



UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE GEOCIÊNCIAS  
CURSO DE ESPECIALIZAÇÃO EM GEOPROCESSAMENTO AMBIENTAL

**APLICAÇÃO DE ALGORITMOS SEMI-ANALÍTICOS À IMAGENS  
SENTINEL-2 PARA A ESTIMATIVA DE CLOROFILA-A NO LAGO  
PARANOÁ-DF**

**Henrique Dantas Borges**

MONOGRAFIA

BRASÍLIA 2018



UNIVERSIDADE DE BRASÍLIA  
INSTITUTO DE GEOCIÊNCIAS  
CURSO DE ESPECIALIZAÇÃO EM GEOPROCESSAMENTO AMBIENTAL

**Henrique Dantas Borges**

**APLICAÇÃO DE ALGORITMOS SEMI-ANALÍTICOS À IMAGENS  
SENTINEL-2 PARA A ESTIMATIVA DE CLOROFILA-A NO LAGO  
PARANOÁ-DF**

**Monografia de especialização em  
Geoprocessamento Ambiental apresentada a  
banca examinadora do Instituto de Geociências  
como exigência para a obtenção do título de  
especialista em Geoprocessamento**

**Orientadora: Prof Dr<sup>a</sup> Rejane Ennes Cicerelli**

**Aprovada em 09/03/2018**

**BANCA EXAMINADORA**

Prof Dr<sup>a</sup>. Tati Almeida (co-orientadora)

\_\_\_\_\_

Prof. Dr. Henrique Llacer Roig

\_\_\_\_\_

Prof. Ms. Elton Souza Oliveira

\_\_\_\_\_

# 1 INTRODUÇÃO

---

As propriedades inerentes de águas naturais (IOPs – *inherent optical properties*), como os coeficientes de absorção ( $a(\lambda)$ ) e de espalhamento  $bb(\lambda)$ , são parâmetros independentes das variações na distribuição angular do campo de luz incidente, sendo determinadas, apenas, pelas substâncias presentes no meio aquático (KAMPEL et al, 2005). Por isso, estas propriedades são as principais responsáveis por governar a propagação da luz na coluna d'água e, portanto, muito importantes na estimativa das concentrações de componentes opticamente significativos (COS) como o fitoplâncton, material em suspensão e matéria orgânica dissolvida que são fundamentais para o monitoramento da qualidade da água.

Para águas interiores a complexidade óptica desses ambientes torna a obtenção de Clorofila-a (Chl-a) a partir da reflectância de sensoriamento remoto desafiadora. Ainda assim, diversas abordagens empíricas têm obtido sucesso na determinação desse parâmetro (MATTHEWS, 2011). No entanto, esses modelos estão fortemente limitados ao conjunto de dados utilizado na sua calibração original. Além disso, especialmente em casos em que há alta concentração de sólidos em suspensão ou matéria orgânica dissolvida, a resposta óptica da Chl-a pode ser mascarada (BUKATA, 1995; ZHOU et al., 2009). Por isso, IOCCG (2006) e Zhou et al. (2009) sugeriram que os valores da concentração de Chl-a fossem obtidos a partir de IOPs como a absorção.

Sendo assim, diversos modelos foram desenvolvidos com o intuito de estimar IOPs a partir de propriedades ópticas aparentes (POA), com a reflectância de sensoriamento remoto (KALLIO et al., 2015; ALIKAS et al., 2015). Dentre os modelos, existem os empíricos, que utilizam uma abordagem mais simplificada e os modelos analíticos e semi-analíticos, que utilizam o entendimento analítico do comportamento da luz na água como base na criação dos algoritmos, em princípio, estes algoritmos. Com base neste princípio, vários algoritmos semi-analíticos foram formulados para a derivação de IOPs. Outras formulações, baseadas no algoritmo “Quasi-Analytical Algorithm” (QAA), originalmente apresentado por Lee et al. (2002) para águas oceânicas, foram propostas nos últimos anos para diferentes ambientes. Por utilizar propriedades físicas da óptica da água, essa abordagem é capaz de obter bons resultados mesmo em corpos de água com características significativamente diferentes (LI et al., 2013).

Porém esses modelos contam com o uso de comprimento de onda específicos, nem sempre disponíveis em satélites comerciais. Assim um dos desafios futuros é configurar espectral e espacialmente sensores adequados às especificidades da resposta espectral da água. Historicamente, os sensores projetados para monitoramento da água foram criados com foco em pesquisas relacionadas a aplicações de sensoriamento remoto oceânicas, tornando-os inadequados ao uso em águas continentais devido a baixas resoluções espaciais e radiométricas, assim como uso de bandas espectrais não ideais (Palmer et al., 2015).

Neste contexto, o sensor Multispectral Imager (MSI), a bordo do recentemente lançado satélite Sentinel-2 tem sido apontado como de grande potencial no sensoriamento remoto de águas continentais. Apesar de ter sido projetado como um sensor multi-propósito, suas 13 bandas, com resoluções espaciais de 10m, 20m e 60m e resolução radiométrica de 12-bit (ESA, 2015) podem fornecer informações necessárias para que bons resultados sejam alcançados em águas continentais. Uma exploração inicial deste potencial já tem sido demonstrada por alguns autores (LIU et al., 2016; TOMING et al., 2016; CHEN et al., 2017).

Um grande empecilho no processo de estimativa de parâmetros de qualidade da água é a qualidade da correção atmosférica utilizada. Superfícies de água são características por possuírem baixíssimos valores de reflectância quando comparados a superfícies terrestres tornando-a a adequada remoção dos efeitos atmosféricos ainda mais importante (IOCCG, 2010). Essa dificuldade é tamanha que o uso de imagens não corrigidas pode resultar em melhores resultados do que as imagens corrigidas atmosféricamente (KUTSER, 2012). Vários algoritmos de correção atmosféricas podem ser aplicados às imagens MSI, serão testados o Sen2Cor, o ACOLITE e o ENVI FLAASH.

