.60	37.04	0.35	0.40	4.90	4.24	0.58	0.46

Fonte: Produção do Autor.

O algoritmo empírico ($\ln(R_{rs,MB5_6S})$) de melhor desempenho resultou da utilização do conjunto completo de dados, à semelhança do que ocorreu com o sensor OLI (Tabela 6.4).

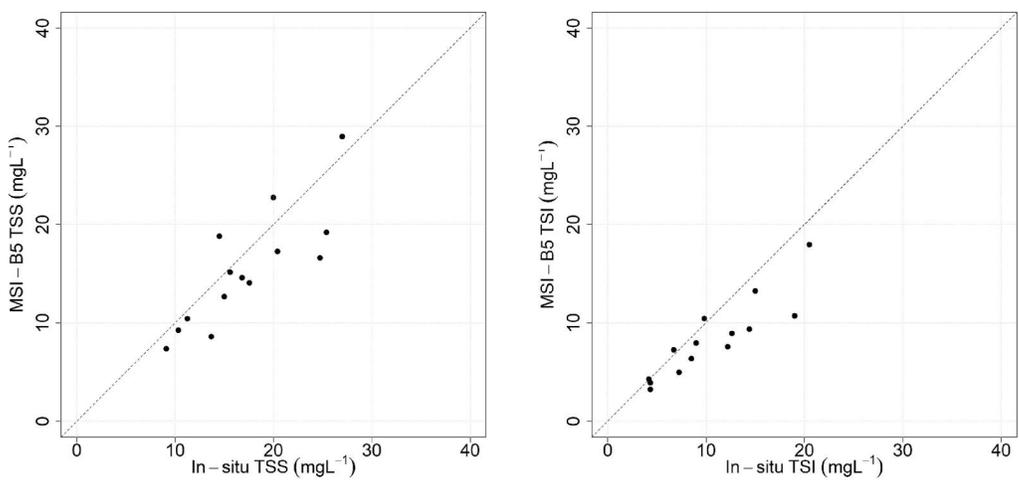
Tabela 6.4 Valores de MAPE, R², RMSE e *Slope* para os algoritmos empíricos obtidos através do conjunto de dados completo, apenas para a campanha de agosto de 2017 e apenas para o Lago de Curuai para o sensor MSI.

Modelo	Banda	MAPE (%)		R ²		RMSE (mgL ⁻¹)		Slope	
		TSS	TSI	TSS	TSI	TSS	TSI	TSS	TSI
Completo	B5-6S	17.80	20.80	0.68	0.8	3.76	3.3	0.87	0.68
Agosto/17	B5-6S	21.09	23.17	0.69	0.8	4.53	3.69	0.73	0.63
Curuai	B5-6S	20.35	29.44	0.68	0.8	4.19	4.20	0.83	0.60

Fonte: Produção do Autor.

Assim como o observado para o OLI, a dispersão (Figura 6.5) dos valores de TSS e TSI também indica boa correlação dos valores estimados pelo modelo em relação aos observados *in-situ* para o sensor MSI.

Figura 6.5 Dispersão dos dados de TSS e TSI para o algoritmo empírico $\ln(R_{rs,MB5_6S_deg\text{lint}})$ utilizando a correção atmosférica pelo 6S aplicado ao sensor MSI.



Fonte: Produção do autor.

Os resultados para a WFI apresentaram erros maiores que os observados com o OLI e com o MSI. Um maior valor de MAPE foi obtido na faixa do azul tanto para TSS quanto para TSI em comparação com os outros dois sensores. Entretanto, apesar do valor de R^2 ser maior para a WFI, o *slope* apresenta resultados mais distantes de 1, indicando menor linearidade entre os dados estimados pela WFI.

Tabela 6.5 Valores de MAPE (%), R^2 , RMSE (mgL^{-1}) e *Slope* para os algoritmos empíricos com transformação logarítmica de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor WFI ($n = 11$).

Atm.Co	Faixa	MAPE		R2		RMSE		Slope	
		TSS	TSI	TSS	TSI	TSS	TSI	TSS	TSI
6S	B3	41.22	36.01	0.81	0.79	7.74	4.82	0.55	0.49
	B4	25.22	28.11	0.57	0.65	5.59	4.72	0.64	0.61
	B5	131.11	146.23	0.69	0.62	25.01	17.85	0.97	0.93

Fonte: Produção do autor.

Na faixa do vermelho, os erros são menores ($MAPE < 30\%$) para TSS e TSI, entretanto, os valores de R^2 apresentam menores valores em relação à faixa do verde. Porém, estes valores são próximos aos obtidos para o MSI nesta faixa. Já a faixa do IVP, apresentou valores de MAPE e RMSE muito altos ($MAPE > 130\%$) principalmente devido aos erros na correção atmosférica nesta faixa e também a falta de correção por glint para o WFI.

Comparando-se os modelos WFI obtidos para todas as campanhas verifica-se que os valores de MAPE são ligeiramente menores para o algoritmo calibrado com os dados de agosto de 2017. Entretanto, os valores de *slope* são maiores para o modelo baseado no conjunto completo de dados quando comparados ao modelo baseado nos dados de agosto de 2017 e com o modelo baseado nos dados de Curuai.

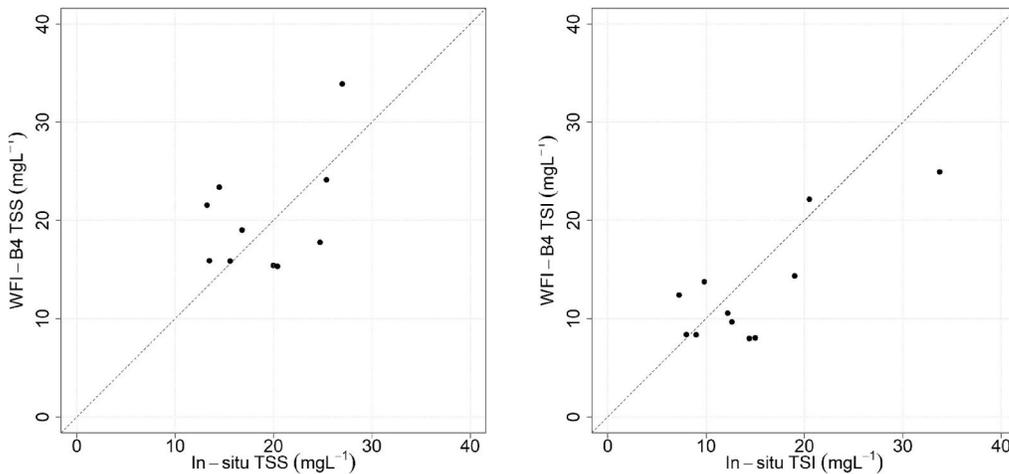
Tabela 6.6 Valores de MAPE, R², RMSE e *Slope* para os algoritmos empíricos obtidos através do conjunto de dados completo, apenas para a campanha de agosto de 2017 e apenas para o Lago de Curuai para o sensor WFI.

Modelo	Banda	MAPE (%)		R ²		RMSE (mgL ⁻¹)		Slope	
		TSS	TSI	TSS	TSI	TSS	TSI	TSS	TSI
Completo	B4-6S	25.23	28.11	0.57	0.65	5.59	4.72	0.64	0.61
Agosto/17	B4-6S	23.70	27.97	0.55	0.64	5.92	4.57	0.41	0.56
Curuai	B4-6S	25.19	28.29	0.57	0.65	5.56	5.24	0.62	0.55

Fonte: Produção do Autor.

Apesar de valores de MAPE menores que 30%, ao se observar a dispersão dos dados estimados em relação aos dados medidos *in-situ*, os resultados apresentam-se mais dispersos do que o observado para o OLI e o MSI. Este fato também ocorre em relação aos valores de R² e *slope*, que não apresentaram resultados satisfatórios (R² < 0.66 e *slope* < 0.62) para TSS e TSI.

Figura 6.6 Dispersão dos dados de TSS e TSI para o algoritmo empírico $\ln(R_{rs, WB4_6S})$ utilizando a correção atmosférica pelo 6S aplicado ao sensor WFI.



Fonte: Produção do autor.

6.3.3 Aplicação dos modelos semi-analíticos baseados nas imagens

A utilização do algoritmo proposto por Nechad et al. (2010) recalibrado com os dados em campo para o sensor OLI apresentou resultados de MAPE próximos aos obtidos com os algoritmos empíricos. Os melhores resultados para TSS e TSI foram observados com os modelos que utilizam a faixa do verde e correção atmosférica pelo 6S (Tabela 6.7).

À semelhança dos modelos empíricos obtidos com o OLI, os três métodos de correção atmosférica apresentaram diferenças estaticamente significativas na faixa do verde (p -valor < 0.05). Novamente, assim como para os algoritmos empíricos, os resultados na faixa do vermelho foram não-significativos (p -valor > 0.05) na comparação entre o ACOLITE e o 6S.

Tabela 6.7 Valores de MAPE (%), R^2 , RMSE (mgL^{-1}) e *Slope* para os algoritmos NC de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor OLI (n = 16).

Atm.Cor	Banda	MAPE (%)		R ²		RMSE (mgL^{-1})		Slope	
		TSS	TSI	TSS	TSI	TSS	TSI	TSS	TSI
L8SR	B3	17.62	25.70	0.71	0.85	3.42	2.27	0.86	0.76
	B4	24.79	24.09	0.62	0.75	4.84	2.66	1.06	0.88
	B5	33.02	52.08	0.62	0.76	4.74	3.57	0.57	0.54
6S	B3	17.56	23.22	0.71	0.86	3.44	2.11	0.91	0.81
	B4	26.26	25.12	0.62	0.75	5.17	2.8	1.15	0.96
	B5	33.36	52.15	0.61	0.76	4.82	3.57	0.59	0.56
ACOLITE	B3	19.94	29.70	0.71	0.85	3.67	2.48	0.85	0.76
	B4	22.56	25.26	0.62	0.75	4.71	2.67	1.06	0.88
	B5	51.03	78.11	0.61	0.76	7.11	5.27	0.57	0.54

Fonte: Produção do Autor.

O MSI (Tabela 6.8) apresentou melhores resultados quando utilizados os métodos de correção atmosférica pelo 6S e pelo ACOLITE. Entretanto, os melhores valores de *slope* foram obtidos pelo Sen2Cor nas faixas do vermelho e do red-edge (B5) devido aos bons resultados obtidos de correção atmosférica nestas faixas, demonstrando maior aproximação à linha 1:1. Já que, como observado na comparação entre a $R_{rs,sim}$ e a $R_{rs,sat_Sen2Cor}$ os erros aumentaram com o comprimento de onda, isto também é observado nos valores de MAPE e R^2 para os modelos de TSS e TSI, que também apresentam maiores erros para a correção pelo Sen2Cor em comprimentos de onda maiores.

Entre os resultados obtidos, o melhor valor de MAPE encontrado tanto para TSS quanto para TSI foi utilizando a faixa do *red-edge* do MSI (B5) com a correção atmosférica pelo 6S. Entretanto, mesmo com os valores próximos entre o 6S e o ACOLITE nesta faixa, através do teste-t, observou-se que estes dois métodos apresentam diferenças significativas (p-valor < 0.05). Estes resultados também seguem os observados para os algoritmos empíricos,

porém, com menores valores de MAPE para o algoritmo NC (Veja os resultados dos algoritmos empíricos na Tabela 6.3).

Tabela 6.8 Valores de MAPE (%), R², RMSE (mgL⁻¹) e *Slope* para os algoritmos NC de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor MSI (n = 14).

Atm. Cor	Faixa	MAPE (%)		R ²		RMSE (mgL ⁻¹)		<i>Slope</i>	
		TSS	TSI	TSS	TSI	TSS	TSI	TSS	TSI
Sen2Cor	B3	30.39	49.47	0.590	0.729	5.475	3.978	0.754	0.643
	B4	21.24	32.97	0.558	0.704	5.141	3.310	0.967	0.810
	B5	25.86	43.09	0.679	0.812	5.348	4.098	1.022	0.947
	B6	22.96	27.68	0.607	0.685	5.152	4.205	0.683	0.591
	B7	21.68	26.96	0.616	0.698	4.939	4.058	0.697	0.596
	B8	49.02	60.41	0.372	0.411	9.626	7.525	0.546	0.462
6S	B3	19.51	34.58	0.594	0.726	3.565	3.015	0.609	0.513
	B4	18.34	24.92	0.561	0.708	4.162	2.771	0.847	0.704
	B5	14.32	16.98	0.686	0.810	3.492	2.428	0.786	0.714
	B6	19.07	34.07	0.603	0.682	3.639	3.043	0.659	0.576
	B7	25.03	40.65	0.607	0.694	4.281	3.346	0.690	0.599
	B8	23.11	43.18	0.363	0.410	4.704	3.972	0.553	0.481
ACOLITE	B3	18.18	32.54	0.592	0.727	3.478	3.053	0.565	0.476
	B4	18.15	25.08	0.559	0.708	4.026	2.765	0.804	0.669
	B5	18.46	18.72	0.686	0.810	4.168	2.995	0.723	0.654
	B6	15.97	30.07	0.608	0.687	3.410	3.004	0.610	0.532
	B7	31.30	50.56	0.606	0.694	5.146	3.963	0.667	0.581
	B8	21.61	40.82	0.355	0.400	4.587	3.958	0.509	0.441

Fonte: Produção do Autor.

A validação do algoritmo NC para as imagens WFI (Tabela 6.9) apresentou resultados piores em relação aos dos algoritmos empíricos. Os valores de MAPE somente apresentaram bons resultados (< 30%) para a faixa do vermelho. Entretanto, como observado também nos algoritmos empíricos os valores de R² nesta faixa, assim como para o MSI e o OLI, apresentaram são inferiores aos da faixa do verde.

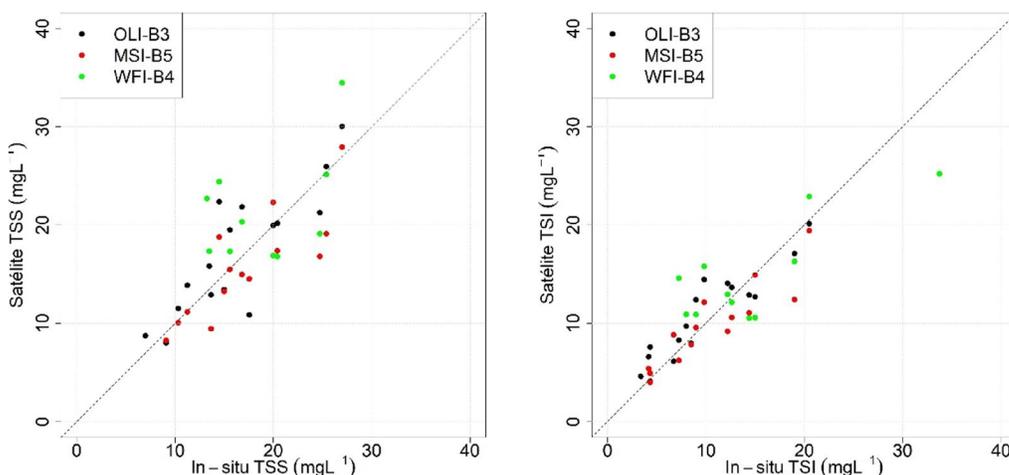
Tabela 6.9 Valores de MAPE (%), R², RMSE (mgL⁻¹) e *Slope* para o algoritmo NC com de TSS e TSI a partir dos coeficientes obtidos para o algoritmo com todas as campanhas aplicados nas imagens do sensor WFI (n = 11).

Atm.Cor	Faixas	MAPE		R ²		RMSE		Slope	
		TSS	TSI	TSS	TSI	TSS	TSI	TSS	TSI
S	B3	44.47	50.19	0.822	0.789	8.262	6.124	0.502	0.427
	B4	27.08	30.58	0.576	0.637	5.730	4.498	0.617	0.527
	B5	127.02	150.43	0.711	0.644	24.713	18.537	1.128	1.015

Fonte: Produção do Autor.