Este estudo tem como objetivo avaliar a performance de diferentes modelos semi-analíticos na obtenção da concentração de chl-a com uso de dados radiométricos de campo e, em seguida, avaliar a aplicabilidade deste modelo a imagens MSI corrigidas atmosféricamente por diferentes algoritmos. O estudo foi feito no Lago Paranoá. Localizado na capital do Brasil, Brasília, esse lago urbano é utilizado para múltiplas finalidades pela população local, tanto como receptor de efluentes domésticos, como para atividades recreativas e como fonte de água para abastecimento humano. No passado, este lago passou por fortes eventos de eutrofização, resultantes da descarga de nutrientes junto aos efluentes domésticos. Dado os usos múltiplos do lago, o seu monitoramento é ainda mais relevante.

## 2 AQUISIÇÃO DE DADOS E METODOLOGIA

### 2.1 ÁREA DE ESTUDO

O Lago Paranoá (Figura 1) foi criado pelo barramento do rio Paranoá durante a construção de Brasília na década de 50. Sua área é de 38km<sup>2</sup>, com profundidade média de 14m e máxima de 40m e volume de  $498 * 10^6$  m<sup>3</sup>. É um lago urbano, que recebe águas pluviais provenientes de Brasília, assim como dos rios Bananal, Gama, Riacho Fundo e Torto. No passado, nas décadas de 70 e 80, o lago passou por um grave processo de eutrofização devido ao despejo de esgoto doméstico não tratados. Esse processo foi revertido com a construção de duas Estações de Tratamento de Esgoto, que ainda despejam efluente tratado no Lago Paranoá.




Figura 1 – Localização do Lago Paranoá.

### 2.2 REFLECTÂNCIA DE SENSORIAMENTO REMOTO DE CAMPO (IN SITU)

Foram feitas 4 campanhas de campo na qual valores de Reflectância de Sensoriamento Remoto (Rrs) e concentração de Chl-a.

As medições dos valores de Rrs foram feitas com o uso de um conjunto de radiômetros hiperspectrais TriOS RAMSES. A geometria de instalação segue a recomendação de Mobley (1999). Os valores de reflectância são então obtidos por meio da equação 1:

$$R_{rs} = \frac{Lu - Ld * p}{Ed} \quad (1)$$

Em que:  $Lu$  é a radiância ascendente da superfície da água;  $Ld$  é a radiância da atmosfera que é usada para corrigir os efeitos de espalhamento da radiação eletromagnética na interface ar-água;  $Ed$  é a irradiância descendente sobre a água de superfície;  $p$  é um fator proporcional que depende das condições do céu, velocidade do vento, ângulo solar zenital e geometria de visada, utilizando-se o valor sugerido de 0,028 para as condições de aquisição deste estudo (Mobley, 1999).

Durante os campos, o conjunto de radiômetros fica ligado à um computador no qual é feita a aquisição dos dados. Em cada ponto de interesse, o conjunto de radiômetros é posicionado à um ângulo azimutal em relação ao sol de  $135^\circ$  e foram medidas cerca de 10 curvas espectrais, o resultado final de cada ponto é a média dessas curvas

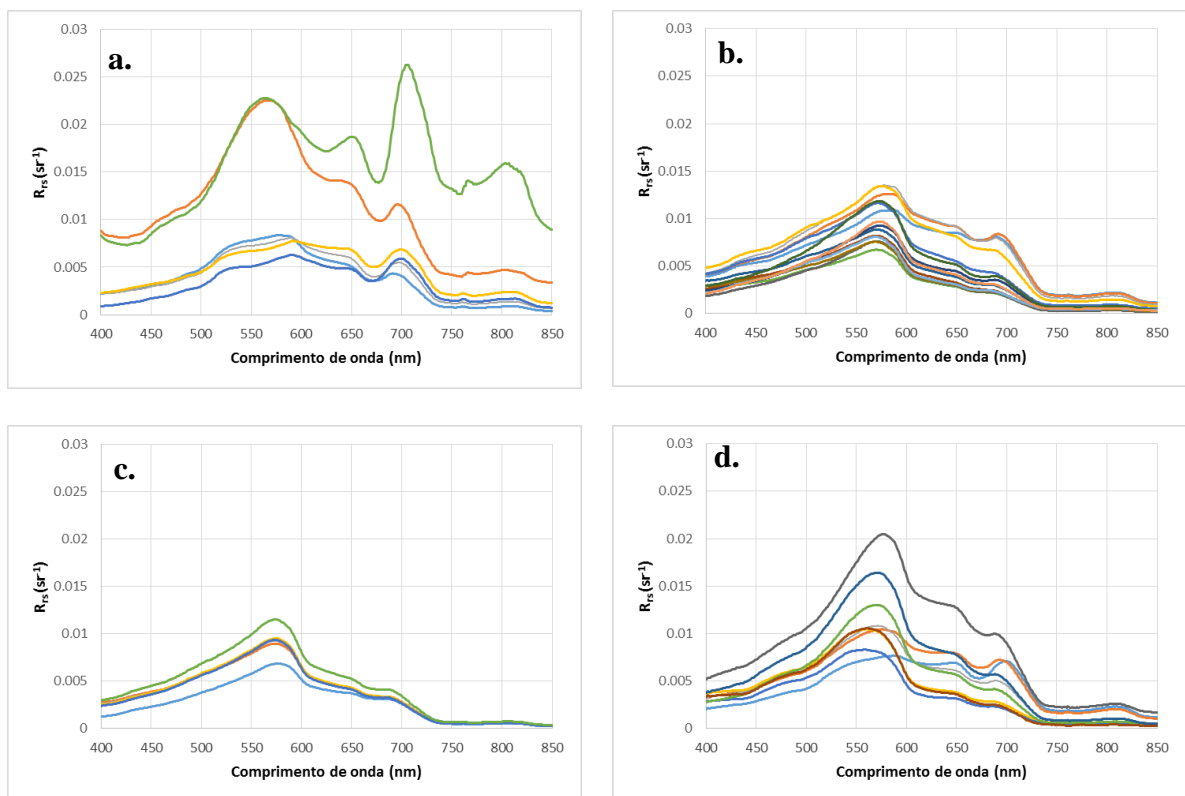


Figura 2. Espectros de reflectância de sensoriamento remoto de diferentes dias no Lago Paranoá. a. 26/11/2016 b.05/05/2017 c.14/06/2017 d.25/10/2017.

### 2.3 IMAGENS DE SATÉLITE

O Multi-Spectral Instrument (MSI) é um sensor óptico do tipo pushbroom montado a bordo dos satélites Sentinel-2A e Sentinel-2B. De forma conjunta, estes satélites fornecem uma taxa de revisita de 5 dias no equador e oferecem imagens de alta resolução em 13 bandas espectrais que vão do visível ao infravermelho de ondas curtas, com resoluções de 10, 20 e 60 metros e resolução radiométrica de 12bits. O produto L1C é fornecido como reflectância do topo da atmosfera em cenas ortorretificadas de 100km<sup>2</sup> em uma projeção UTM/WGS84.p

As imagens MSI Level-1C (L1C) foram obtidas através do portal “Copernicus Scientific Data Hub” (<https://scihub.copernicus.eu/>). Foram adquiridas imagens do dia 05/05/2017, no qual foram feitas de forma simultânea a amostragem de campo e do dia 26/12/2016.

### 2.4 MEDIÇÃO DA CONCENTRAÇÃO DE CHL-A IN-SITU

As amostras de água coletadas em cada ponto são filtradas por filtros com miliporos de 0,45 µm para a Chl-a e em filtro de miliporos de 0,7 µm para os sólidos totais em suspensão (STS). Para esses dois componentes a filtragem foi feita por uma bomba de sucção a vácuo e por unidade de filtração de polisulfona. A determinação das concentrações foi feita seguindo o método descrito em APHA (1998).

É possível ver na tabela 1 que o maior observado foi de 52,12 mg/L, e o menor de 0,39 mg/L. O dia 26/11/2016 apresentou o maior valor médio, resultante de um evento de eutrofização no Lago Paranoá. Nesse mesmo dia, foi medido um ponto com concentração de 176 mg/L, que foi retirado das análises por ser considerado um outlier.

Tabela 1 – Estatística descritiva das medições de chl-a in-situ, em mg/L

<b>Dia</b>	<b>Nº de pontos</b>	<b>Max</b>	<b>Min</b>	<b>Média</b>	<b>Desvio Padrão</b>
26/11/2016	6	52.12	11.42	23.64	16.21
05/05/2017	14	12.01	0.39	4.44	3.39
14/06/2017	6	4.91	1.09	3.64	1.44
25/10/2017	8	24.39	1.17	7.30	6.81

## 2.5 ESTIMATIVA DE ABSORÇÃO A PARTIR DE RRS

O QAA é um modelo semi-analítico, originalmente desenvolvido por Lee et al. (2002) que é capaz de derivar IOPs como os coeficientes de absorção  $a(\lambda)$  e de espalhamento  $bb(\lambda)$  da água a partir da reflectância de sensoriamento remoto  $Rrs(\lambda)$ . Os QAA utilizados também são capazes de estimar os componentes da absorção, em particular, a absorção do fitoplâncton ( $a_{phy}$ ).

Este estudo buscou entender o comportamento de QAAs originalmente criados para diferentes aplicações, em um reservatório oligotrófico tropical com uso de medições radiométricas e de imagens de satélite. Quatro algoritmos foram testados. O QAAV5 (LEE et al., 2009), foi desenvolvido para aplicações em águas oceânicas. Os demais QAA foram desenvolvidos para águas interiores, o QAAM14 (MISHRA et al., 2014) e o QAABBHR (WATANABE et al., 2016) foram aplicados a águas hipereutróficas. Já o IIMIW (LI et al., 2013) é outro algoritmo semi-analítico que utiliza princípios similares aos QAAs citados anteriormente. Esse será avaliado neste estudo por ter sido parametrizado com base em ambientes na China e nos EUA em lagos com características relativamente parecidas as aquelas observadas no Lago Paranoá.

O QAAM14 e o QAABBHR possuem diferenças relativas aos diferentes ambientes utilizados nas suas parametrizações e calibrações. Vale destacar, também, que o IIMIW faz a estimativa da absorção total subtraída da absorção da água ( $a_{t-w}$ ), mas assume que para comprimentos de onda superiores a 620nm essa absorção é majoritariamente composta pela absorção do fitoplâncton, adotando, portanto, que  $a_{t-w} = a_{ph}$ .

## 2.6 ESTIMATIVA DE CHL-A A PARTIR DE APH

Com base nos valores de absorção obtidos dos diferentes QAA utilizados, foram utilizadas duas abordagens distintas para realizar a estimativa da concentração de Chl-a.

Na primeira abordagem, os IOPs estimados foram utilizados na parametrização de modelos bio-ópticos. Os algoritmos two-band (2B) e three-band (3B)(GITELSON et al., 2003) e o Normalized Difference Chlorophyll Index (NDCI) foram reparametrizados com base nos valores de  $Rrs$  de campo para realizar a estimativa de Chl-a. Além disso, foi feita a decomposição dos algoritmos citados acima em termos de  $a_{\phi}$  e  $a_w$ , conforme proposto por Le et al. (2013) para os index 2B e 3B e por Watanabe et al. (2016) para o NDCI.



Ao contrário das águas oceânicas, em que o fitoplâncton é praticamente o único OAC, águas interiores são muito afetadas opticamente pela presença do CDOM. Por isso, modelos baseados em comprimentos de onda nas faixas do vermelho e do infravermelho próximo têm sido muito utilizados (GITELSON et al., 2008; MISHRA & MISHRA, 2012; LE et al., 2013; MATSUSHITA et al., 2015). Desta forma, e com base nas bandas centrais do Sentinel-2, os algoritmos foram adaptados aos comprimentos de onda de 665, 705 e 740nm, juntamente com a concentração de Chl-a *in-situ*, para se obter uma regressão linear para cada modelo. As equações (2) a (7) mostram cada modelo empírico que foi parametrizado.

$$2B \propto R_{rs}(705)/R_{rs}(665) \quad (2)$$

$$3B \propto [(R_{rs}^{-1}(705) - R_{rs}^{-1}(665))] \times R_{rs}(740) \quad (3)$$

$$NDCI \propto \frac{R_{rs}(705) - R_{rs}(665)}{R_{rs}(705) + R_{rs}(665)} \quad (4)$$

$$\Psi_1 = [a_{ph}(665) + a_w(665)]/a_w(705) \quad (5)$$

$$\Psi_2 = [a_{ph}(665) + a_w(665) - a_{ph}(705) - a_w(705)]/a_w(740) \quad (6)$$

$$\Psi_3 = \frac{a_w(665) + a_{ph}(665) - a_w(705)}{a_{ph}(665)} \quad (7)$$

Em que  $a_{ph}$  é a absorção da chl-a e  $a_w$  é absorção da água pura.