A dispersão dos dados de TSS e TSI estimados pelos melhores resultados dos algoritmos NC apresentaram resultados semelhantes aos obtidos com os modelos empíricos. Há boa aderência, principalmente em relação aos modelos calibrados para os sensores OLI e MSI.

Figura 6.7 Dispersão dos dados de TSS e TSI estimados através do algoritmo NC para os sensores OLI (Pontos em preto), MSI (Pontos em vermelho) e WFI (Pontos em verde) em relação aos valores de TSS e TSI *in-situ*.



Fonte: Produção do autor.

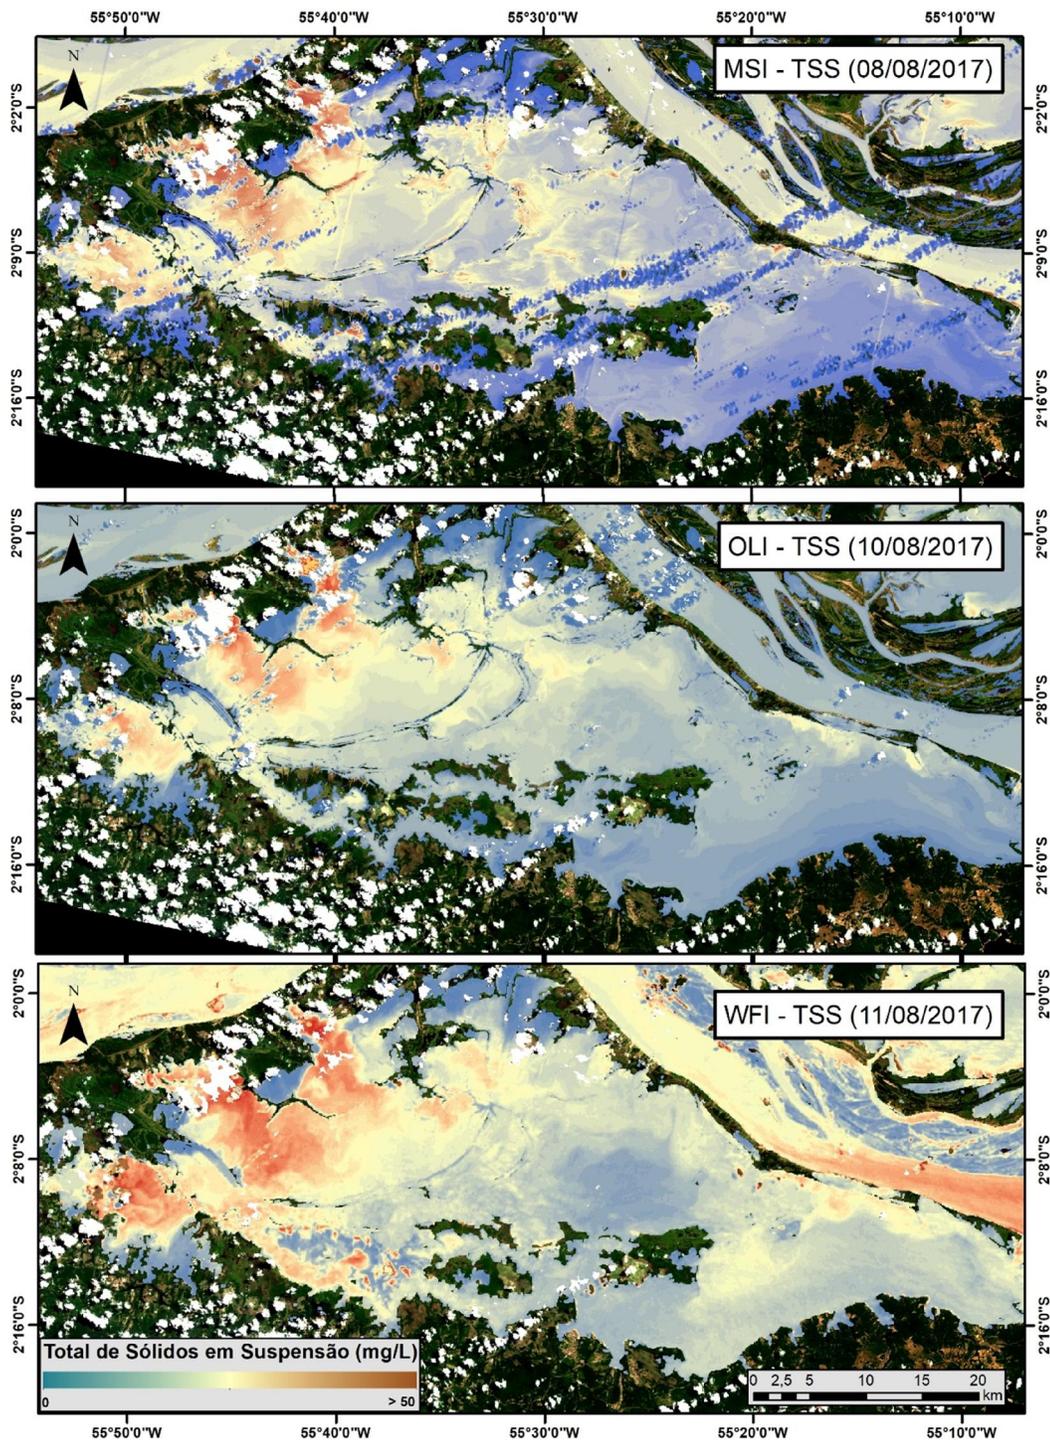
6.3.4 Espacialização das estimativas

A espacialização das concentrações de TSS (Figura 6.8) e de TSI (Figura 6.9) permite avaliar através de uma visão sinóptica o comportamento dos sedimentos dentro da planície. Foram aplicados os algoritmos que utilizam a

B5, B3 e B4 (MSI, OLI e WFI, respectivamente) após a correção atmosférica pelo 6S e correção de glint (para o OLI e MSI). Os valores de TSS médios estimados em todo o Lago Curuai foram de $15.59 \pm 8.15 \text{ mgL}^{-1}$, $15.18 \pm 7.13 \text{ mgL}^{-1}$ e $20.17 \pm 7.28 \text{ mgL}^{-1}$ para os sensores MSI, OLI e WFI, respectivamente. Estes valores são semelhantes aos valores médios de TSS medidos durante a campanha de campo de agosto de 2017 ($17,7 \pm 8.52 \text{ mgL}^{-1}$) (Tabela 3.1).

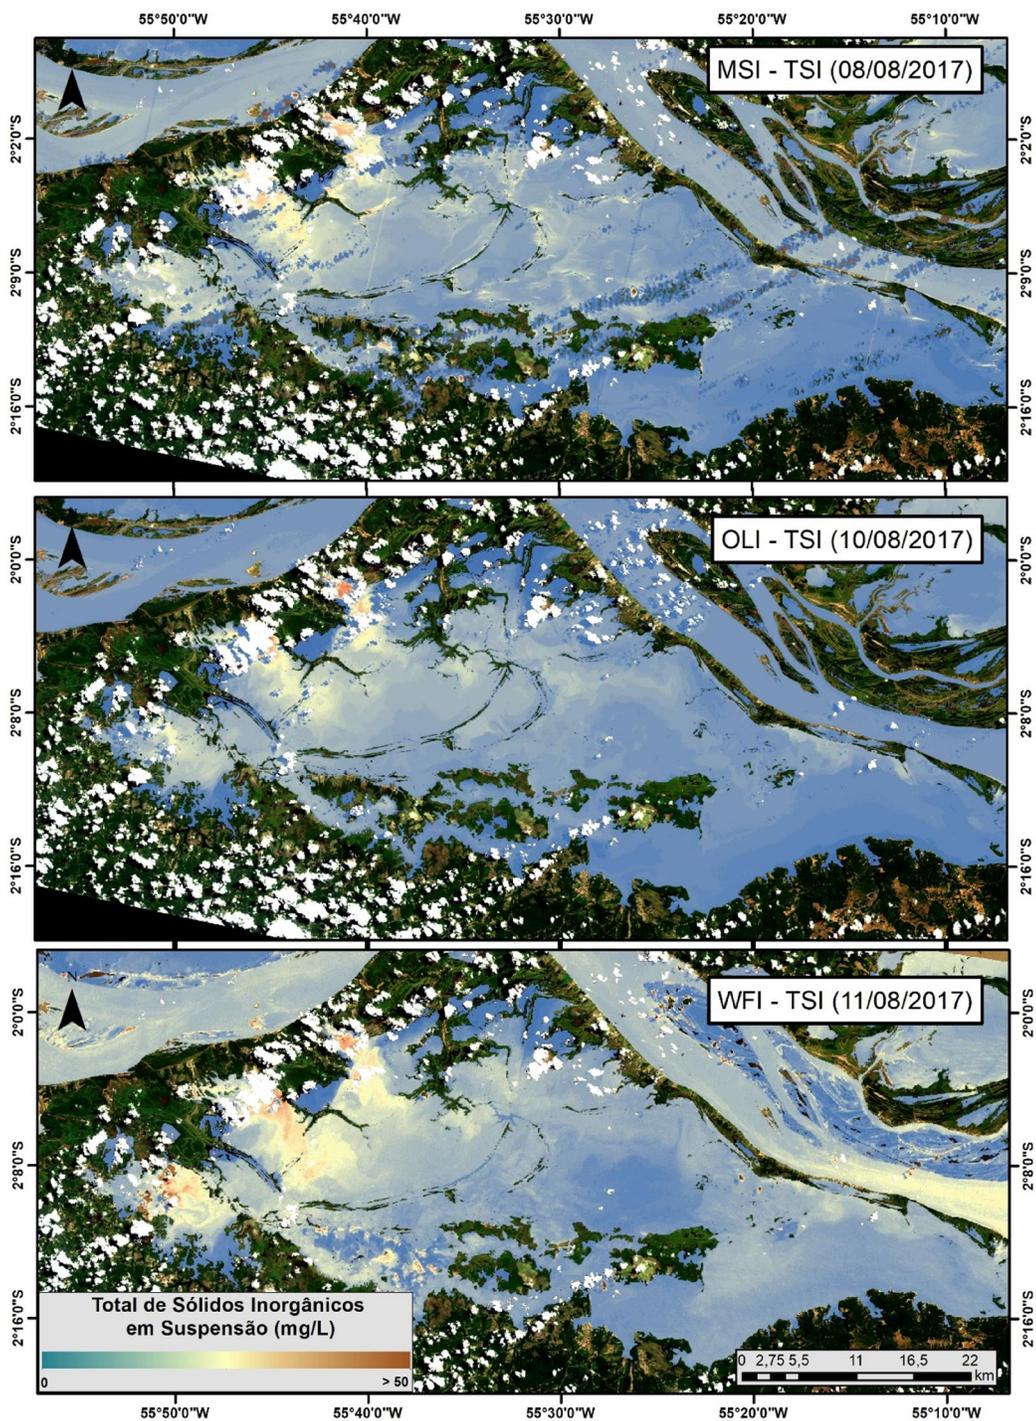
Já para as estimativas de TSI, utilizando as bandas B5, B3 e B5 (MSI, OLI e WFI), os valores médios foram de $8.88 \pm 5.46 \text{ mgL}^{-1}$, $9,66 \pm 4.8 \text{ mgL}^{-1}$ e $11.7 \pm 5.49 \text{ mgL}^{-1}$ para os sensores MSI, OLI e WFI, respectivamente. Estes valores novamente estão próximos dos observados na campanha de campo ($11,12 \pm 7.53 \text{ mgL}^{-1}$). Estes valores novamente são bastante semelhantes aos medidos durante a campanha de campo ($11,12 \pm 7.53 \text{ mgL}^{-1}$). A diferença em percentagem da média de TSS e TSI *in-situ* com os valores de TSS e TSI obtidos para o OLI e MSI não ultrapassam 20% (Figura 6.9).

Figura 6.8 Mapas de TSS obtidos pelos sensores MSI, OLI e WFI através dos algoritmos empíricos que apresentaram os melhores resultados.



Fonte: Produção do autor.

Figura 6.9 Mapas de TSI obtidos pelos sensores MSI, OLI e WFI através dos algoritmos empíricos que apresentaram os melhores resultados.



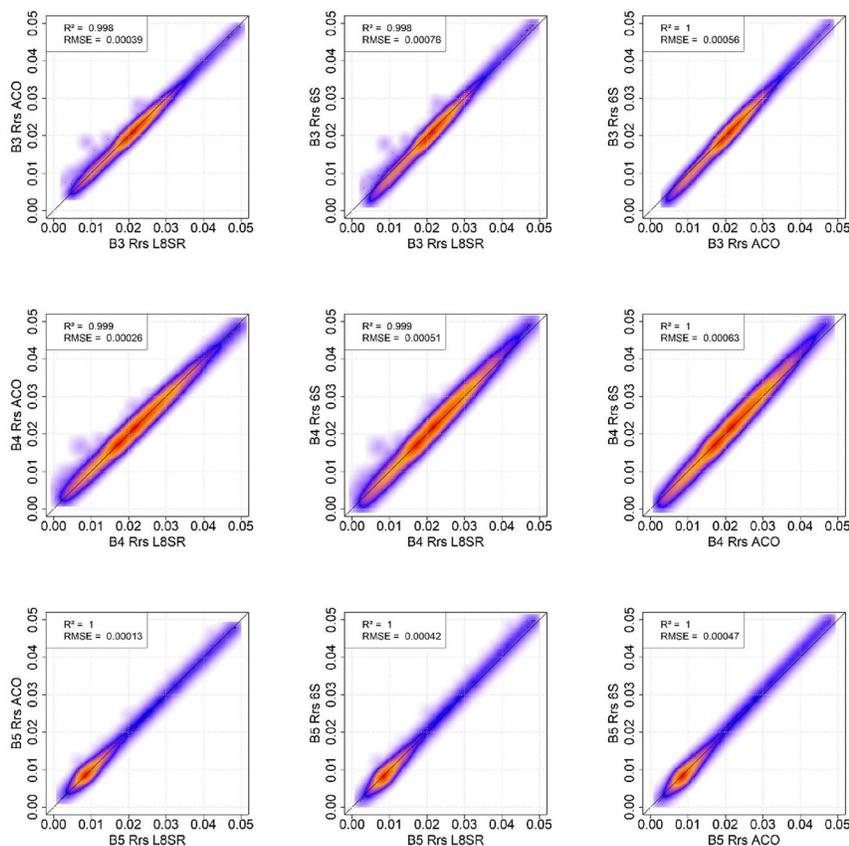
Fonte: Produção do autor.

6.4 Discussões

6.4.1 Resultado das correções atmosféricas e de glint

Para o sensor OLI, a combinação da correção atmosférica + correção de glint apresentou melhores resultados para a faixa do verde e vermelho (B3 e B4), produzindo valores de MAPE menores que 15% independentemente do método de correção atmosférica. A comparação entre os três métodos de correção atmosférica apresentou resultados muito semelhantes entre si, com um RMSE $< 10^{-3}$ (sr^{-1}) e um R^2 maior que 0.99 em todas as comparações (Figura 6.10) para um conjunto de pixels dentro da área do Lago Grande de Curuai ($n > 33000$).

Figura 6.10 Comparação entre os métodos de correção atmosférica para o sensor OLI.



A Primeira Linha corresponde a banda 3, a segunda à banda 4 e a terceira à banda 5 ($n = 33694$). As cores em vermelho representam maior densidade de pontos, enquanto as cores em azul representam menor densidade de pontos.

Fonte: Produção do autor.