Na segunda abordagem, os algoritmos propostos por Ritchie (2008), Gons et al. (2008) e Gitelson et al. (2010), que relacionam os valores de  $a_{ph}$  diretamente com a concentração de Chl-a, foram utilizados. Ritchie (2008) propôs a Eq. 9 para uso em laboratório, portanto, é preciso converter os valores de absorção do fitoplâncton *in-vitro* ( $a_{sol}$ ) para  $a_{ph}$  conforme a Eq. 8 (SIMIS et al. 2007).

$$a_{sol} = \frac{a_{ph}(665)}{0.68} \quad (8)$$

$$Chl - a(mg m^{-3}) = 4.34 \times [-0.3319a_{sol}(630) - 1.7485a_{sol}(647) + 11.9442a_{sol}(665) - 1.4306a_{sol}(691)] \quad (9)$$

O algoritmo proposto por Gons et al. (2008):

$$Chl - a(mg\ m^{-3}) = \frac{a_{ph}(665)}{a_{ph}^*(665)} \quad (10)$$

Em que  $a_{ph}^*(665)$  denota a absorção específica do fitoplâncton em 665nm e vale 0,0161  $m^2(mg\ Chl - a)^{-1}$ .

O algoritmo proposto por Gitelson et al. (2010):

$$Chl - a(mg\ m^{-3}) = \left[ \frac{a_{ph}(665)}{0.022} \right]^{1.124} \quad (11)$$

A efetividade de cada modelo, para cada QAA, foi avaliada com uso dos métodos estatísticos *root mean square error* (RMSE), *relative error* RE e *mean relative error* MRE.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X' - X)^2} \quad (12)$$

$$RE(\%) = \frac{|X' - X|}{X} \times 100\% \quad (13)$$

$$MRE(\%) = \frac{1}{N} \sum_{i=1}^N RE_i \quad (14)$$

Em que  $X'$  são os valores estimados e  $X$  os valores medidos.

## 2.7 AVALIAÇÃO DA CORREÇÃO ATMOSFÉRICA DE IMAGENS MSI/SENTINEL2 PARA ESTIMATIVA DE CHL-A

A baixa reflectância da água, especialmente quando as concentrações de substâncias opticamente ativas é baixa, torna o seu monitoramento particularmente sensível a qualidade da correção atmosférica aplicada às imagens de satélite. Desta forma, este estudo buscou avaliar três métodos de correção atmosférica aplicado às imagens MSI. Com base nas imagens MSI corrigidas, um conjunto de 3x3 pixels foi extraído em cada ponto de coleta para as bandas B1 (443nm), B3 (560nm), B4(665nm), B5(705nm) e B7(783nm) e comparado aos valores de campo em termos de RMSE e MRE.

A avaliação dos diferentes métodos de correção atmosférica foi feita com o intuito de identificar o melhor produto de reflectância advindo das imagens MSI Sentinel-a a ser utilizado para a estimativa da concentração de clorofila-a no Lago Paranoá. Sendo assim, também foi

feita a comparação de cada método de correção atmosférica quando aplicado à obtenção de  $aphy(665)$  com o algoritmo semi-analítico de melhor performance na obtenção de chl-a.

Este estudo testará o algoritmo Sen2Cor, parte do toolbox Sentinel, fornecido pela Agência Espacial Europeia e possivelmente a escolha mais comum na correção atmosférica das imagens MSI (Main-Knorn et al., 2015); o ACOLITE que é um algoritmo de correção baseado em imagens desenvolvido por Vanhellemont e Ruddick (2016); e o ENVI FLAASH, baseado no MODTRAN4 (ENVI, 2009).

### 3 RESULTADOS E DISCUSSÃO

#### 3.1 AVALIAÇÃO DOS MODELOS SEMI-ANALÍTICOS COM DADOS DE CAMPO

##### 3.1.1 Abordagem por ajuste empírico

Foram utilizadas duas abordagens na estimativa da concentração de Chl-a. Na primeira delas, modelos que estimam Chl-a a partir de Rrs foram reparametrizados para que os valores de  $aphy$  obtidos pelos modelos semi-analíticos pudessem ser utilizados e comparados aos modelos originais baseados nos valores de Rrs medidos em campo. Nesta abordagem, a modelagem entre os valores de Rrs ou de  $aphy$  e os valores de clorofila é feita de forma empírica, e, portanto, precisa de valores de campo para ser realizada. A performance de cada um dos modelos foi avaliada com os indicadores estatísticos  $R^2$ , RMSE e MRE, conforme pode ser visto na Tabela 2.

Tabela 2 – Avaliação estatística das estimativas empíricas (eq. 2-7) da concentração de Chl-a utilizando diferentes algoritmos.

Modelo para obtenção de $aphy$	Método de regressão	Inclinação	Intercepção	$R^2$	RMSE (mg/L)	Erro Médio (%)
<i>Modelos calibrados a partir de Rrs</i>						
	2B	42.7785	-22.6155	<b>0.8589</b>	3.6812	28.9673
	3B	158.1200	19.5463	<b>0.8418</b>	3.8979	40.2416

	NDCI	72.8006	21.0852	<b>0.7995</b>	4.3878	36.5783
<i>Modelos calibrados a partir de aphy</i>						
V5	$\Psi_1$	-6.2222	15.0871	<b>0.0101</b>	9.7490	129.8208
	$\Psi_2$	42.8991	19.5408	<b>0.6366</b>	5.9067	69.5732
	$\Psi_3$	-10.1408	8.6552	<b>0.0054</b>	9.7724	129.3368
BBHR	$\Psi_1$	38.2000	-24.3997	<b>0.8382</b>	3.9417	29.6693
	$\Psi_2$	68.7885	20.1305	<b>0.8425</b>	3.8882	29.7132
	$\Psi_3$	74.6437	14.7115	<b>0.7345</b>	5.0494	43.5238
M14	$\Psi_1$	33.5570	-18.7579	<b>0.8645</b>	3.6074	29.2150
	$\Psi_2$	73.7086	19.1854	<b>0.8644</b>	3.6088	29.4448
	$\Psi_3$	63.3478	15.8186	<b>0.7444</b>	4.9537	45.0441
IIMIW	$\Psi_1$	39.5093	-20.3448	<b>0.8552</b>	3.7291	29.1596
	$\Psi_2$	73.3167	19.1645	<b>0.8552</b>	3.7291	29.1596