Lobo et al. (2015) também relataram valores de $R^2 = 0,93$ para as faixas do verde e vermelho do sensor TM (Landsat-5) utilizando a correção atmosférica pelo 6S e a correção de glint (WANG; SHI, 2007) no Rio Tapajós (Pará). Outros estudos (Bernardo et al. 2017) também corroboram com os resultados de validação obtidos neste estudo para a R_{rs} nas faixas do verde (MAPE = 6,39%) e do vermelho (MAPE = 16,7%) utilizando o produto L8SR em um reservatório brasileiro eutrofizado, embora sem correção de glint. Wei et al. (2018) também

encontraram bons resultados para a faixa do verde em águas túrbidas do Harbor Bay [TSS ~ 3-8 mgL⁻¹, Chl-a ~ 2-5 µgL⁻¹] (MAPE = 18%) para o L8SR.

Mesmo na faixa do IVP do OLI, em que erros mais altos são reportados por diversos autores (BERNARDO et al., 2017; DE KEUKELAERE et al., 2018; LOBO; COSTA; NOVO, 2015; WANG et al., 2019), com valores de MAPE acima de 100%, os resultados obtidos neste estudo apresentaram valores menores que 21%, mostrando que a metodologia correção atmosférica + correção *glint* permite estimar adequadamente as medidas de R_{rs} para o OLI nesta região de estudo.

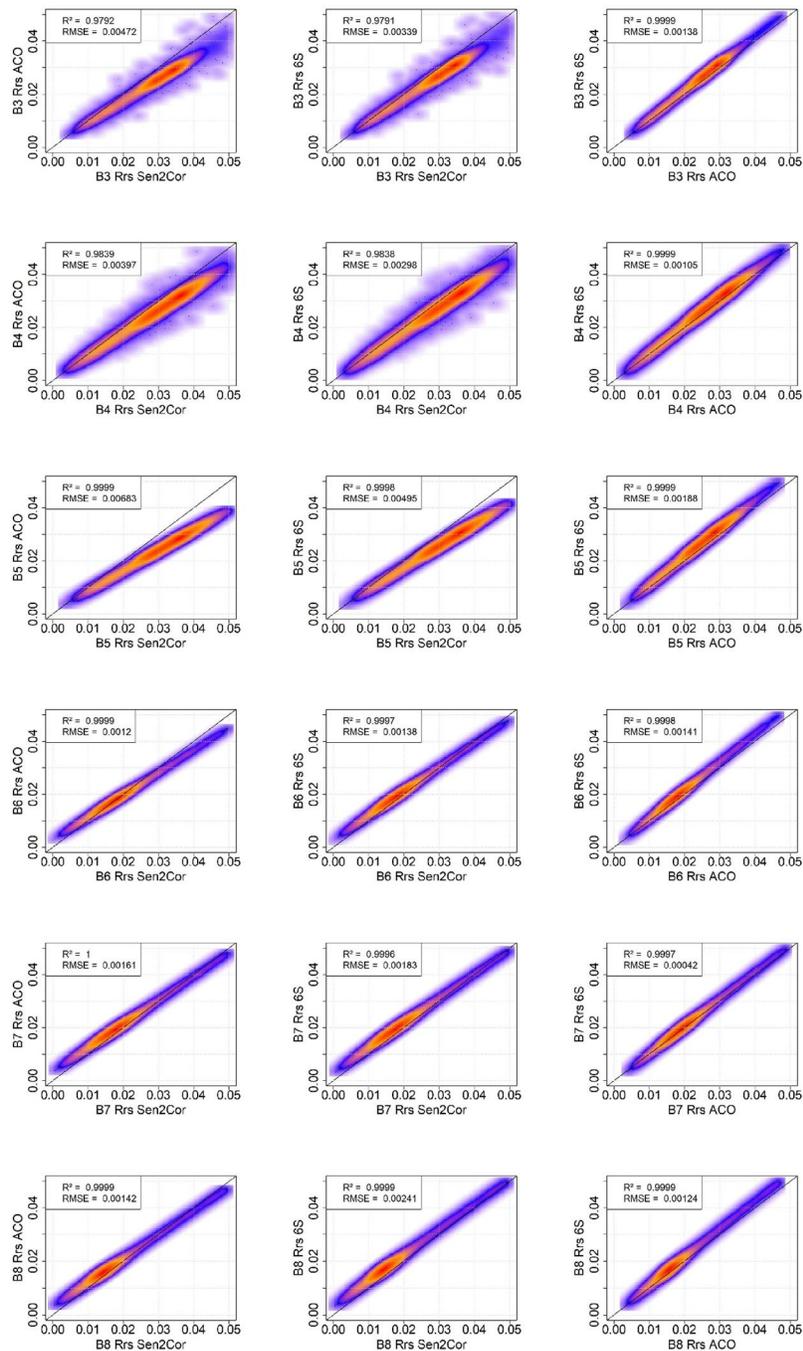
Para o sensor MSI, vê-se que antes da correção do *glint*, altos valores de MAPE (> 100%) foram encontrados para a validação da correção atmosférica. Estes maiores efeitos foram explicados por dois principais fatores: i) segundo Pahlevan et al. (2017b), os efeitos de *glint* são maiores em imagens MSI em relação às do OLI devido ao horário de passagem do Sentinel-2 (~20 min após o OLI), o que resulta em maiores ângulos de elevação solar e aumento da possibilidade de ocorrer *glint* (HARMEL et al., 2018; JERLOV, 1976; MOBLEY, 1994). ii) a velocidade do vento média obtida através de anemômetros no dia 08 de agosto foi de 3.99 ms⁻¹ (Data de aquisição da imagem MSI) contra uma velocidade de vento média de 1.62 ms⁻¹ para o dia 10/Agosto (Data da imagem OLI) pode ter aumentado a rugosidade da superfície do lago aumentando a ocorrência de *glint* (KAY; HEDLEY; LAVENDER, 2009; MOBLEY, 2015; ZHOU et al., 2013).

Neste sentido, o desempenho do sensor MSI após a correção do *glint* apresenta redução de mais de 100% nos valores de MAPE. Os menores erros foram obtidos utilizando o método 6S para a faixa do vermelho (MAPE < 10%). No infravermelho próximo, os resultados obtidos para os métodos 6S e ACOLITE também apresentaram valores de MAPE menores que 30% em todas as bandas espectrais. Já nas faixas do infravermelho próximo, diferentemente do observado por Martins et al. (2017), que avaliou o desempenho do 6S, ACOLITE e Sen2Cor e observou melhores resultados para o Sen2Cor nesta faixa, os resultados observados neste trabalho para o Sen2Cor apresentaram

maiores erros em relação ao ACOLITE e o 6S, o que também foi observado por Doxani et al. (2018) e Xu et al. (2018). Estas diferenças podem ser atribuídas às incertezas na estimativa da espessura óptica de aerossol (AOT) pelo Sen2Cor, fazendo com que haja maiores erros na estimativa da refletância de superfície (DÖRNHÖFER et al., 2016; DOXANI et al., 2018; LI et al., 2018).

A variação do Sen2Cor com os outros métodos de correção atmosférica também é vista na dispersão dos pontos de R_{rs} obtidos após a correção (Figura 6.11). Observou-se maiores valores de RMSE na comparação entre o Sen2Cor e o 6S e ACOLITE, enquanto que os menores valores de RMSE foram obtidos nas comparações entre o 6S e ACOLITE. Estas diferenças são evidenciadas também ao observarmos a diferença entre os resultados da correção atmosférica validada com os dados de $R_{rs,sim}$ para o MSI, em que erros mais altos são encontrados para o Sen2Cor na faixa do IVP e menores na faixa do visível, enquanto que os erros obtidos para o ACOLITE e 6S são próximos em todas as faixas. Ainda, os valores de RMSE foram maiores do que os observados para o OLI.

Figura 6.11 Comparação entre os métodos de correção atmosférica para o sensor MSI.



As linhas correspondem as faixas espectrais (3 a 8) do MSI. As cores em vermelho representam maior densidade de pontos, enquanto as cores em azul representam menor densidade de pontos.

Fonte: Produção do autor.

Em relação ao WFI, os resultados para as faixas do visível também foram satisfatórios, com o melhor resultado obtido para a faixa do vermelho (B4) (MAPE = 7.94%, R^2 0.851, RMSE = 0.0019 sr^{-1} , *slope* = 0.883). Entretanto, os resultados para a faixa do infravermelho próximo da WFI não foram satisfatórios (MAPE = 123%). Estes resultados para a WFI indicam que a correção atmosférica pelo 6S apresentou bons resultados apenas na faixa do visível. Ainda, vê-se que os resultados seguem a tendência observada para o OLI e MSI, em que a faixa do vermelho apresentou os melhores resultados utilizando a correção atmosférica pelo 6S.

6.4.2 Aplicações dos modelos empíricos e semi-analíticos e espacialização

A aplicação dos modelos calibrados nas imagens OLI e MSI apresentou resultados satisfatórios de validação. Para o OLI, foi evidente a seleção do modelo para a região do verde (B3) independentemente do método de correção atmosférica utilizado para os algoritmos empíricos e semi-analíticos. Estes resultados podem ser atribuídos à concentração de TSS e TSI observada na campanha de agosto de 2017, cujo range de concentração variou entre 7 a 43,5 mgL^{-1} de TSS. Bernardo et al. (2017) também obtiveram melhores resultados de validação de TSS para a faixa espectral do verde do sensor OLI (MAPE = 10,06%) para uma amplitude de TSS próximo ao deste estudo (10,8 – 44 mgL^{-1}), porém, em um reservatório com maiores valores de concentração de Chl-a (263.2-726.5 μL^{-1}). Min et al. (2012) também encontraram bons resultados para estimativas de TSS utilizando a faixa do verde do sensor TM (Landsat-5) em áreas costeiras com concentrações abaixo de 100 mgL^{-1} , na Coreia do Sul (R^2 = 0.72).

Os resultados de TSS para o sensor OLI mostram também que seguiram a tendência observada com os dados de R_{rs} simulados quando foi utilizada apenas a campanha de campo de agosto de 2017: Melhores resultados para TSS foram encontrados para o modelo ln (R_{rs,sim_OB3}). Ainda, apesar de maiores valores de MAPE em relação à faixa do verde, os modelos utilizando a faixa do

vermelho e do IVP para o OLI também apresentaram resultados satisfatórios, com valores de MAPE menores que 35% para o 6S e o L8SR e $R^2 > 0.61$.

Zheng et al. (2015) em amostras de validação utilizando a faixa do IVP do OLI para concentrações entre 4-101 mgL^{-1} de TSS encontraram valores de MAPE de 20,6%. Neste estudo, o resultado para a faixa do IVP foi um pouco mais alto (MAPE ~27%) devido à menor concentração observada de TSS que diminui o sinal do NIR e causa maiores erros a baixas concentrações (GIARDINO et al., 2017; YEPEZ et al., 2018). Já os modelos de razão de banda apresentaram valores de MAPE $> 60\%$ em todos os modelos aplicados ao OLI. Este resultado pode ser atribuído também à SNR, porque os modelos de razão de banda tendem a amplificar o efeito do sinal ruído sobre o erro das estimativas, com este efeito sendo maior em baixas concentrações (JORGE et al., 2017).

Os resultados indicaram que quando se comparam todos os modelos derivados de todos os três conjuntos de dados (Conjunto completo, separados por lagos e separados por campanhas) para o sensor OLI, os melhores modelos são os baseados em todas as amostras coletadas ao longo das campanhas de campo. (MAPE $< 20\%$ para TSS e TSI). Como o processo de calibração/validação é realizado utilizando-se Simulação Monte Carlo, a aleatorização provida pela simulação permite que a amplitude de variação dos COAs seja capturada pelo modelo fazendo com que se torne mais robusto do que o modelo desenvolvido para a própria data de aquisição da imagem. Devido às limitações de amostragem, o uso de uma única data para a calibração do modelo acaba por fazer com que as características ópticas do corpo d'água fiquem sub-representadas e haja maior incerteza nas estimativas dos coeficientes da regressão (Veja na Tabela 4.5. e Tabela 4.6).

O sensor MSI, devido à sua maior resolução espectral no NIR em relação à do OLI, possibilitou o uso destas faixas para estimar concentrações mais baixas de TSS e de TSI, evitando assim a interferência de outros COAs (ROESLER; BOSS, 2008). O melhor resultado para TSS e TSI obtido para o MSI foi utilizando a faixa espectral em 705 nm (B5) para os algoritmos empíricos e semi-analíticos. Os modelos de TSS e TSI baseados no conjunto completo de

dados apresentaram melhores resultados, como também observado para o OLI (MAPE < 21%).

Novamente, como foi observado para o sensor OLI, este resultado segue o que foi observado nos modelos separados por campanha para agosto de 2017, em que, para o MSI, o melhor resultado dos algoritmos logarítmicos de TSS foi obtido pelo $\ln(R_{rs,sim_MB5})$ e para o algoritmos semi-analíticos para a $\rho_{w,MB5}$. Os resultados para o MSI foram melhores do que os obtidos por Liu et al. (2017). Entretanto, estes autores avaliaram amplitudes de concentração de até $\sim 300 \text{ mgL}^{-1}$.

Ainda, mesmo com altos valores de concentração estes autores encontraram bons resultados de validação para a banda 5 do MSI (MAPE = 34,56%, $R^2 = 0,81$), mostrando que esta faixa também pode ser utilizada para concentrações mais altas. Olmanson et al. (2013) também encontraram bons resultados para a faixa de 705 nm utilizando um sensor hiperespectral aerotransportado no Rio Mississippi, para concentrações TSS entre 4 e 80 mgL^{-1} ($R^2 = 0,83$).

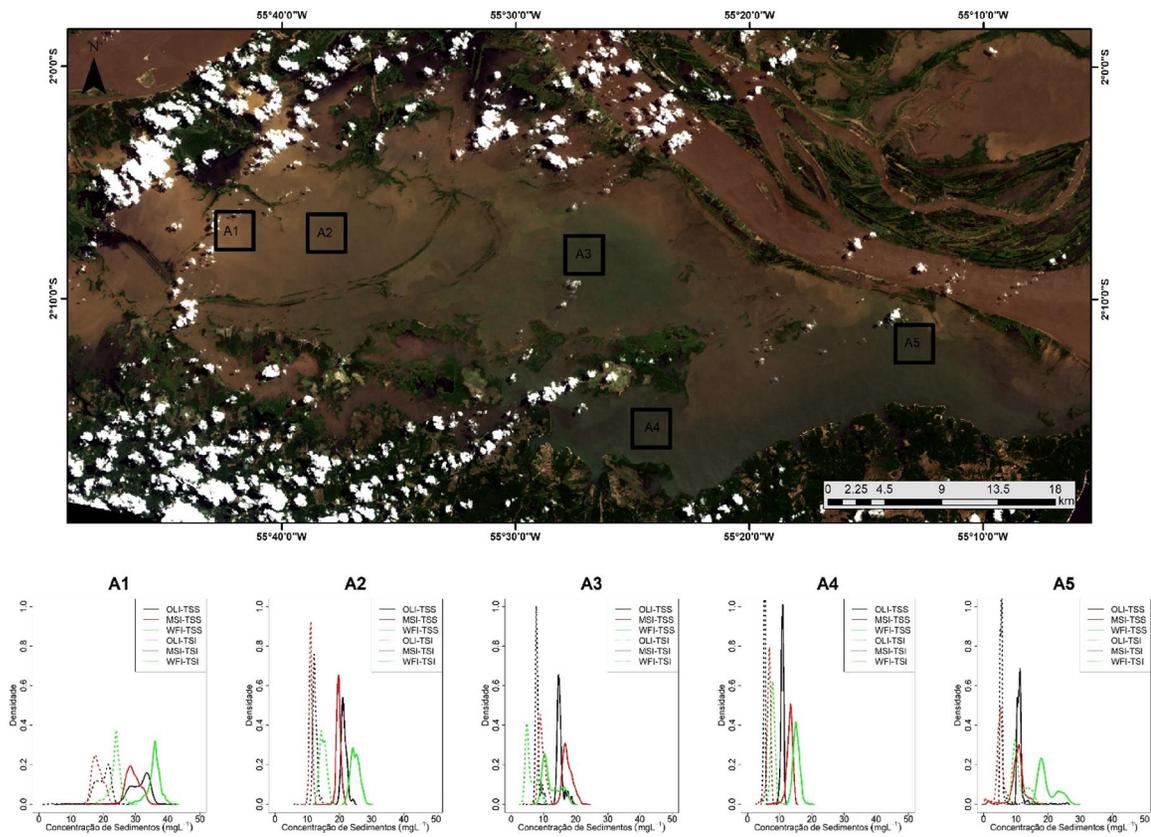
Já os resultados obtidos com o sensor WFI apresentaram erros e dispersão maiores que os observados para os sensores OLI e MSI. Apesar de valores de MAPE menores que 30%, os resultados mostraram valores de R^2 na faixa dos 0,6, o que é identificado também na dispersão dos valores de TSS e TSI *in-situ* com os obtidos pelos modelos empíricos e semi-analíticos fazendo com que os valores de R^2 e *slope* sejam menores. Estes maiores erros em relação aos obtidos pelos sensores OLI e MSI podem estar relacionados à dinâmica da água na planície de inundação entre os dias amostrados em campo e a data de passagem do satélite CBERS-4, à erros na correção atmosférica e a não aplicação de uma correção dos efeitos de glint.

A aplicação nas imagens dos algoritmos de TSS e de TSI desenvolvidos permitiu uma espacialização de sua concentração no Lago Grande de Curuai e adjacências. Esta espacialização permite avaliar o comportamento da dinâmica da circulação de sedimentos nesta região, já que cada imagem é proveniente de uma data. Na Figura 6.12 é possível observar valores mais altos de TSS e de TSI à noroeste do Lago Curuai (Figura 6.12, Áreas A1 e A2), com um

aumento da concentração de sedimentos ao longo dos dias, observado picos maiores na FDP para o OLI e para a WFI em relação ao sensor MSI. Esta região recebe água com sedimentos provenientes do Rio Amazonas que passa por diversos canais até chegar ao Lago (ALCÂNTARA et al., 2008; RUDORFF; DUNNE; MELACK, 2018). Além disto, como esta localidade é mais rasa, pode ser mais sensível às ações do vento, por exemplo (BARBOSA, 2005; BARBOSA et al., 2006).

Barbosa (2005) avaliando a distribuição espacial do TSS na planície de inundação de Curuai observou, durante o período de cheia (maio e junho) e vazante (setembro a outubro) comportamentos espaciais do TSS semelhantes aos observados neste trabalho. Na região central (Figura 6.12, Área A3), a concentração de TSS e TSI apresentou redução em relação às áreas A1 e A2 devido a provável aumento da deposição de sedimentos. Além disto, na área A3 observa-se a ocorrência de uma floração de fitoplancton (veja o observado na coloração em verde na Figura 6.12). A área A4 também apresentou menor concentração de sedimentos. Já na área A5, a concentração de TSS e TSI estimada pela WFI foi maior que a estimada pelo OLI e MSI, provavelmente devido ao aporte de sedimentos nesta área da planície devido ao extravasamento do canal (RUDORFF et al. 2018) ou devido também à efeitos de glint.

Figura 6.12 Variação da concentração de TSS e de TSI em cinco áreas para os modelos empíricos gerados para as imagens OLI, MSI e WFI. As caixas na parte inferior representam a função de distribuição de probabilidade para os algoritmos de TSS e de TSI. Data das imagens: MSI – 08/08/2017; OLI – 10/08/2017; WFI – 11/08/2017.



Fonte: Produção do autor.

6.5 Conclusões

Neste capítulo, foram avaliadas diversas metodologias de correção atmosférica e aplicada a correção de glint em imagens dos sensores OLI e MSI e uma metodologia de correção atmosférica para o sensor WFI. Os resultados indicaram ser possível obter estimativas acuradas da R_{rs} , principalmente nas faixas do visível para os três sensores avaliados com a utilização do 6S. Já na faixa do infravermelho próximo, maiores erros foram encontrados principalmente devido ao baixo sinal da água nesta faixa espectral para os valores de TSS estimados. Observou-se que a correção de glint melhorou os resultados das estimativas de R_{rs} para os sensores OLI e WFI, mas que foi fundamental para o sensor MSI, com uma redução nos valores de MAPE maior que 100%.

Os algoritmos empíricos e semi-analíticos aplicados às imagens dos sensores OLI, MSI e WFI também apresentaram bons resultados de validação (MAPE < 25%), na faixa do verde do sensor OLI, na faixa do red-edge (B5) do sensor MSI após correção atmosférica pelo 6S seguida da correção de glint para TSS e TSI. Já para o WFI, os resultados foram satisfatórios na faixa do vermelho após a correção atmosférica pelo 6S.

7 COMPARAÇÃO DAS ESTIMATIVAS DE TSS E TSI UTILIZANDO MULTISENsoRES

7.1 Introdução

A utilização do sensoriamento remoto para a estimativa da concentração de sedimentos nas planícies de inundação do baixo Amazonas a partir de sensores de média resolução espacial pode ampliar o conhecimento sobre a dinâmica de sedimentos nestes locais. Entretanto, a alta cobertura de nuvens na região Amazônica (ASNER, 2001) ainda é um fator restritivo para sua aplicação a esse tipo de estudo nesta região, já que, em determinadas épocas do ano (principalmente entre dezembro – maio) a frequência de imagens com nuvens é de cerca de 90% na região do Baixo Amazonas (MARTINS et al., 2018a).

Diferentemente de sensores com resolução espacial mais grosseira e tempo de revisita mais frequente (~1 dia) como o MODIS, sensores de média resolução espacial como o Landsat-8/OLI, Sentinel-2A e B/MSI e CBERS-4/WFI possuem tempos de revisita que variam entre 16 dias (OLI) a 5 dias (Sentinel-2A e B, usados em conjunto e CBERS-4/WFI). Este intervalo de revisita, contudo, pode não ser suficiente para detectar mudanças na variação dos sedimentos em determinadas épocas em que a probabilidade da ocorrência de nuvens é grande. Assim, a utilização conjunta de vários sensores é de extrema importância para aumentar a probabilidade da obtenção de imagens com menor cobertura de nuvens.

Pesquisas recentes vêm mostrando a aplicabilidade da utilização dos sensores OLI e MSI em conjunto para as estimativas de sedimentos em suspensão em águas interiores e costeiras (PAHLEVAN et al., 2018). Entretanto, a maioria dos estudos ainda foca na utilização de apenas um destes sensores (LIU et al., 2017; LOBO; COSTA; NOVO, 2015; NOVOA et al., 2017; YEPEZ et al., 2018). Há também esforços para a construção de uma constelação virtual de produtos integrados de refletância de superfície para o OLI e MSI, disponibilizado inicialmente para os EUA e para algumas regiões de teste ao redor do globo

chamado HLS (*Harmonized Landsat Sentinel-2* - <https://hls.gsfc.nasa.gov/>) (CLAVERIE et al., 2018).

Entretanto, não há um esforço de validação para a estimativa de TSS e TSI a partir das imagens WFI e também não há estudos comparativos entre dados de R_{rs} obtidos por estes três sensores. Há, no entanto, nos últimos anos esforços para avaliar a consistência dos dados de R_{rs} e produtos derivados, como a concentração de TSS estimados por diferentes sensores, como apreciado pela primeira vez em ambientes costeiros por Pahlevan et al. (2019) para os sensores OLI e MSI. Na utilização de dados de R_{rs} e produtos estimados por diferentes sensores, a avaliação da consistência destes produtos através da utilização de dados obtidos no mesmo dia e em horários próximos permite quantificar a diferença nestas estimativas.

Yepez et al. (2018) utilizaram algoritmos empíricos desenvolvidos para o sensor OLI para a estimativa de TSS no Rio Orinoco (Venezuela). Lobo et al. (2015) utilizaram imagens dos sensores MSS, TM e OLI (Da série Landsat) para estimativas de TSS em rios na bacia do Rio Tapajós (Amazonia) e o aumento de sua concentração relacionado com a atividade de mineração. Já Liu et al. (2017), utilizando imagens do sensor MSI avaliaram a utilização de modelos empíricos para estimativas de TSS no Lago Poyang (China), com bons resultados para as faixas do infravermelho próximo deste sensor. Montanher et al. (MONTANHER; NOVO; SOUZA FILHO, 2018) também mostram a aplicabilidade da utilização de séries temporais dos sensores TM (Landsat-5) para estimativa do material em suspensão no Rio Amazonas. Já em relação ao sensor WFI, não há estudos investigando a sua acurácia para a determinação da concentração TSS e TSI.

Alguns trabalhos como os de Molleri et al. (2008) utilizando o sensor WFI a bordo do antigo satélite CBERS-2 (Com 260m de resolução espacial) mostraram uma boa relação entre a refletância obtida através da WFI em comparação com a obtida pelo sensor MODIS na faixa do vermelho (MOLLERI et al., 2008). Novo et al. (2017) demonstram a possibilidade da utilização do sensor WFI para avaliar a dinâmica de trocas de águas entre os lagos de

várzea na Reserva de Desenvolvimento Sustentável de Mamirauá e os rios Solimões e Japurá.

Neste sentido, este capítulo teve como objetivo apresentar e discutir os resultados da avaliação da consistência entre as estimativas de TSS e de TSI resultantes da aplicação dos algoritmos empíricos e semi-analíticos calibrados e validados nos Capítulos 4 e 5 em imagens quase simultâneas dos sensores OLI, MSI e WFI.

7.2 Metodologia

7.2.1 Imagens utilizadas e correção atmosférica

Neste trabalho foram utilizadas imagens provenientes dos sensores OLI, WFI e MSI datadas de 13 de agosto de 2018. Apenas esta data foi utilizada já que ela foi a única obtida entre 2015-2018 no mesmo dia sem cobertura de nuvens na área do Lago Grande de Curuai (LGC). A diferença de horário entre a passagem dos satélites não foi superior a 24 minutos (Veja na Tabela 7.1). Esta pequena diferença no horário de passagem dos satélites é importante já que minimiza a variação atmosférica e também a variação entre as condições do ambiente aquático, o que favorece a diminuição das incertezas na comparação entre os diferentes sensores (PAHLEVAN et al., 2018). A correção atmosférica utilizada em ambas imagens foi pelo método 6S (VERMOTE et al., 1997), conforme descrito na Seção 6.2.2., para o OLI, MSI e WFI, seguida pela correção de glint (WANG; SHI, 2007) apenas nas imagens dos sensores OLI e MSI, também conforme descrito na Seção 6.2.2.

Tabela 7.1 Data e horário de passagem dos sensores utilizados.

Satélite/Sensor	Data	Horário Local
Landsat8/OLI	13/08/2018	10:53
Sentinel2A/MSI	13/08/2018	11:10
CBERS-4/WFI	13/08/2018	10:53

Fonte: Produção do autor.

A análise dos dados de TSS e TSI foi realizada a partir da criação e extração dos valores de R_{rs} para cerca de 50.000 pontos aleatórios dentro do LGC. Para cada sensor, um *buffer* de 120 x 120 m (4x4 pixels OLI, 6x6 pixels MSI B5-B7, 12x12 pixels MSI B3, B4 e B8 e 2x2 pixels WFI) foi utilizado em cada ponto e a média aritmética destes pixels foi calculada para evitar a influência da relação sinal-ruído (JORGE et al., 2017; PAHLEVAN et al., 2018). Após a extração desses valores, foi calculado o índice NDWI (Equação 7.1) para excluir todos os pixels em que seu valor fosse menor que 0 (MCFEETERS, 2013).

$$NDWI = \frac{R_{rs-verde} - R_{rs-IVP}}{R_{rs-verde} + R_{rs-IVP}} \quad (7.1)$$

Após esta primeira filtragem, os pontos remanescentes da primeira filtragem não correspondentes à superfície do lago foram excluídos por meio de inspeção visual, em que pontos fora da área de água foram descartados. Após a etapa de filtragem, os algoritmos empíricos e semi-analíticos de TSS e TSI para as faixas do verde, vermelho e IVP foram aplicados nas imagens. Nesta análise não se fez necessária a utilização do Fator de Ajuste de Banda Espectral (ou *Spectral Band Adjustment Factor – SBAF*) já que cada algoritmo foi desenvolvido baseado na R_{rs} simulada para cada sensor e as divergências da Função de Resposta Espectral em cada banda são tratadas pelos algoritmos com a R_{rs} simulada.

7.2.2 Análise estatística

As diferenças entre os valores de TSS e TSI estimados pelos três sensores foi avaliada através das métricas estatísticas MAPE, R^2 , *slope* e intercepto da regressão e mediana da diferença (MD, da sigla em inglês). Nos cálculos do MAPE e MD, os dados obtidos pelo OLI foram tomados como referência seguindo a metodologia proposta por Pahlevan et al. (2018), de acordo com a Equação 7.2.

$$MD_{\lambda,i} = \text{Mediana} (\text{Sedimento}_{OLI_{\lambda,i}} - \text{Sedimento}_{MSI_{\lambda,i} \text{ ou } WFI_{\lambda,i}}) \quad (7.2)$$

Em que $MD_{\lambda,i}$ é a mediana para a concentração de sedimento (TSS ou TSI) calculada para a faixa espectral λ (e.g. verde, vermelho) para o número de amostras i .

7.3 Resultados

7.3.1 Variação dos resultados de TSS e TSI obtidos através dos algoritmos empíricos

Os resultados da comparação da aplicação dos algoritmos empíricos entre os sensores OLI e MSI apresentou bons resultados (Tabela 7.2), com a menor diferença nas estimativas entre os algoritmos que utilizam a faixa do verde e do vermelho e uma boa dispersão nestes pontos ($R^2 > 0.86$) (Figura 7.1). A mediana da diferença entre as estimativas pelo OLI e MSI não foi superior a $1,1 \text{ mgL}^{-1}$, para uma amplitude de concentração estimada entre $0\text{-}30 \text{ mgL}^{-1}$, em todas as faixas espectrais avaliadas tanto para TSS quanto para TSI. A maior diferença observada foi para a faixa do IVP entre o OLI e o MSI. Os valores de MD foram menores na comparação entre os valores de TSS e TSI estimados pelo algoritmo que utiliza a faixa 3 do OLI e a faixa 5 do MSI, que foram os algoritmos que apresentaram os melhores resultados de validação no Capítulo 6. Já os valores de MAPE apresentaram valores menores que 10% para os algoritmos na faixa do visível e erros menores que 15% para a comparação entre os algoritmos que apresentaram os melhores resultados de validação no Capítulo 6.