O QAAM14(w2) obteve os melhores resultados de forma geral, com  $R^2=88,24\%$ ,  $RMSE=3,92$  e Erro médio =  $89,43\%$ . O alto valor do erro médio pode ser explicado pela grande variabilidade percentual que um erro absoluto relativamente pequeno gera em valores amostrais próximos à zero. É possível perceber pelos resultados apresentados na Tabela 2, que os valores de aphy obtidos pelo V5 não foram capazes de estabelecer uma boa correlação com a concentração de chl-a para todos os modelos empíricos aplicados (w1, w2 e w3). Como este estudo não fez medições dos valores de absorção em laboratório, razões pelas quais estes modelos não tiveram boa performance são relativamente especulativas. Mesmo assim, resultados ruins já eram esperados deste do QAAV5, visto que este foi originalmente calibrado para águas oceânicas, que possuem características ópticas significativamente diferentes daquelas observadas em águas continentais devido principalmente à maior concentração de sedimento e matéria orgânica. Os demais modelos semi-analíticos obtiveram bons resultados, sendo os índices  $\Psi_1$  e  $\Psi_2$  os com melhor performance. Os demais modelos (fora o V5), assim

como os modelos baseados em Rrs, obtiveram resultados parecidos aos do QAAM14. Enquanto este resultado por um lado valida indiretamente os modelos semi-analíticos, por outro mostra que o aumento na complexidade do modelo (em relação aos modelos baseados em Rrs) não gerou resultados significativamente superiores.

### **3.1.2 Abordagem direta**

Na segunda abordagem, os resultados de aphy obtidos foram utilizados para estimar a concentração de chl-a através das equações (9), (10) e (11). Ao contrário da abordagem anterior, no qual houve uma calibração dos modelos com os dados medidos em campo, aqui buscou-se estimar a concentração de chl-a diretamente. A tabela 3 mostra os resultados obtidos. Nela, é possível perceber novamente que o QAAV5 não foi capaz de obter resultados satisfatórios. As três equações testadas obtiveram resultados parecidos, sendo que o modelo proposto por Li (2013) foi o que obteve os melhores resultados, alcançando um RMSE=4.63, R<sup>2</sup>=85,52% e MRE=33,14% com a eq. (11). Também pode ser observado que os valores de inclinação encontrados foram todos inferiores a 1, indicando que por mais que os modelos estejam atingindo altos níveis de correlação, eles estão superestimando os valores de clorofila. O IIMIW foi o que obteve os valores de inclinação mais próximos a 1, enquanto o qaam14 e o qaabbhr tiveram valores de inclinação mais baixos, possivelmente devido ao fato destes dois modelos terem sido calibrados para águas com altíssimas concentrações de chl-a. Em termos do erro percentual médio, o IIMIW foi o algoritmo de melhor performance, apresentando valores significativamente menores àqueles do qaam14 e do qaabbhr, indicando principalmente sua superioridade na estimativa de chl-a em pontos na qual a concentração deste IOP era muito baixa (<5 mg/L).

De forma geral, apesar dos resultados obtidos pelo qaam14 e pelo qaabbhr terem sido relativamente satisfatórios, o IIMIW teve um desempenho consideravelmente melhor nesta abordagem. Isto pode ser explicado pelo fato desse modelo ter sido parametrizado em águas com características físico-químicas mais próximas às observadas no lago Paranoá e indica que ele pode ser um bom algoritmo caso se queira estimar os valores de absorção da água deste lago. Por ter sido o modelo com melhor performance, testou-se o desempenho do IIMIW com as bandas simuladas do MSI-SENTINEL2, visto que há o intuito de se aplicar este modelo a imagens de satélite deste sensor. Como pode ser visto na tabela 3, foram obtidos valores de R<sup>2</sup>=85,7%, RMSE=5,97 e Erro médio = 104,11%, significativamente piores aos obtidos

anteriormente, mas ainda satisfatórios para a determinação da concentração de chl-a no Lago Paranoá.

Por ter sido o algoritmo de melhor performance, testou-se a performance do IIMIW com as bandas simuladas do sensor MSI, fazendo as adaptações apropriadas em relação aos comprimentos de onda usados no modelo original. Conforme a tabela 2, é possível perceber como houve uma queda considerável na qualidade de predição do algoritmo, tanto para as equações de Gitelson, quanto para a de Gons. Em particular, houve um aumento considerável do erro médio, acompanhado de um valor de interceptação de -3.2624, indicando que o uso de bandas simuladas faz com que o modelo superestime a concentração de chl-a, afetando principalmente os pontos amostrais de baixa concentração. Por isso, é adequado que a aplicação do modelo a imagens MSI seja feita com uso deste ajuste empírico.

Ao se comparar os resultados obtidos na primeira e na segunda abordagem é possível concluir que enquanto os algoritmos IIMIW, QAAM14 e QAABBHR foram adequados à modelagem empírica descrita em 3.1.1, apenas o IIMIW foi capaz de estimar de forma apropriada a magnitude do valor de  $a_{ph}$  para que eles pudessem ser diretamente aplicados às equações (9), (10) e (11). Além disso, é necessário levar em conta o fato de que parte considerável dos pontos amostrais utilizados nesta pesquisa eram de parcelas de água com baixas concentrações de chl-a. Nessas medições a razão sinal/ruído ocasionada pela precisão do método de aferição é alta e pode prejudicar de forma considerável a verdade de campo considerada. Sendo assim, apesar do valor de RMSE de 4,6 mg/L poder ser considerado relativamente alto para um lago oligotrófico, o IIMIW pode ser considerado um modelo apropriado para a aferição da concentração de chl-a em conjunto à equação (11) a partir de dados radiométricos de campo.

Tabela 3 – Avaliação estatística da estimativa de concentração de chl-a a partir do  $a_{phy}$  estimado por algoritmos semi-analíticos, aplicados às equações (9), (10) e (11).