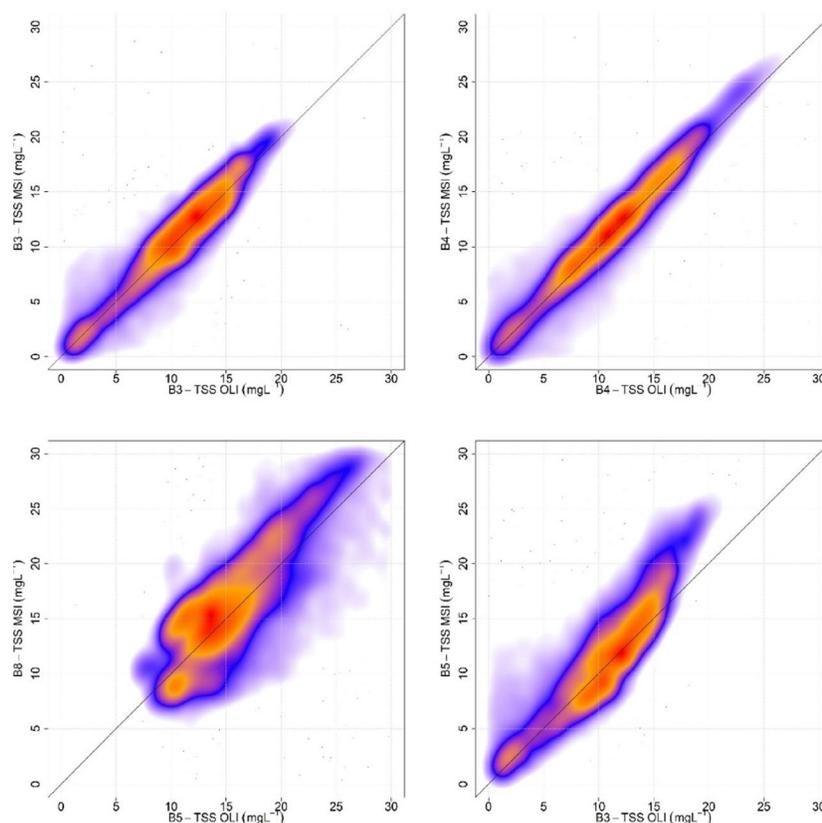
Tabela 7.2 Valores de diferença mediana (MD), MAPE, R², intercepto e slope para a comparação dos dados de TSS e TSI obtidos pelo OLI e pelo MSI.

Estatística	Sedimento	Faixa			
		Verde	Vermelho	IVP	OB3xMB5
MD (mgL ⁻¹)	TSS	0,45	0,42	1,07	0,33
	TSI	0,28	0,23	0,63	0,08
MAPE(%)	TSS	7,70	5,28	15,29	12,04
	TSI	9,56	6,55	18,61	14,93
R ²	TSS	0,86	0,97	0,64	0,80
	TSI	0,86	0,97	0,64	0,80
Intercepto	TSS	1,10	0,30	4,17	4,11
	TSI	0,54	0,19	2,23	2,20
Slope	TSS	0,89	0,94	0,68	0,62
	TSI	0,88	0,93	0,68	0,60

As estatísticas foram calculadas para a faixa do verde ($R_{rs,OB3} \times R_{rs,MB3}$), vermelho ($R_{rs,OB4} \times R_{rs,MB4}$), IVP ($R_{rs,OB5} \times R_{rs,MB8}$) e para os melhores resultados dos modelos empíricos para o OLI e MSI ($R_{rs,OB3} \times R_{rs,MB5}$).

Fonte: Produção do autor.

Figura 7.1 Dispersão entre os valores de TSS estimados pelo OLI e MSI através dos algoritmos empíricos que utilizam a faixa do verde (B3), vermelho (B4), IVP (B5 OLI e B8 MSI) e red-edge (B5 MSI).



Fonte: Produção do autor.

Já os resultados obtidos na comparação entre o OLI e a WFI foram inferiores do que os da comparação entre o OLI e o MSI (Tabela 7.3). A menor diferença mediana foi encontrada na comparação entre os melhores algoritmos obtidos na fase de validação ($R_{rs,OB3} \times R_{rs,WB4}$) assim como obtido para o OLI e o MSI. Entretanto, diferentemente da comparação entre o OLI e o MSI, os valores de MAPE para os algoritmos empíricos que apresentaram os melhores resultados para o OLI e WFI foram melhores que para a comparação entre a faixa do vermelho. Esta faixa espectral (vermelho) também apresentou resultados satisfatórios com uma diferença mediana de $-1,774 \text{ mgL}^{-1}$ para TSS e $-1,127 \text{ mgL}^{-1}$ para TSI e valores de MAPE menores que 30%. Já a faixa do IVP os resultados não foram satisfatórios, com uma superestimativa dos valores de

TSS e TSI pelo WFI. Esta diferença é notável na dispersão dos pontos, em que esta superestimação é pronunciada (Figura 7.2).

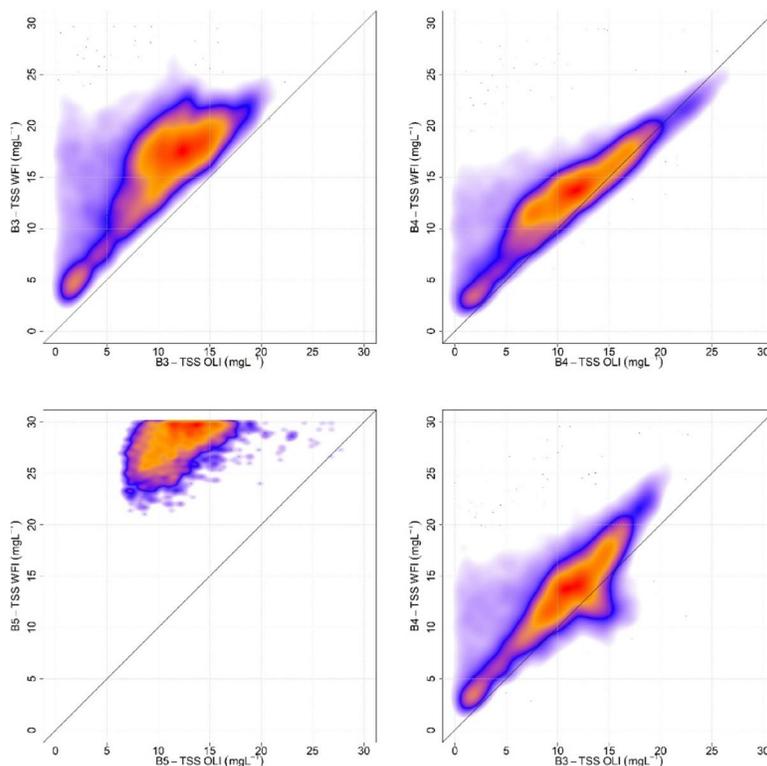
Tabela 7.3 Valores de diferença mediana (MD), R^2 , intercepto e slope para a comparação dos dados de TSS e TSI obtidos pelo OLI e pelo WFI.

Estatística	Sedimento	Faixa			
		Verde	Vermelho	IVP	OB3xWB4* ou WB5*
MD (mgL⁻¹)	TSS	-5.20	-1.77	-20.44	-0.76
	TSI	-3.40	-1.13	-14.96	-0.25
MAPE(%)	TSS	50.33	20.77	145.11	20.35
	TSI	66.23	27.87	200.94	23.37
R²	TSS	0.42	0.84	0.20	0.67
	TSI	0.40	0.85	0.21	0.68
Intercepto	TSS	0.51	-4.55	-0.88	1.41
	TSI	0.33	-2.27	-0.60	0.97
Slope	TSS	0.65	1.18	0.45	0.75
	TSI	0.59	1.15	0.38	0.70

As estatísticas foram calculadas para as faixas do verde ($R_{rs,OB3} \times R_{rs,WB3}$), vermelho ($R_{rs,OB4} \times R_{rs,WB4}$), IVP ($R_{rs,OB5} \times R_{rs,WB5}$) e para os melhores resultados dos modelos empíricos para o OLI e WFI ($R_{rs,OB3} \times R_{rs,WB4}$). *B4 para TSS e B5 para TSI.

Fonte: Produção do autor.

Figura 7.2 Dispersão entre os valores de TSS estimados pelo OLI e WFI através dos algoritmos empíricos que utilizam a faixa do verde (B3), vermelho (B4), IVP (B5).



Fonte: Produção do autor.

7.3.2 Variação dos resultados de TSS e TSI obtidos através do algoritmo de Nechad

A variabilidade entre os dados de TSS e TSI estimados utilizando o algoritmo NC em relação ao OLI e ao MSI apresentou resultados similares (Tabela 7.4) aos obtidos para os algoritmos empíricos, com valores de MD < 1.3 mgL⁻¹ em todos os casos. Já os valores de MAPE foram menores que 7% para a faixa do visível, com resultados similares também aos obtidos para os algoritmos empíricos. Os resultados mais consistentes foram obtidos para a concentração de TSS e TSI na faixa do vermelho (*slope* e R² > 0.94). Já na faixa do IVP, apesar de valores baixos de MD (< 0.25 mgL⁻¹) e MAPE (< 13.35%), os valores de R² e *slope* não foram satisfatórios (< 0.65) similarmente ao também

observado para os algoritmos empíricos. Já em relação à dispersão dos pontos, observa-se maior coerência entre os valores de TSS estimados com os algoritmos que utilizam as faixas do verde e do vermelho (Figura 7.3).

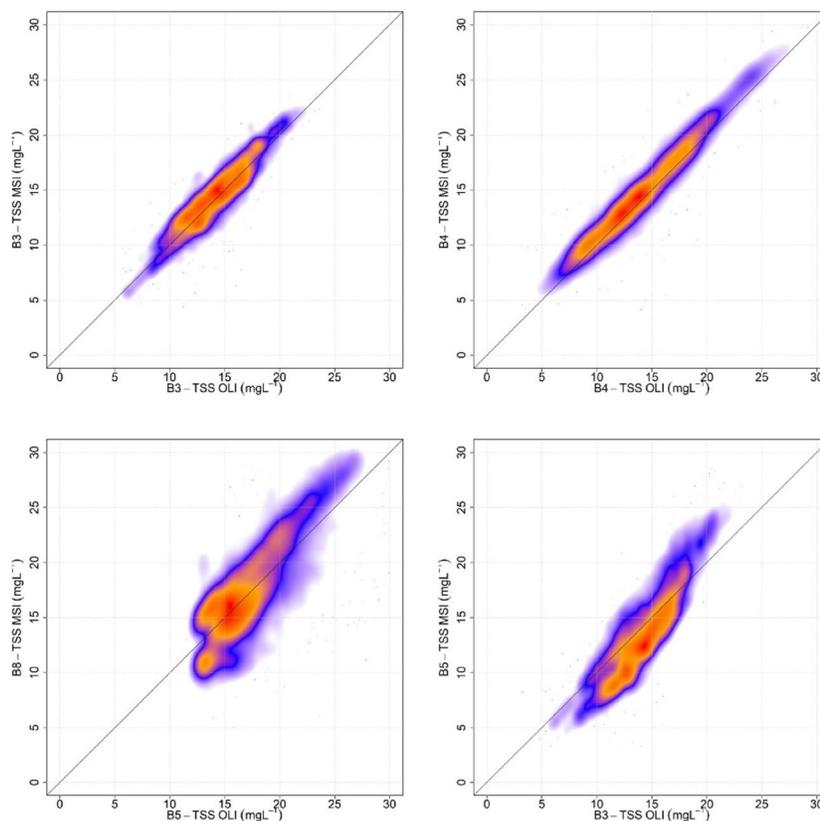
Tabela 7.4 Valores de diferença mediana (MD), R^2 , intercepto e *slope* para a comparação dos dados de TSS e TSI obtidos pelo OLI e pelo MSI .

Estatística	Sedimento	Faixa			
		Verde	Vermelho	IVP	OB3xMB5
MD (mgL⁻¹)	TSS	0.41	0.59	0.19	-1.22
	TSI	0.16	0.12	0.25	-0.89
MAPE(%)	TSS	5.78	5.55	10.32	11.74
	TSI	6.73	3.92	13.31	15.69
R²	TSS	0.86	0.97	0.65	0.80
	TSI	0.86	0.97	0.65	0.80
Intercepto	TSS	1.23	-0.06	5.96	5.89
	TSI	0.66	0.36	3.55	3.96
Slope	TSS	0.90	0.96	0.64	0.62
	TSI	0.91	0.94	0.63	0.58

Estatísticas do algoritmo NC para as faixas do verde ($p_{w,OB3} \times p_{w,MB3}$), vermelho ($p_{w,OB4} \times p_{w,MB4}$), IVP ($p_{w,OB5} \times p_{w,MB8}$) e para os melhores resultados do algoritmo NC para o OLI e MSI ($p_{w,OB3} \times p_{w,MB5}$).

Fonte: Produção do autor.

Figura 7.3 Dispersão entre os valores de TSS estimados pelo OLI e MSI através do algoritmo NC para as faixas do verde (B3), vermelho (B4), IVP (B5 OLI e B8 MSI) e red-edge (B5 MSI).



Fonte: Produção do autor.

Já a comparação entre o OLI e o WFI para os algoritmos semi-analíticos apresentou também resultados similares aos obtidos pelos algoritmos empíricos, em que os melhores resultados foram para a comparação entre a faixa do vermelho e também entre a faixa do verde com a do vermelho, que foi o que apresentou os melhores resultados para TSS e TSI, utilizando a WFI e o OLI.

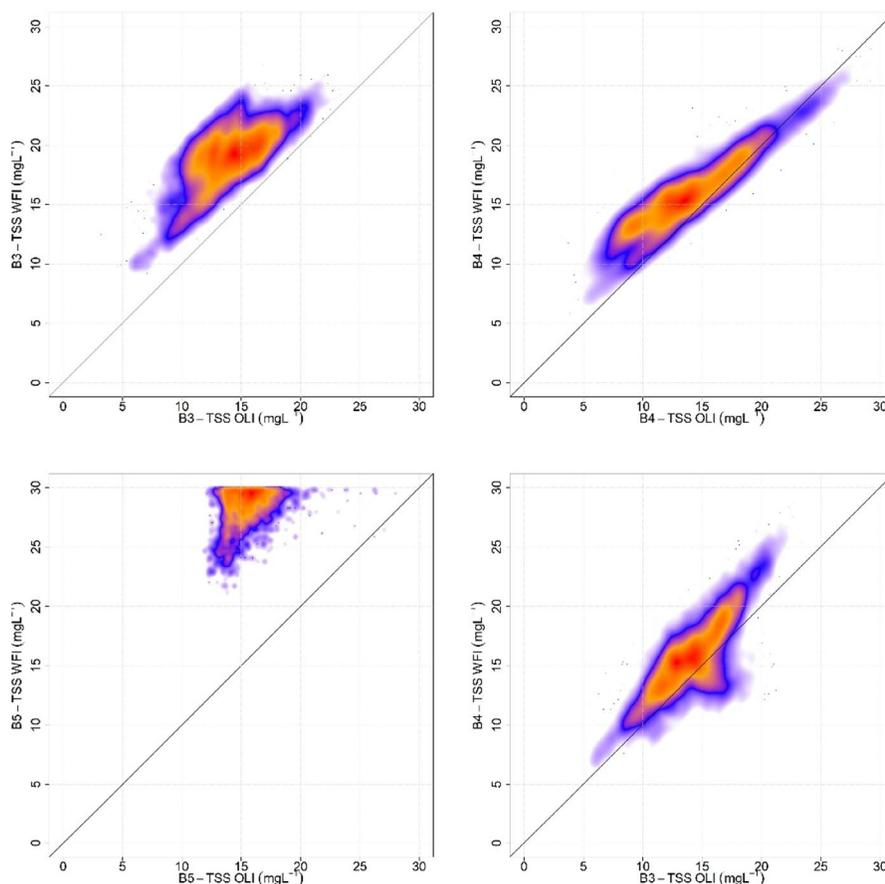
Tabela 7.5 Valores de diferença mediana (MD), R^2 , intercepto e *slope* para a comparação dos dados de TSS e TSI obtidos pelo OLI e pelo WFI.

Estatística	Sedimento	Faixa			
		Verde	Vermelho	IVP	OB3xMB5
MD (mgL ⁻¹)	TSS	4.72	1.78	17.63	1.72
	TSI	3.50	1.02	13.62	1.42
MAPE(%)	TSS	37.54	17.85	109.12	14.02
	TSI	47.14	17.33	143.20	18.83
R^2	TSS	0.47	0.86	0.22	0.65
	TSI	0.47	0.87	0.22	0.65
Intercepto	TSS	-0.39	-5.68	3.16	2.94
	TSI	-0.64	-3.26	1.03	1.12
<i>Slope</i>	TSS	0.65	1.18	0.45	0.71
	TSI	0.75	1.22	0.38	0.75

Estatísticas calculadas através do algoritmo NC para as faixas do verde ($p_{w,OB3} \times p_{w,MB3}$), vermelho ($p_{w,OB4} \times p_{w,WB4}$), IVP ($p_{w,OB5} \times p_{w,WB5}$) e para os melhores resultados do algoritmo NC para o OLI e WFI ($p_{w,OB3} \times p_{w,WB4}$).

Fonte: Produção do autor.

Figura 7.4 Dispersão entre os valores de TSS estimados pelo OLI e WFI através do algoritmo NC para as faixas do verde (B3), vermelho (B4) e IVP (B5).



Fonte: Produção do autor.

7.4 Discussões

A utilização de constelações virtuais para o aumento da resolução temporal e da possibilidade de obtenção de imagens sem nuvens na região amazônica foi avaliada neste estudo utilizando três imagens obtidas pelos sensores OLI, MSI e WFI quase simultâneas, com diferença máxima de 17 minutos entre elas.

Os algoritmos empíricos e semi-analíticos para TSS e TSI calibrados com os dados de $R_{rs,sim}$ para os três sensores apresentaram resultado semelhantes, com valores de diferença mediana de cerca de 2 mgL^{-1} na maioria das comparações realizadas e valores de MAPE menores que 10% para as faixas do vermelho na comparação entre o OLI e o MSI. Pahlevan et al. (2018)

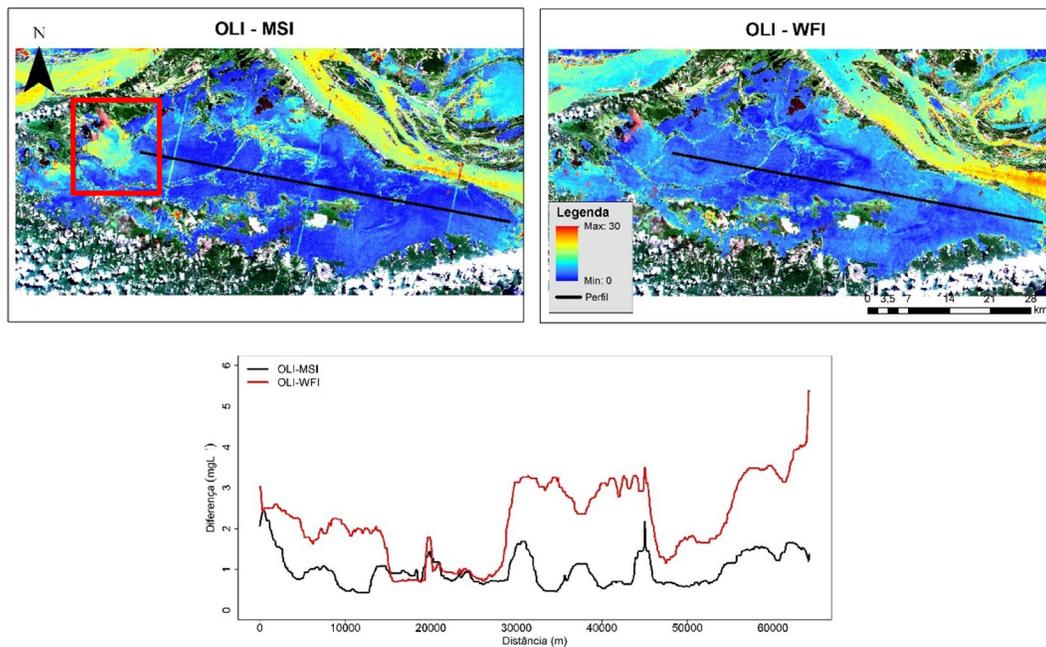
avaliaram também a consistência de produtos de TSS derivados dos sensores OLI e MSI a partir do algoritmo NC na faixa do vermelho em diversos ambientes aquáticos e encontraram valores de MD de -0.27 mgL^{-1} (na comparação entre o OLI e o MSI-A) para concentrações de TSS menores que 8 mgL^{-1} ($\sim 4\%$) corroborando com os resultados obtidos neste estudo, em que os valores de MD para a faixa do vermelho nos algoritmos empíricos e semi-analíticos não foi maior que 0.6 mgL^{-1} para concentrações máximas de cerca de 25 mgL^{-1} ($\sim 3\%$). Estes maiores valores de MD podem ser explicados pelas maiores concentrações de TSS estimadas pelos algoritmos do que o encontrado por Pahlevan et al. (2019).

Já os resultados para a comparação entre o OLI e o WFI apresentaram erros maiores. Estas maiores diferenças podem estar associadas às geometrias de visada do sensor, ao tamanho do pixel, à erros na correção atmosférica (Veja a validação para o WFI no Capítulo 6) e também à não correção dos efeitos de glint para o sensor WFI. As incertezas relacionadas à correção atmosférica para o WFI é mais pronunciada na comparação com a faixa do IVP, que foi a que apresentou maiores erros em relação à R_{rs} obtida em campo (Veja na Figura 6.3). Ainda, a não utilização da correção de glint devido à falta de uma faixa espectral no infravermelho médio também pode ser uma explicação para os maiores erros do sensor WFI.

Quando observada a diferença dos algoritmos aplicados nas cenas OLI, WFI e MSI são menores que 5 mgL^{-1} na maioria das situações. A Figura 7.5 apresenta o mapa das diferenças entre os valores de TSS estimados pelo OLI e MSI e pelo OLI e WFI (Através dos algoritmos empíricos: $\ln(R_{rs,OB3})$, $\ln(R_{rs,MB5})$ e $\ln(R_{rs,WB4})$). Como foi observado nas estatísticas para os algoritmos empíricos, uma diferença menor entre os produtos de TSS entre o OLI e o MSI pode ser observada em relação à comparação entre o OLI e o WFI. Uma linha de perfil também foi gerada para avaliar a variação da diferença entre os valores de TSS estimados ao longo deste perfil (Veja na Figura 7.5). Há, na linha de perfil uma diferença máxima de cerca de 4 mgL^{-1} na comparação entre o OLI e o WFI, mas este valor é, em média, menor que 3 mgL^{-1} em quase todo o transecto avaliado. Estas variações podem estar relacionadas com o maior

fluxo de entrada de sedimentos e turbulência (Veja no retângulo vermelho da Figura 7.5), afetados por forçantes locais como rochas, bancos de areia e corredeiras (BOUCHEZ et al., 2011), além da diferença de tempo entre a passagem do OLI e MSI (~16 minutos), o que pode explicar esta variação.

Figura 7.5 Mapa da diferença absoluta entre as estimativas de TSS derivadas dos sensores OLI, WFI e MSI e perfil com os valores de diferença entre os valores de TSS estimados pelo OLI, WFI e MSI.



Fonte: Produção do autor.

7.5 Conclusões

Através de uma breve análise de três imagens concomitantes dos sensores OLI, WFI e MSI pode-se observar que há boa correlação e pouca diferença nos valores de TSS e de TSI estimados por estes três sensores, com valores de diferença mediana menores que 1 mgL^{-1} para grande parte das comparações, principalmente quando avaliado os algoritmos que apresentaram os melhores desempenhos no processo de validação do Capítulo 6. Como este trabalho foi realizado com apenas uma cena, recomenda-se a utilização de uma série temporal de imagens concomitantes dos três sensores para a avaliação em

outras fases da hidrógrafa e em outras condições atmosféricas. Porém, mesmo com este conjunto único de dado (uma cena) é possível perceber a possibilidade da utilização destes três sensores para a construção de séries temporais e aumento da resolução temporal no Lago Grande de Curuai.

8 CONSIDERAÇÕES FINAIS

Através de técnicas de sensoriamento remoto foi possível, através deste trabalho, calibrar e validar diversos algoritmos empíricos e semi-analíticos para estimativa da concentração de TSS e de TSI na planície de inundação do Baixo Amazonas. Os algoritmos desenvolvidos, tanto os empíricos como os semi-analíticos mostraram dependência da sua acurácia em relação à fase da hidrógrafa e com a concentrações dos constituintes opticamente ativos presentes em cada fase. Ainda, observou-se que, em relação aos dados de $R_{rs,sim}$ os algoritmos desenvolvidos que utilizam faixas espectrais próximas (principalmente as do verde e vermelho) os resultados são equivalentes. Observou-se também que os algoritmos empíricos e NC re-calibrados com os dados *in-situ* apresentaram resultados similares, o que não acontece para o NC original, que apresenta uma superestimativa dos valores de TSS e TSI.

A validação dos dados de R_{rs} mostrou dependência do método de correção atmosférica para o OLI e o MSI e apresentou bons resultados ao utilizar o 6S com o sensor WFI. Ainda, uma dependência da correção dos efeitos de glint para o MSI foi observada, com uma diminuição substancial (> 100%) nos valores de MAPE após a correção por glint nos três métodos de correção atmosférica utilizados. A validação nas cenas OLI, MSI e WFI dos algoritmos de TSS e TSI calibrados com os dados *in-situ* apresentou também bons resultados, com valores de MAPE menores que 31% para TSS e TSI, para os três sensores. Finalmente, a avaliação das imagens concomitantes mostrou uma diferença mediana entre as estimativas de TSS menor que 1 mgL^{-1} para os algoritmos empíricos, demonstrando a possibilidade da utilização em conjunto destes três sensores.

A partir dos resultados obtidos neste trabalho, vê-se que ainda há a necessidade da avaliação de algoritmos TSS e TSI para épocas em que a concentração de sedimentos nos lagos da planície do Baixo Amazonas é alta (época de seca, em que as concentrações podem ser maiores que 1000 mgL^{-1} no Lago Curuai segundo Barbosa (2005)). Ainda, há a necessidade da

avaliação da influência dos efeitos de glint e também da convergência entre os satélites nas épocas em que não foram avaliadas neste estudo.

REFERÊNCIAS BIBLIOGRÁFICAS

- AFFONSO, A. G.; BARBOSA, C. C. F.; NOVO, E. M. L. DE M. Water quality changes in floodplain lakes due to the Amazon River flood pulse : Lago Grande de Curuaí (Pará). **Brazilian Journal of Biology**, v. 71, n. 3, p. 601–610, 2011.
- ALCÂNTARA, E. H. et al. Turbidity in the Amazon floodplain assessed through a spatial regression model applied to fraction images derived from MODIS / Terra. **IEEE Transactions on Geoscience and Remote Sensing**, v. 46, n. 10, p. 2895–2905, 2008.
- ALMEIDA, R. M. et al. Phosphorus transport by the largest Amazon tributary (Madeira River, Brazil) and its sensitivity to precipitation and damming. **Inland Waters**, v. 5, n. 3, p. 275–282, 2015.
- AQUINO DA SILVA, A. G. et al. Spectral calibration of CBERS 2B multispectral satellite images to assess suspended sediment concentration. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 104, p. 53–62, 2015.
- ASNER, G. P. Cloud cover in Landsat observation of the Brazilian Amazon. **International Journal of Remote Sensing**, v. 22, n. 18, p. 3855–3862, 2001.
- AUGUSTO-SILVA, P. B. et al. Analysis of MERIS reflectance algorithms for estimating chlorophyll-a concentration in a Brazilian reservoir. **Remote Sensing**, v. 6, n. 12, p. 11689–11707, 2014.
- BARBOSA, C. C. F. **Sensoriamento remoto da dinâmica da circulação da água do sistema planície de Curuaí/ Rio Amazonas**. 2005. 287p. Tese (Doutorado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007. Disponível em: <mtc-m16c.sid.inpe.br/col/sid.inpe.br/MTC-13@80/2006/02.22.15.../publicacao.pdf>
- BARBOSA, C. C. F. et al. Metodologia de análise da dinâmica de área e volume inundável : o exemplo da várzea do Lago Grande de Curuaí. **Revista Brasileira de Cartografia**, v. 1, p. 1–10, 2006.

BARBOSA, C. C. F. et al. Geospatial analysis of spatiotemporal patterns of pH, total suspended sediment and chlorophyll-a on the Amazon floodplain.

Limnology, v. 11, n. 2, p. 155–166, 2010.

BARICHIVICH, J. et al. Recent intensification of Amazon flooding extremes driven by strengthened Walker circulation. **Science Advances**, v. 4, n. 9, p. eaat8785, 2018.

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

BARTLETT, K. B.; HARRISS, R. C. Review and assessment of methane emissions from wetlands. **Chemosphere**, v. 26, n. 1–4, p. 261–320, 1993.

BATTIN, T. J. et al. The boundless carbon cycle. **Nature Geoscience**, v. 2, n. 9, p. 598–600, 2009.

BERK, A.; BERNSTEIN, L. S.; ROBERTSON, D. C. **MODTRAN**: a moderate resolution model for LOWTRAN. [S.l.]: Air Force Systems Command, 1987.

BERNARDO, N. 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.

BLAUSTEIN, J. et al. The peak near 700 nm on radiance spectra of algae and water: relationships of its magnitude and position with chlorophyll. **International Journal of Remote Sensing**, v. 13, n. 17, p. 3367–3373, 1992.

BONNET, M. P. et al. Floodplain hydrology in an Amazon floodplain lake (Lago Grande de Curuaí). **Journal of Hydrology**, v. 349, n. 1–2, p. 18–30, 2008.

BONNET, M. P. et al. Amazonian floodplain water balance based on modelling and analyses of hydrologic and electrical conductivity data. **Hydrological Processes**, v. 31, n. 9, p. 1702–1718, 2017.

BOUCHEZ, J. et al. Prediction of depth integrated fluxes of suspended sediment in the Amazon River: particle aggregation as a complicating factor. **Hydrological Processes**, v. 794, p. 778–794, 2011.

BOURGOIN, L. M. et al. Temporal dynamics of water and sediment exchanges between the Curuaí floodplain and the Amazon River, Brazil. **Journal of Hydrology**, v. 335, n. 1/2, p. 140–156, 2007.

BRAMANTE, J.; SIN, T. Optimization of a semi-analytical algorithm for multi-temporal water quality monitoring in inland waters with wide natural variability. **Remote Sensing**, v. 7, n. 12, p. 16623–16646, 2015.

CABALLERO, I.; STEINMETZ, F.; NAVARRO, G. Evaluation of the first year of operational Sentinel-2A data for retrieval of suspended solids in medium- to high-turbidity waters. **Remote Sensing**, v. 10, n. 7, 2018.

CARLOS, F. M.; MARTINS, V. S. ; BARBOSA, C. C. F. Sistema semi-automático de correção atmosférica para multi-sensores orbitais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., Santos, SP. **Anais...** São José dos Campos: INPE, 2019

CASALI, S. et al. Impact of the 2009 extreme water level variation on phytoplankton community structure in Lower Amazon floodplain lakes. **Acta Limnologica Brasiliensia**, v. 23, n. 3, p. 260–270, 2011.

CASTELLO, L. et al. The vulnerability of Amazon freshwater ecosystems. **Conservation Letters**, v. 6, n. 4, p. 217–229, 2013.

CASTELLO, L.; MACEDO, M. N. Large-scale degradation of Amazonian freshwater ecosystems. **Global Change Biology**, v. 22, n. 3, p. 990–1007, 2016.

CHEN, J. et al. A semi-analytical total suspended sediment retrieval model in turbid coastal waters: a case study in Changjiang River Estuary. **Optics Express**, v. 21, n. 11, p. 13018, 2013.

CLAVANO, W.; BOSS, E. S.; KARP-BOSS, L. Inherent optical properties of non-spherical marine-like particles: from theory to observation. **Oceanography and Marine Biology: An Annual Review**, v. 45, p. 1–38, 2007.

CLAVERIE, M. et al. Remote sensing of environment the harmonized Landsat and Sentinel-2 surface reflectance data set. **Remote Sensing of Environment**, v. 219, p. 145–161, 2018.