Modelo para obtenção de $a_{phy}$	Modelo para obtenção de chl-a	Inclinação	Interceptação	R <sup>2</sup>	RMSE (µg/L)	Erro Médio
IIMIW	Gitelson	0.7878	0.7787	85.52%	4.6307	33.14%
	Gons	0.7072	1.5843	86.78%	5.3335	35.72%
	Ritchie	0.7307	0.8545	85.82%	5.3325	35.00%

<b>QAAV5</b>	Gitelson	-0.1241	11.7604	1.01%	23.3406	586.71%
	Gons	-0.1075	11.4850	1.07%	25.3223	627.77%
	Ritchie	-0.0200	8.8989	0.03%	23.3950	587.42%
<b>QAABBHR</b>	Gitelson	0.7617	-3.9763	83.82%	9.2036	162.78%
	Gons	0.6573	-2.4679	85.02%	10.1116	150.22%
	Ritchie	0.7089	-3.5440	84.52%	9.9748	168.05%
<b>QAAM14</b>	Gitelson	0.6691	-0.8168	86.45%	7.8657	84.81%
	Gons	0.5806	0.2452	87.80%	9.3302	72.82%
	Ritchie	0.6290	-0.6267	87.09%	8.7440	89.66%
<b>HMIW (Bandas MSI simuladas)</b>	Gitelson	0.8985	-3.2624	85.70%	5.9744	104.11%
	Gons	0.7932	-1.8284	86.95%	6.1860	88.58%

### 3.2 AVALIAÇÃO DOS ALGORITMOS DE CORREÇÃO ATMOSFÉRICA

A Figura 3 mostra a média dos valores de reflectância por banda para cada método de correção atmosférica, assim como para a reflectância do topo da atmosfera. Enquanto a reflectância de topo da atmosfera apresenta uma curva espectral caracterizada principalmente pela dominância dos efeitos do espalhamento atmosférico, as curvas corrigidas apresentam um padrão espectral similar ao observado in-situ, com um pico de reflectância na banda 3. Isso evidencia que por mais que os métodos de correção possam não ter sido perfeitamente acurados, houve sucesso na remoção da maior parte dos efeitos atmosféricos.




Figura 3. Comparação da reflectância MSI média proveniente da reflectância de topo da atmosfera, simulada por medições radiométricas de campo e de três diferentes algoritmos de correção atmosférica (Sen2Cor, ACOLITE e FLAASH).

Com o intuito de descobrir qual o melhor método de correção atmosférica a ser utilizado, a performance desses algoritmos, em reflectância, foi comparada em termos de RMSE e MRE (Figura 4). Em termos de RMSE, os três algoritmos tiveram uma performance satisfatória, com RMSE menores que 0.01 em todas as bandas avaliadas sendo que, na média, os menores valores médios de RMSE foram observados com o Sen2Cor e o Flaash. Destaca-se, em particular, os baixos valores de RMSE ( $< 0.004$ ) observados nas bandas 4 e 5 com o uso do modelo Flaash, bandas, estas, utilizadas em modelos bio-ópticos para predição de concentrações de chl-a. Já o Sen2Cor conseguiu atingir valores de erro relativo médio menores que 50% para as bandas 1, 3, 4 e 5. Os altos erros relativos observados na banda 7, principalmente nos resultados obtidos pelo Flaash, pode ser explicada pelo fato dos valores observados in situ nesta banda terem sido muito baixos (média de 0,26% para todos os pontos), fazendo com que pequenos erros absolutos causem alto erro relativo.

Apesar de resultados satisfatórios terem sido alcançados com o ACOLITE, isto só se deu após várias iterações das configurações internas do modelo. Somente após adotar um valor fixo de 35 para o percentil da reflectância do aerossol que o modelo conseguiu obter bons resultados. Anteriormente, o ACOLITE estava superestimando os efeitos atmosféricos, resultando em valores negativos de reflectância especialmente nas regiões mais limpas do Lago



Paranoá. Os valores observados estão em consonância com os encontrados por Martins et al. (2017), que avaliou a qualidade da correção atmosférica do Sen2Cor, do ACOLITE e do 6SV em imagens MSI de planícies de inundação da bacia amazônica.




Figura 4. RMSE e MRE de cada método de correção atmosférica em relação aos dados de campo.

Apenas uma análise por bandas da correção atmosférica pode não ser suficiente para definir se bons resultados serão obtidos na aplicação de modelos bio-ópticos. Erros aparentemente pequenos podem se propagar e afetar negativamente o resultado final na aplicação destes modelos. Por isso, a performance de cada algoritmo de correção atmosférica foi avaliada em termos do valor de  $a_{phy}(665)$  estimado pelo IIMIW (Tabela 4).

Entre os modelos de correção atmosférica, o FLAASH foi o de melhor performance, obtendo resultados de  $RMSE = 0.102$  e  $MRE = 73,0\%$ . Nas estimativas feitas pelo Sen2Cor e pelo ACOLITE, houve a estimativa de valores negativos em certos pontos, principalmente devido a subestimação de reflectâncias da banda 5. Caso esses pontos sejam excluídos, a correção feita pelo Sen2Cor passa a ser a de melhor desempenho, com  $RMSE = 0.084$  e  $MRE = 40,3\%$ . Uma análise dos dados brutos mostra que os valores negativos foram causados pela subestimação das reflectâncias da banda 5.

Tabela 4 – Comparação estatística entre os diferentes métodos de correção atmosférica.

<b>Correção atmosférica</b>	<b>RMSE</b>	<b>MRE</b>	<b>Número de pontos restantes</b>	<b>RMSE</b>	<b>MRE</b>
<i>Retirando pontos com <math>a_{ph}(665) &lt; 0</math></i>					
<b>Sen2Cor (n=13)</b>	0.1603	84.09%	11	0.0835	40.25%
<b>TOA (n=13)</b>	0.0495	32.15%	13	0.0495	32.15%
<b>ACOLITE (n=13)</b>	0.2952	218.74%	6	0.1038	44.91%
<b>FLAASH (n=13)</b>	0.1026	73.01%	13	0.1026	73.01%