- COSTA, M. **Net primary productivity of aquatic vegetation of the Amazon floodplain: a Multi-SAR satellite approach.** Victoria, Canada: University of Victoria, 2000.
- COX, C.; MUNK, W. Measurement of the roughness of the sea surface from photographs of the sun's glitter. **Journal of the Optical Society of America**, v. 44, n. 11, p. 838, 1954.
- CROWLEY, P. H. Resampling methods for computation-intensive data analysis in ecology and evolution. **Annual Review of Ecology and Systematics**, v. 23, n. 1, p. 405-447, 1992.
- DALL'OLMO, G.; GITELSON, A. A. Effect of bio-optical parameter variability and uncertainties in reflectance measurements on the remote estimation of chlorophyll-a concentration in turbid productive waters: modeling results. **Applied Optics**, v. 45, n. 15, p. 3577, 2006.
- DAMASCENO, J. C.; ANTONIO, J.; DE OLIVEIRA, S. P. **JCGM 100: 2008: avaliação de dados de medição: guia para a expressão de incerteza de medição.** Rio de Janeiro, 2008.
- DE KEUKELAERE, L. et al. Atmospheric correction of Landsat-8/OLI and Sentinel-2/MSI data using iCOR algorithm: validation for coastal and inland waters. **European Journal of Remote Sensing**, v. 51, n. 1, p. 525–542, 2018.
- DEKKER, A. G. **Detection of optical water quality parameters for eutrophic waters by high resolution remote sensing.** 1993. 237p. Thesis (Doctor in Earth and Life Sciences) - VRIJE Universiteit Amsterdam, Amsterdam, 1993.
- DOGLIOTTI, A. I. et al. A single algorithm to retrieve turbidity from remotely-sensed data in all coastal and estuarine waters. **Remote Sensing of Environment**, v. 156, p. 157–168, 2015.
- DORJI, P.; FEARN, P.; BROOMHALL, M. A semi-analytic model for estimating total suspended sediment concentration in turbid coastal waters of northern Western Australia using MODIS-Aqua 250 m data. **Remote Sensing**, v. 8, n. 7, p. 33–38, 2016.

DÖRNBÖFER, K. et al. Water constituents and water depth retrieval from Sentinel-2A: a first evaluation in an oligotrophic lake. **Remote Sensing**, v. 8, n. 11, 2016.

DOXANI, G. et al. Atmospheric correction inter-comparison exercise. **Remote Sensing**, v. 10, n. 2, p. 1–18, 2018.

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

DOXARAN, D.; CHERUKURU, R. C. N.; LAVENDER, S. J. Use of reflectance band ratios to estimate suspended and dissolved matter concentrations in estuarine waters. **International Journal of Remote Sensing**, v. 26, n. 8, p. 1763–1769, 2005.

DOXARAN, D.; DEVRED, E.; BABIN, M. A 50 % increase in the mass of terrestrial particles delivered by the Mackenzie River into the Beaufort Sea (Canadian Arctic Ocean) over the last 10 years. **Biogeosciences**, v. 12, n. 11, p. 3551–3565, 2015.

DUNNE, T. et al. Exchanges of sediment between the flood plain and channel of the Amazon River in Brazil. **Bulletin of the Geological Society of America**, v. 110, n. 4, p. 450–467, 1998a.

ELEVELD, M. A. et al. Remotely sensed seasonality in the spatial distribution of sea-surface suspended particulate matter in the southern North Sea. **Estuarine, Coastal and Shelf Science**, v. 80, n. 1, p. 103–113, 2008.

EPIPHANIO, J. C. N. CBERS: Estado atual e futuro. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009. **Anais...** São José dos Campos: INPE, 2009. p. 2001–2008.

ESPINOZA VILLAR, R. et al. A study of sediment transport in the Madeira River, Brazil, using MODIS remote-sensing images. **Journal of South American Earth Sciences**, v. 44, p. 45–54, 2013.

- ESPINOZA VILLAR, R. et al. Spatio-temporal monitoring of suspended sediments in the Solimões River (2000-2014). **Comptes Rendus - Geoscience**, p. 1–9, 2016.
- EUROPEAN SPACE AGENCY. **{Sentinel-2A spectral response functions (S2A-SRF)} COPE-GSEG-EOPG-TN-15-0007**, 2017. Disponível em: <<https://sentinels.copernicus.eu/web/sentinel/document-library/content/-/article/sentinel-2a-spectral-responses>>
- FIQUEPRON, J.; GARCIA, S.; STENGER, A. Land use impact on water quality: valuing forest services in terms of the water supply sector. **Journal of Environmental Management**, v. 126, p. 113–121, 2013.
- FORSBERG, B. R. et al. The potential impact of new Andean dams on Amazon fluvial ecosystems. **PloS one**, v. 12, n. 8, p. e0182254, 2017.
- GAGNE-MAYNARD, W. C. et al. Evaluation of primary production in the lower Amazon River based on a dissolved oxygen stable isotopic mass balance. **Frontiers in Marine Science**, v. 4, p. 26, 2017.
- GANDY, A. Sequential implementation of Monte Carlo tests with uniformly bounded resampling risk. **Journal of the American Statistical Association**, v. 104, n. 488, p. 1504–1511, 2009.
- GARCIA, B. N.; LIBONATI, R.; NUNES, A. M. B. Extreme drought events over the Amazon Basin : the perspective from the reconstruction of South American hydroclimate. **Water**, v. 10, n. 11, p. 1594, 2018.
- GERGELY, M.; ZIBORDI, G. Assessment of AERONET-OC LWN uncertainties. **Metrologia**, v. 51, n. 1, p. 40–47, 2014.
- GIARDINO, C. et al. Bio-optical modeling of total suspended solids. In: MISHRA, D.; OGASHAWARA, I.; GITELSON, A. (Eds.). **Bio-optical modeling and remote sensing of inland waters**. Amsterdam: Elsevier, 2017. p. 129–156.
- GIBBS, R. J. The geochemistry of the Amazon River system: part I. the factors that control the salinity and the composition and concentration of the suspended solids. **GSA Bulletin**, v. 78, n. 10, p. 1203–1232, 1 out. 1967.

- GORDON, H. R.; BROWN, O. B.; JACOBS, M. M. Computed relationships between the inherent and apparent optical properties of a flat homogeneous ocean. **Applied Optics**, v. 14, n. 2, p. 417–27, 1975.
- GORDON, R. et al. A semianalytic radiance model of ocean color. **Journal of Geophysical Research**, v. 93, n. 8, p. 10909–10924, 1988.
- GUO, Q. **Correlation of Total Suspended Solids (TSS) and Suspended Sediment Concentration (SSC) test methods**: final report. New Jersey: Department of Environmental Protection, 2006.
- HÅKANSON, L. The role of characteristic coefficients of variation in uncertainty and sensitivity analyses, with examples related to the structuring of lake eutrophication models. **Ecological Modelling**, v. 131, n. 1, p. 1–20, 2000.
- HAN, B. et al. Development of a semi-analytical algorithm for the retrieval of suspended particulate matter from remote sensing over clear to very turbid waters. **Remote Sensing**, v. 8, n. 3, 2016.
- HARMEL, T. et al. Sun glint correction of the Multi-Spectral Instrument (MSI)-SENTINEL-2 imagery over inland and sea waters from SWIR bands. **Remote Sensing of Environment**, v. 204, p. 308–321, 2018.
- HESS, L. L. et al. Wetlands of the lowland Amazon Basin: extent, vegetative cover, and dual-season inundated area as mapped with JERS-1 Synthetic Aperture Radar. **Wetlands**, v. 35, n. 4, p. 745–756, 2015.
- HOCHBERG, E. J.; ANDRÉFOUËT, S.; TYLER, M. R. Sea surface correction of high spatial resolution Ikonos images to improve bottom mapping in near-shore environments. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41, n. 7, p. 1724-1729, 2003.
- INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. **JCGM 100: 1995**: Evaluation of measurement data: guide to the expression of uncertainty in measurement. Geneva, Switzerland, 1995.
- JERLOV, N. G. **Marine optics**. Amsterdam: Elsevier, 1976. v. 14

JIMÉNEZ-MUÑOZ, J. C. et al. Record-breaking warming and extreme drought in the Amazon rainforest during the course of El Niño 2015-2016. **Scientific Reports**, v. 6, p. 1–7, May 2016.

JONASZ, M.; FOURNIER, G. **Light scattering by particles in water: theoretical and experimental foundations**. [S.l.]: Academic Press, 2011.

JORGE, D. S. F. et al. SNR (signal-to-noise ratio) impact on water constituent retrieval from simulated images of optically complex Amazon lakes. **Remote Sensing**, v. 9, n. 7, p. 1–18, 2017.

JUNK, W. J. et al. The flood pulse concept in river-floodplain systems. **Canadian Special Publication of Fisheries and Aquatic Sciences**, v. 106, n. 1, p. 110–127, 1989.

JUNK, W. J. et al. A classification of major naturally-occurring amazonian lowland wetlands. **Wetlands**, v. 31, n. 4, p. 623–640, 2011.

JUNK, W. J. **The central Amazon floodplain: ecology of a pulsing system**. Berlin: Springer, 2013. v. 126.

KAY, S.; HEDLEY, J. D.; LAVENDER, S. Sun glint correction of high and low spatial resolution images of aquatic scenes: a review of methods for visible and near-infrared wavelengths. **Remote Sensing**, v. 1, n. 4, p. 697–730, 2009.

KHORRAM, S. Development of water quality models applicable throughout the entire San Francisco Bay and Delta. **Photogrammetric Engineering and Remote Sensing**, v. 51, n. 1, p. 53–62, 1985.

KILHAM, N. E.; ROBERTS, D. Amazon river time series of surface sediment concentration from MODIS. **International Journal of Remote Sensing**, v. 32, n. 10, p. 2659–2679, 2011.

KIRK, J. T. O. **Light and photosynthesis in aquatic ecosystems**. Cambridge: Cambridge University Press, 2010.

KNAEPS, E. et al. A SWIR based algorithm to retrieve total suspended matter in extremely turbid waters. **Remote Sensing of Environment**, v. 168, p. 66–79, 2015.

- KOBAYASHI, H. et al. Optical properties of inorganic suspended solids and their influence on coastal ocean color remote sensing. **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science**, v. 38, n. 8, p. 997–1001, 2010.
- KOUMROUYAN, A.; SANTANA, G. P. Química de elementos-traço nos sedimentos do Lago do Parú (Manacapuru - Amazonas), sob influência do pulso de inundação do baixo Rio Solimões. **Acta Amazonica**, v. 38, n. 3, p. 491–502, 2008.
- KRÖGER, S.; LAW, R. J. Sensing the sea. **Trends in Biotechnology**, v. 23, n. 5, p. 250–256, 2005.
- LATRUBESSE, E. M. et al. Damming the rivers of the Amazon basin. **Nature**, v. 546, n. 7658, p. 363–369, 2017.
- LATRUBESSE, E. M.; FRANZINELLI, E. The Holocene alluvial plain of the middle Amazon River, Brazil. **Geomorphology**, v. 19, n. 44, p. 241–257, 2002.
- LEE, Z. et al. Hyperspectral remote sensing for shallow waters: 2 deriving bottom depths and water properties by optimization. **Applied Optics**, v. 38, n. 18, p. 3831, 1999.
- LEE, Z. et al. Removal of surface-reflected light for the measurement of remote-sensing reflectance from an above-surface platform. **Optics Express**, v. 18, n. 25, p. 26313, 2010.
- LEE, Z.; CARDER, K. L.; ARNONE, R. A. Deriving inherent optical properties from water color: a multiband quasi-analytical algorithm for optically deep waters. **Applied Optics**, v. 41, n. 27, p. 5755, 2002.
- LEPOT, M.; AUBIN, J. B.; BERTRAND-KRAJEWSKI, J. L. Accuracy of different sensors for the estimation of pollutant concentrations (total suspended solids, total and dissolved chemical oxygen demand) in wastewater and stormwater. **Water Science and Technology**, v. 68, n. 2, p. 462–471, 2013.
- LI, J.; ROY, D. P. A global analysis of Sentinel-2a, Sentinel-2b and Landsat-8 data revisit intervals and implications for terrestrial monitoring. **Remote Sensing**, v. 9, n. 9, 2017.

- LI, Y. et al. Evaluation of Sentinel-2A surface reflectance derived using Sen2Cor in North America. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 6, p. 1997–2021, 2018.
- LIN, M.; LUCAS JR, H. C.; SHMUJELI, G. Research commentary—too big to fail: large samples and the p-value problem. **Information Systems Research**, v. 24, n. 4, p. 906–917, 2013.
- LIU, H. et al. Application of Sentinel 2 MSI images to retrieve suspended particulate matter concentrations in Poyang Lake. **Remote Sensing**, v. 9, n. 7, p. 761, 2017.
- LOBO, F. D. L. et al. Reference spectra to classify Amazon water types. **International Journal of Remote Sensing**, v. 33, n. 11, 2012.
- LOBO, F. L.; COSTA, M. P. F.; NOVO, E. M. L. M. M. L. M. M. L. M. M. L. M. Time-series analysis of Landsat-MSS/TM/OLI images over Amazonian waters impacted by gold mining activities. **Remote Sensing of Environment**, v. 157, p. 170–184, 2015.
- LOISEL, H. et al. Investigation of the optical backscattering to scattering ratio of marine particles in relation to their biogeochemical composition in the eastern English Channel and southern North Sea. **Limnology and Oceanography**, v. 52, n. 2, p. 739–752, 2007.
- LOUIS, J. et al. Sentinel-2 Sen2Cor: L2A processor for users. In: LIVING PLANET SYMPOSIUM, 2016, Prague, Czech Republic. **Proceedings...** ESA, 2016
- MAKRIDAKIS, S. Accuracy concerns measures : theoretical and practical concerns. **International Journal of Forecasting**, v. 9, p. 527–529, 1993.
- MARENGO, J. A. et al. Onset and end of the rainy season in the Brazilian Amazon Basin. **Journal of Climate**, v. 14, n. 5, p. 833–852, 2001.
- MARTINEZ, J.-M. M. et al. Increase in suspended sediment discharge of the Amazon River assessed by monitoring network and satellite data. **Catena**, v. 79, n. 3, p. 257–264, 2009.

- MARTINEZ, J.-M. M. et al. The optical properties of river and floodplain waters in the Amazon River Basin: implications for satellite-based measurements of suspended particulate matter - supplementary material. **Journal of Geophysical Research : Earth Surface**, v. 1, n. 860, p. 1–11, 2015.
- MARTINS, V. S. et al. Assessment of atmospheric correction methods for sentinel-2 MSI images applied to Amazon floodplain lakes. **Remote Sensing**, v. 9, n. 4, 2017.
- MARTINS, V. S. et al. Seasonal and interannual assessment of cloud cover and atmospheric constituents across the Amazon (2000–2015): insights for remote sensing and climate analysis. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, , p. 309–327, Oct. 2018a.
- MARTINS, V. S. et al. Continental-scale surface reflectance product from CBERS-4 MUX data: assessment of atmospheric correction method using coincident Landsat observations. **Remote Sensing of Environment**, v. 218, p. 55–68, Sept. 2018b.
- MATTHEWS, M. W. A current review of empirical procedures of remote sensing in Inland and near-coastal transitional waters. **International Journal of Remote Sensing**, v. 32, n. 21, p. 6855–6899, 2011.
- MATTHEWS, M. W. Bio-optical modeling of phytoplankton chlorophyll-a. In: MISHRA, D. K.; OGASHAWARA, I.; GITELSON, A. A. (Eds.). **Bio-optical modeling and remote sensing of inland waters**. Amsterdam: Elsevier, 2017. p. 157–188.
- MCCLAIN, M. E.; NAIMAN, R. J. Andean Influences on the biogeochemistry and ecology of the Amazon River. **BioScience**, v. 58, n. 4, p. 325–338, 2008.
- MCFEETERS, S. K. Using the Normalized Difference Water Index (ndwi) within a geographic information system to detect swimming pools for mosquito abatement: a practical approach. **Remote Sensing**, v. 5, n. 7, p. 3544–3561, 2013.
- MEADE, R. H. **Suspended sediment in the Amazon River and its tributaries in Brazil, during 1982-1984**. Denver:U.S Geological Survey, 1985.