Curiosamente, os valores de  $a_{ph}$  calculados a partir dos dados não corrigidos (topo da atmosfera) foram os que alcançaram os melhores resultados em relação aos valores de campo (RMSE = 0,05 e MRE=32,1%), indicando que mesmo uma correção atmosférica aparentemente bem-sucedida pode não ser adequada para que bons resultados sejam obtidos na aplicação de modelos bio-ópticos. Além disso, uma análise da importância de cada banda para a obtenção de  $a_{ph}(665)$  - em termos de  $R^2$ , para o conjunto de dados de todos os campos- mostra que as bandas 1 e 3 tiveram pouquíssima correlação com o resultado final ( $R^2 = 0,01$  e  $R^2 = 0,015$ , respectivamente), sendo as bandas 4, 5 e 7 as mais relevantes na determinação desse parâmetro ( $R^2 = 0,1$ ,  $R^2=0,29$  e  $R^2 = 0,15$ , respectivamente), indicando que mesmo uma grande discrepância nos valores medidos para as bandas 1 e 3, como a observada para os valores de topo da atmosfera, não é suficiente para prejudicar o resultado final obtido pelo modelo. A figura X mostra

Este resultado está em concordância com os resultados obtidos por Toming et. al (2016), que, usando bandas do vermelho e infravermelho próximo, obteve maior sucesso na estimativa de chl-a com modelos empíricos utilizando dados de topo da atmosfera do sensor MSI. Além disso, Gower et al. (2005) e Matthews et al. (2012) calcularam com sucesso a concentração de chl-a utilizando imagens de topo da atmosfera do *Medium Resolution Imaging Spectrometer* (MERIS). Kutser (2012) e Olmanson et. al (2011) também concluíram que é vantajoso usar imagens Landsat não corrigidas atmosféricamente na estimativa de parâmetros de qualidade de água.

## OBTENÇÃO DE IMAGENS DE CONCENTRAÇÃO DE CHL-A COM UM MODELO SEMI-ANALÍTICO

As imagens não corrigidas foram então escolhidas na confecção dos mapas de concentração de chl-a do Lago Paranoá. Usou-se o modelo de IIMIW/Gitelson ajustado, conforme a equação (11). Com o intuito de ilustrar os padrões de concentração de chl-a em dois momentos climáticos distintos, foram escolhidas imagens do dia 05/05/2017, já no período de seca e do dia 26/12/2016, no período chuvoso.




Figura 5 – Imagens da concentração de chl-a do Lago Paranoá nos dias 26/12/2016 e 05/05/2017

Para a maior parte do lago, foram encontrados valores dentro das faixas de concentração esperadas de 0 a 5 mg/L (Figura 5), no entanto, os valores calculados foram consideravelmente ruidosos nesta faixa, algo que não corresponde com a realidade de campo esperada. Apesar de não ter sido avaliado nesse estudo, especula-se que esse padrão é resultante de ruído na aquisição da imagem pelo sensor MSI.

Comparando os resultados das duas datas, não foi possível observar diferenças significativas entre elas, a distribuição de clorofila-a foi, de forma geral, muito parecida. Algumas feições puderam ser observadas e estão assinaladas na Figura 4. A região “a” é onde as maiores concentrações de chl-a foram observadas, atingindo valores na faixa de 10 mg/L. Esse é um resultado coerente, visto que é a região com maior carga de nutrientes, provenientes de uma Estação de Tratamento de Efluentes e do córrego Riacho Fundo. Nas regiões b e c foram encontrados valores baixíssimos de chl-a. Estas duas regiões são caracterizadas por

apresentarem valores relativamente altos de sólidos em suspensão, que podem ter afetado negativamente a capacidade do IIMIW de aferir a concentração de chl-a, é possível, ainda, que a própria existência dos sedimentos tenha afetado a capacidade da clorofila de se proliferar.

## 4 CONCLUSÕES

---

Por meio deste trabalho foi possível concluir que é possível calibrar empiricamente modelos semi-analíticos como o QAABBHR, o M14 e o IIMIW, assim como modelos empíricos como o 2B e o 3B atingindo valores de  $R^2$  superiores à 85%. Além disso, conclui-se que, utilizando uma abordagem mais direta, sem qualquer calibração, que o algoritmo IIMIW aplicado à eq. (11), proposta por Gitelson et. al (2008), conseguiu alcançar bons resultados na estimativa desse COS, atingindo um RMSE de apenas 4,63  $\mu\text{g/L}$ . No entanto, estes resultados ainda devem ser interpretados com cautela, visto que apesar do IIMIW ter encontrado baixos valores de RMSE, em consonância com a literatura, a concentração média de chl-a do Lago Paranoá é regularmente baixa e, portanto, por essa perspectiva o RMSE pode ser considerado relativamente alto. Este modelo foi também avaliado para valores radiométricos simulados das bandas do sensor MSI, a bordo dos satélites Sentinel-2, neste caso, os resultados foram satisfatórios, mas houve perda na performance do algoritmo, que passou a superestimar os valores encontrados.

A aplicação do IIMIW foi testada, então, a imagens MSI. Para tal, diferentes algoritmos de correção atmosférica foram testados. De forma geral, o Sen2Cor e o FLAASH obtiveram os melhores resultados, conseguindo remover a maior parte dos efeitos atmosféricos. No entanto, ao se avaliar a qualidade da correção atmosférica em termos da sua capacidade de se obter valores de  $a_{\text{ph}}$  com uso do modelo IIMIW, foi constatado que para a situação testada, era melhor utilizar imagens de reflectância do topo da atmosfera, isto é, imagens não corrigidas, na qual houve um erro percentual médio de apenas 32,15%. As imagens obtidas foram coerentes do ponto de vista espacial, apresentando valores altos de clorofila na região esperada, no entanto, a imagem apresentou muito ruído, tendo certa dificuldade em determinar a concentração de chl-a em pontos em que ela possui baixa concentração.

O sensor MSI apresenta grande potencial para o monitoramento de corpos de água interiores, com bandas espectrais relevantes e boas resoluções espaciais e temporais. No entanto, apesar de resultados satisfatórios já poderem ser alcançados com imagens de topo da

atmosfera, para que o monitoramento de chl-a em águas relativamente limpas, como as do Lago Paranoá, possa ser feito com maior precisão, serão necessárias melhorias nos algoritmos de correção atmosférica existentes.