- MEADE, R. H. Suspended sediments of the modern Amazon and Orinoco rivers. **Quaternary International**, v. 21, n. C, p. 29–39, 1994.
- MELACK, J. M. et al. Floodplain ecosystem processes. **Amazonia and Global Change**, n. 2003, p. 525–541, 2013.
- MERTES, L. A. K.; DUNNE, T.; MARTINELLI, L. A. Channel-floodplain geomorphology along the Solimões-Amazon River, Brazil. **Geological Society of America Bulletin**, v. 108, n. 9, p. 1089–1107, 1996.
- MERTES, L. A. K.; SMITH, M. O.; ADAMS, J. B. Estimating suspended sediment concentrations in surface waters of the Amazon River wetlands from Landsat images. **Remote Sensing of Environment**, v. 43, n. 3, p. 281–301, 1993.
- MIN, J. E. et al. Monitoring of suspended sediment variation using Landsat and MODIS in the Saemangeum coastal area of Korea. **Marine Pollution Bulletin**, v. 64, n. 2, p. 382–390, 2012.
- MOBLEY, C. D. **Light and water: radiative transfer in natural waters**. [S.l.] Academic Press, 1994.
- MOBLEY, C. D. Estimation of the remote-sensing reflectance from above-surface measurements. **Applied Optics**, v. 38, n. 36, p. 7442, 1999.
- MOBLEY, C. D. Polarized reflectance and transmittance properties of windblown sea surfaces. **Applied Optics**, v. 54, n. 15, p. 4828–4849, 2015.
- MOBLEY, C. D.; BOSS, E. S.; ROESLER, C. **Ocean optics web book**, 2010. Disponível em: <http://www.oceanopticsbook.info/>.
- MOLLERI, G. S. F. et al. Assessment of the sensors modis/terra and WFI/CBERS-2 for the Amazon river suspended sediment monitoring. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 37, 2008.

MONTANHER, O. C. **Modelos empíricos para estimativa da concentração de sedimentos em suspensão em rios Amazônicos de Águas Brancas a partir de imagens Landsat 5**. 2013. 145p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.

MONTANHER, O. C. et al. Empirical models for estimating the suspended sediment concentration in Amazonian white water rivers using Landsat 5 / TM. **International Journal of Applied Earth Observations and Geoinformation**, v. 29, p. 67–77, 2014.

MOREIRA-TURCQ, P. et al. Carbon sedimentation at Lago Grande de Curuai, a floodplain lake in the low Amazon region: insights into sedimentation rates. **Palaeogeography, Palaeoclimatology, Palaeoecology**, v. 214, n. 1/2, p. 27–40, 2004.

MOREIRA-TURCQ, P. et al. Seasonal variability in concentration, composition, age, and fluxes of particulate organic carbon exchanged between the floodplain and Amazon River. **Global Biogeochemical Cycles**, v. 27, n. 1, p. 119–130, 2013.

MOREL, A.; GENTILI, B. 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, 1991.

MOREL, A.; GENTILI, B. Diffuse reflectance of oceanic waters III Implication of bidirectionality for the remote-sensing problem. **Applied Optics**, v. 35, n. 24, p. 4850, 1996.

MOSES, W. J. et al. Estimation of chlorophyll- a concentration in case II waters using MODIS and MERIS data — successes and challenges. **Environmental Research Letters**, v. 4, n. 4, p. 045005, 2009.

MUNDAY, J. C.; ALFÖLDI, T. T. LANDSAT test of diffuse reflectance models for aquatic suspended solids measurement. **Remote Sensing of Environment**, v. 8, n. 2, p. 169–183, 1979.

- NECHAD, B.; RUDDICK, K. G.; PARK, Y. Calibration and validation of a generic multisensor algorithm for mapping of total suspended matter in turbid waters. **Remote Sensing of Environment**, v. 114, n. 4, p. 854–866, 2010.
- NEILL, C. et al. Deforestation for pasture alters nitrogen and phosphorus in small amazonian streams. **Ecological Applications**, v. 11, n. 6, p. 1817–1828, 1 dez. 2001.
- NOVO, E. M. L. M. et al. Avaliação de imagens WFI/CBERS-4 no estudo dos tipos de água da Reserva de Desenvolvimento Sustentável de Mamirauá (AM). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18., Santos, SP. **Anais...** São José dos Campos: INPE, 2017.
- NOVO, E. M. L. M.; STEFFEN, C. A.; ZUCCARI FERNANDES BRAGA, C. Results of a laboratory experiment relating spectral reflectance to total suspended solids. **Remote Sensing of Environment**, v. 36, n. 1, p. 67–72, 1991.
- NOVOA, S. et al. Atmospheric corrections and multi-conditional algorithm for multi-sensor remote sensing of suspended particulate matter in low-to-high turbidity levels coastal waters. **Remote Sensing**, v. 9, n. 1, 2017.
- NUSH, E. A. Comparison of different methods for chlorophyll and phaeopigment determination. **Archiv für Hydrobiologie Beiheft**, v. 14, p. 14–36, 1980.
- ODERMATT, D. et al. Review of constituent retrieval in optically deep and complex waters from satellite imagery. **Remote Sensing of Environment**, v. 118, p. 116–126, Mar. 2012.
- OGASHAWARA, I.; MISHRA, D. R.; GITELSON, A. A. Remote sensing of inland waters: background and current state-of-the-art. In: MISHRA, D. R.; OGASHAWARA, I.; GITELSON, A. A. (Eds). **Bio-optical modeling and remote sensing of inland waters**. Amsterdam: Elsevier, 2017. p. 1–24.
- OLMANSON, L. G.; BREZONIK, P. L.; BAUER, M. E. Airborne hyperspectral remote sensing to assess spatial distribution of water quality characteristics in large rivers: the Mississippi River and its tributaries in Minnesota. **Remote Sensing of Environment**, v. 130, p. 254–265, 2013.

PAHLEVAN, N. et al. Sentinel-2 MultiSpectral Instrument (MSI) data processing for aquatic science applications: demonstrations and validations. **Remote Sensing of Environment**, v. 201, p. 47–56, Aug. 2017.

PAHLEVAN, N. et al. Sentinel-2/Landsat-8 product consistency and implications for monitoring aquatic systems. **Remote Sensing of Environment**, v. 220, p. 19–29, Oct. 2018.

PARK, E.; LATRUBESSE, E. M. Remote sensing of environment modeling suspended sediment distribution patterns of the Amazon River using MODIS data. **Remote Sensing of Environment**, v. 147, p. 232–242, 2014.

PARK, E.; LATRUBESSE, E. M. The hydro-geomorphologic complexity of the lower Amazon River floodplain and hydrological connectivity assessed by remote sensing and field control. **Remote Sensing of Environment**, v. 198, p. 321–332, 2017.

PETERSON, K. et al. Suspended sediment concentration estimation from Landsat imagery along the lower Missouri and Middle Mississippi rivers using an extreme learning machine. **Remote Sensing**, v. 10, n. 10, p. 1503, 2018.

PINET, S. et al. Variability of apparent and inherent optical properties of sediment-laden waters in large river basins: lessons from in situ measurements and bio-optical modeling. **Optics Express**, v. 25, n. 8, p. A283, 2017.

PINTO, C. et al. First in-flight radiometric calibration of MUX and WFI on-board CBERS-4. **Remote Sensing**, v. 8, n. 5, p. 1–22, 2016.

PLATES, A. O. **Standard methods for the examination of water and wastewater**. [S.l.: s.n.], 1999.

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

R CORE TEAM. **R: a language and environment for statistical computing**. Vienna, Austria, 2017. Disponível em: <<https://www.r-project.org/>>.

RENÓ, V. F. et al. Assessment of deforestation in the Lower Amazon floodplain using historical Landsat MSS/TM imagery. **Remote Sensing of Environment**, v. 115, n. 12, p. 3446–3456, 2011.

RENÓ, V. F.; NOVO, E. M. L. M.; ESCADA, M. Forest fragmentation in the lower amazon floodplain: implications for biodiversity and ecosystem service provision to riverine populations. **Remote Sensing**, v. 8, n. 11, 2016.

RICHEY, J. E. et al. Water discharge and suspended sediment concentrations in the Amazon River: 1982–1984. **Water Resources Research**, v. 22, n. 5, p. 756–764, 1986.

RICHEY, J. E. et al. Outgassing from Amazonia rivers and wetlands as a large tropical source of atmospheric CO₂. **Nature**, v. 416, n. 1991, p. 617–620, 2002.

ROESLER, C. S.; BOSS, E. S. In situ measurement of the Inherent Optical Properties (IOPs) and potential for harmful algal bloom detection and coastal ecosystem observations. In: MARCEL, B.; ROESLER, C. S.; CULLEN, J. J. (Eds.). **Realtime observation systems for ecosystem dynamics and harmful algal blooms**. Paris: Unesco, 2008.

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

RUDORFF, C. D. M. D. M.; DUNNE, T.; MELACK, J. M. Recent increase of river–floodplain suspended sediment exchange in a reach of the lower Amazon River. **Earth Surface Processes and Landforms**, v. 43, n. 1, p. 322–332, 2018.

RUDORFF, C. M. D. M.; MELACK, J. M.; BATES, P. D. Flooding dynamics on the lower Amazon floodplain: 1. hydraulic controls on water elevation, inundation extent, and river-floodplain discharge. **Water Resources Research**, v. 50, n. 1, p. 619–634, 2014.

SANDER DE CARVALHO, L. A. et al. Implications of scatter corrections for absorption measurements on optical closure of Amazon floodplain lakes using the Spectral Absorption and Attenuation Meter (AC-S-WETLabs). **Remote Sensing of Environment**, v. 157, p. 123–137, 2015.

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

SAWAKUCHI, H. O. et al. Carbon dioxide emissions along the lower Amazon River. **Frontiers in Marine Science**, v. 4, p. 1–12, Mar. 2017.

SHEIKH, P. A.; MERRY, F. D.; MCGRATH, D. G. Water buffalo and cattle ranching in the Lower Amazon Basin: comparisons and conflicts. **Agricultural Systems**, v. 87, n. 3, p. 313–330, 2006.

SILVA, M. P. DA. **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 óticas**. 2018. 97p. Dissertação (Mestrado do em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2018.

SILVA, T. S. F.; MELACK, J. M.; NOVO, E. M. L. M. Responses of aquatic macrophyte cover and productivity to flooding variability on the Amazon floodplain. **Global Change Biology**, v. 19, n. 11, p. 3379–3389, 2013.

SIOLI, H. Alguns resultados e problemas da limnologia amazônica. **Boletim Técnico IPEAM**, v. 24, p. 3–44, 1951.

SNYDER, W. A et al. Optical scattering and backscattering by organic and inorganic particulates in U.S. coastal waters. **Applied Optics**, v. 47, n. 5, p. 666–77, 2008.

SORRIBAS, M. V. et al. Projections of climate change effects on discharge and inundation in the Amazon basin. **Climatic Change**, v. 136, n. 3/4, p. 555–570, 2016.

STRAMSKI, D. et al. The role of seawater constituents in light backscattering in the ocean. **Progress in Oceanography**, v. 61, n. 1, p. 27–56, 2004.

STREHER, A. S. et al. Sunglint correction in airborne hyperspectral images over inland waters. **Revista Brasileira de Cartografia**, v. 667, p. 1437–1449, 2014a.

TUNDISI, J. G. et al. How many more dams in the Amazon. **Energy Policy**, v. 74, n. C, p. 703–708, 2014.

TUNDISI, J. G.; MATSUMURA-TUNDISI, T. **Limnologia**. São Paulo: Oficina de Textos, 2008.

TWARDOWSKI, M. S. et al. A model for estimating bulk refractive index from the optical backscattering ratio and the implications for understanding particle composition in case I and case II waters. **Journal of Geophysical Research**, v. 106, n. C7, p. 14129, 2001.

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

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

VANHELLEMONT, Q.; RUDDICK, K. ACOLITE processing for Sentinel-2 and Landsat-8: atmospheric correction and aquatic applications. **Living Planet Symposium**, 2016.

VERMOTE, E. et al. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46–56, 2016.

- VERMOTE, E. F. et al. Second Simulation of the Satellite Signal in the Solar Spectrum (6S): 6S user guide version 2: appendix III: description of the subroutines. **IEEE Transactions on Geoscience and Remote Sensing**, v. 35, n. 3, p. 675–686, 1997.
- VIGEN, T. **Spurious correlations**. [S.l.] Hachette books, 2015.
- WANG, D. et al. The assessment of Landsat-8 OLI atmospheric correction algorithms for inland waters. **Remote Sensing**, v. 11, n. 2, p. 169, 2019.
- WANG, M.; SHI, W. The NIR-SWIR combined atmospheric correction approach for MODIS ocean color data processing. **Optics Express**, v. 15, n. 24, p. 15722–15733, 2007.
- WANG, Z. et al. Retrieval of chlorophyll-a and total suspended solids using iterative stepwise elimination partial least squares (ISE-PLS) regression based on field hyperspectral measurements in irrigation ponds in Higashihiroshima, Japan. **Remote Sensing**, v. 9, n. 3, p. 1–14, 2017.
- WEI, J. 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, R. G.; LIKENS, G. E. **Limnological analysis**. Berlin: Springer, 2013.
- WILCOXON, F. Individual comparisons by ranking methods. **Biometrics Bulletin**, v. 1, n. 6, p. 80–83, 1945.
- WILSON, R. T. Py6S: a Python interface to the 6S radiative transfer model. **Computers and Geosciences**, v. 51, p. 166–171, 2013.
- WINKLERPRINS, A. M. G. A. Jute cultivation in the Lower Amazon, 1940-1990: an ethnographic account from Santarém, Pará, Brazil. **Journal of Historical Geography**, v. 32, n. 4, p. 818–838, 2006.
- XU, M. et al. A spectral space partition guided ensemble method for retrieving chlorophyll-a concentration in inland waters from Sentinel-2A satellite imagery. **Journal of Great Lakes Research**, 2018. In press.

- YEPEZ, S. et al. Retrieval of suspended sediment concentrations using Landsat-8 OLI satellite images in the Orinoco River (Venezuela). **Comptes Rendus - Geoscience**, v. 350, n. 1/2, p. 20–30, 2018.
- ZHANG, X.; HU, L. Estimating scattering of pure water from density fluctuation of the refractive index. **Optics Express**, v. 17, n. 3, p. 1671-1678, 2009.
- ZHENG, Z. et al. Landsat-based long-term monitoring of total suspended matter concentration pattern change in the wet season for Dongting Lake, China. **Remote Sensing**, v. 7, n. 10, p. 13975–13999, 2015.
- ZHOU, G. et al. The polarization patterns of skylight reflected off wave water surface. **Optics Express**, v. 21, n. 26, p. 32549, 2013.
- ZIMMERMAN, D. W. A warning about the large-sample Wilcoxon-Mann-Whitney test. **Understanding Statistics**, v. 2, n. 4, p. 267–280, 2003.
- ZOCATELLI, R. et al. Sedimentary evidence of soil organic matter input to the curuai amazonian floodplain. **Organic Geochemistry**, v. 63, p. 40–47, 2013.
- ZOCATELLI, R. et al. Holocene land cover dynamics in the Curuai Floodplain inferred from lacustrine biomarkers. **Palaeogeography, Palaeoclimatology, Palaeoecology**, v. 443, p. 237–248, 2016.
- ZULLO-JUNIOR, J. **Correção atmosférica de imagens de satélite e aplicações**. 204 p. Tese (Doutorado em Engenharia Elétrica)-Universidade Estadual de Campinas, Campinas, 1994.