## 5 REFERÊNCIAS

---

- ALIKAS, Krista et al. Robust remote sensing algorithms to derive the diffuse attenuation coefficient for lakes and coastal waters. **Limnology and Oceanography: Methods**, v. 13, n. 8, p. 402-415, 2015.
- APHA - AMERICAN PUBLIC HEALTH ASSOCIATION. **Standard methods for the examination of water and wastewater**. 20. ed. New York: APHA/WWA/WPCR, 1998.
- BUKATA, R. P. (1995). Optical properties and remote sensing of inland and coastal waters. Boca Raton, Fla.: **CRC Press**.
- CHEN, Jiang et al. Remote estimation of colored dissolved organic matter and chlorophyll-a in Lake Huron using Sentinel-2 measurements. **Journal of Applied Remote Sensing**, v. 11, n. 3, p. 036007, 2017.
- ENVI. Atmospheric Correction Module. 2009. "QUAC and FLAASH User's Guide." In Atmospheric Correction Module Version 4.7, 43. Boulder, CO: ITT **Visual Information Solutions**.
- European Space Agency. **Sentinel-2 User Handbook; ESA Standard Document**; ESA: Paris, France, 2015.
- GITELSON, A.A. et al. A simple semi-analytical model for remote estimation of chlorophyll-a in turbid waters: validation. **Remote Sensing of Environment**, v. 112, p. 3582 – 3593, 2008.
- GORDON, H.R. *et al.* Exact Rayleigh scattering calculations for use with the Nimbus-7 Coastal Zone Color Scanner. **Applied Optics**, v. 27, n. 5, p. 862 – 871, 1988.
- GOWER, J. et al. Detection of intense plankton blooms using the 709 nm band of the MERIS imaging spectrometer. **International Journal of Remote Sensing**, v. 26, n. 9, p. 2005-2012, 2005.
- KALLIO, K. et al. Validation of MERIS spectral inversion processors using reflectance, IOP and water quality measurements in boreal lakes. **Remote Sensing of Environment**, v. 157, p. 147-157, 2015.
- KAMPEL, M.; Lorenzetti, J.A.; Bentz, C.M.; Nunes, R.A.; Paranhos, R.; Rudorff, F.M.; Politano, A.T. Simultaneous Measurements of Chlorophyll Concentration by Lidar, Fluorometry, above-Water Radiometry, and Ocean Color MODIS Images in the Southwestern Atlantic. **Sensors**, v. 9, p. 528-541, 2009.
- KUTSER, Tiit. The possibility of using the Landsat image archive for monitoring long time trends in coloured dissolved organic matter concentration in lake waters. **Remote Sensing of Environment**, v. 123, p. 334-338, 2012.
- LE, C. et al. Evaluation of chlorophyll-a remote sensing algorithms for an optically complex estuary. **Remote Sensing of Environment**, v. 129, p. 75 – 89, 2013.
- LEE, ZhongPing et al. An update of the quasi-analytical algorithm (QAA\_v5). **International Ocean Color Group Software Report**, p. 1-9, 2009

- LEE, ZhongPing; CARDER, Kendall L.; ARNONE, Robert A. Deriving inherent optical properties from water color: a multiband quasi-analytical algorithm for optically deep waters. **Applied optics**, v. 41, n. 27, p. 5755-5772, 2002.
- LI, Linhai et al. An inversion model for deriving inherent optical properties of inland waters: Establishment, validation and application. **Remote Sensing of Environment**, v. 135, p. 150-166, 2013.
- LIU, Huizeng 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.
- MAIN-KNORN, Magdalena et al. Calibration and validation plan for the L2a processor and products of the Sentinel-2 mission. **The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 40, n. 7, p. 1249, 2015.
- MARTINS, Vitor Souza et al. Assessment of Atmospheric Correction Methods for Sentinel-2 MSI Images Applied to Amazon Floodplain Lakes. **Remote Sensing**, v. 9, n. 4, p. 322, 2017.
- MATSUSHITA, B. et al. A hybrid algorithm for estimating the chlorophyll-a concentration across different trophic states in Asian inland waters. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 28 – 37, 2015.
- MATTHEWS, M. W., Bernard, S., & Robertson, L. (2012). An algorithm for detecting trophic status (chlorophyll-a), cyanobacterial-dominance, surface scums and floating vegetation in inland and coastal waters. **Remote Sensing of Environment**, 124, 637-652.
- MATTHEWS, Mark William. 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.
- MISHRA, S.; MISHRA, D.R. Normalized difference chlorophyll index: a novel model for remote estimation of chlorophyll-a concentration in turbid productive waters. **Remote Sensing of Environment**, v. 117, p. 394 – 406, 2012.
- MISHRA, Sachidananda; MISHRA, Deepak R.; LEE, ZhongPing. Bio-optical inversion in highly turbid and cyanobacteria-dominated waters. **IEEE Transactions on Geoscience and Remote Sensing**, v. 52, n. 1, p. 375-388, 2014.
- OGASHAWARA, Igor et al. Re-parameterization of a quasi-analytical algorithm for colored dissolved organic matter dominant inland waters. **International Journal of Applied Earth Observation and Geoinformation**, v. 53, p. 128-145, 2016.
- OLMANSON, Leif G.; BREZONIK, Patrick L.; BAUER, Marvin E. Evaluation of medium to low resolution satellite imagery for regional lake water quality assessments. **Water Resources Research**, v. 47, n. 9, 2011.
- PALMER, Stephanie CJ; KUTSER, Tiit; HUNTER, Peter D. Remote sensing of inland waters: Challenges, progress and future directions. **Remote Sensing of Environment**, v. 157, p. 1-8, 2015.
- SIMIS, Stefan GH et al. Influence of phytoplankton pigment composition on remote sensing of cyanobacterial biomass. **Remote Sensing of Environment**, v. 106, n. 4, p. 414-427, 2007.

TOMING, Kaire et al. First experiences in mapping lake water quality parameters with Sentinel-2 MSI imagery. **Remote Sensing**, v. 8, n. 8, p. 640, 2016.

VANHELLEMONT Q. & RUDDICK K. 2016. ACOLITE For Sentinel-2: Aquatic Applications of MSI imagery. Submitted for the proceedings of the 2016 ESA Living Planet Symposium held in Prague, Czech Republic, 9-13 May 2016, **ESA Special Publication SP-740**.

WANG, Menghua. Atmospheric correction for remotely-sensed ocean-colour products. **Reports and Monographs of the International Ocean-Colour Coordinating Group (IOCCG)**, 2010.

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

ZHOU, G., Tang, J., Tian, G., Li, J., & Liu, Q. (2009). Uncertainty analysis of inland water quality remote sensing: A review. **Advances in Earth Science**, 24, 150–158.