

# Efeitos da correção atmosférica em imagens multiespectrais orbitais para estudos em corpos d'água interiores

## Analysis of the effects of atmospheric correction on orbital images for studies in interior water bodies

Gabriella C. Segedi<sup>\*</sup>, Rejane E. Cicerelli<sup>\*</sup>, Tati de Almeida<sup>\*</sup>, Henrique Llacer Roig<sup>\*</sup>, Diogo Olivetti<sup>\*</sup>, Vicente Bernardi<sup>\*\*</sup>,  
Adriana Castreghini<sup>\*\*\*</sup>

<sup>\*</sup> Universidade de Brasília, Instituto de Geociências, Programa de pós-graduação em Geociências Aplicadas e Geodinâmica, Laboratório de Geoprocessamento/GeoLab, e-mails: gabriella.segedi@gmail.com ; rejaneig@unb.br; tati\_almeida@unb.br; roig@unb.br; di\_olivetti@gmail.com

<sup>\*\*</sup> Universidade de Brasília, Faculdade Planaltina, Laboratório de Geoestatística e Geodésia. Email: bernardi.jve@gmail.com

<sup>\*\*\*</sup> Universidade Estadual de Londrina, Departamento de Geociências. Email: adrianacfp@uel.br.

<http://dx.doi.org/10.5380/raega.v58i0.91408>

### Resumo

Os reservatórios hídricos além de serem importantes para a produção de energia elétrica, são recursos para outras necessidades da população. Imagens de sensores orbitais são aplicadas para complementar o monitoramento desses ambientes e assim suprir a deficiência de cobertura espacial e temporal das técnicas tradicionais. No entanto, estudos envolvendo análises de qualidade de água ainda são um grande desafio devido ao baixo sinal proveniente do corpo d'água e a interferência de fatores externos (ou fatores ambientais). Procedimentos de correção das imagens são propostos com frequência, principalmente para a redução da interferência atmosférica. Nesse estudo foram avaliadas as melhores técnicas de correção atmosférica disponíveis no intuito de indicar aquela técnica que mais se aproxima da resposta espectral de sensoriamento remoto obtida em campo (referência). No decorrer do estudo foram aplicados seis algoritmos de correção atmosférica (FLAASH, Second simulation of a Satellite Signal in the Solar Spectrum (6S), L8SR, Aquatic Reflectance (NASA/ USGS), ACOLITE e Sen2Cor) que, a partir das análises estatísticas de análise discriminante e covariância apontaram os aplicativos 6S para imagens Landsat e Sentinel e o ACOLITE para imagens Landsat como os mais acurados. Embora o 6S tenha apresentado resposta próxima dos dados de referência, observou-se baixa variabilidade na resposta espectral. Para séries temporais, o ACOLITE apresentou maior capacidade de correção dos dados. O tipo de aplicação também é um fator preponderante, pois ficou evidente que o uso de séries temporais indicou uma técnica de correção atmosférica diferente quando comparado com a análise das cenas de forma individual.

### Palavras-chave:

Corpos d'água interiores, Correção Atmosférica, Landsat-8, Sentinel-2.

### Abstract

The water reservoirs, in addition to their significance in electricity generation, serve as vital resources for various other requirements of the population. Images from orbital sensors have been

applied to complement the monitoring of these environments and thus overcome the deficiency of spatial and temporal coverage of traditional techniques. However, studies involving water quality are still a great challenge due to the low signal coming from the water body and the interference of external factors (or environmental factors). Image correction/improvement procedures are often proposed, mainly to reduce atmospheric interference. In this study the best available atmospheric correction techniques were evaluated to indicate the technique that most closely matches the spectral response of remotely sensed images obtained in the field. During the study six atmospheric correction algorithms were applied (FLAASH, Second simulation of a Satellite Signal in the Solar Spectrum (6S), L8SR, Aquatic Reflectance (NASA/USGS), ACOLITE and Sen2Cor) that, based on the statistical analysis of discriminant analysis and covariance, indicated the 6S for Landsat and Sentinel images and ACOLITE for Landsat images as the most accurate. Although 6S showed a response close to the reference data, low variability in spectral response was observed. For time series, ACOLITE showed better capacity to correct the data. The type of application is also a preponderant factor, since it was evident that the use of time series indicated a different atmospheric correction technique when compared to the analysis of the scenes individually

**Keywords:**

Inland water bodies; Atmospheric correction; Landsat-8; Sentinel-2.

## I. INTRODUÇÃO

Reservatórios artificiais são reconhecidos como uma forma de obtenção de energia limpa, abastecimento humano, irrigação, aquicultura, piscicultura, recreação, navegação e resfriamento de efluentes industriais, entre outros usos. A manutenção da qualidade da água desses ambientes depende de uma série de fatores de caráter antrópico, tais como, ocupação urbana, agricultura, efluentes domésticos e industriais, vazão, entre outros e natural (clima, declividade, vegetação, entre outros). Torna-se, portanto, essencial o entendimento da dinâmica do reservatório visando garantir a segurança hídrica da região onde o projeto é instalado (GONZÁLEZ-MÁRQUEZ *et al.*, 2018).

Imagens de sensores orbitais vêm sendo aplicadas para complementar o monitoramento desses ambientes e assim suprir a deficiência de cobertura espacial e temporal das técnicas tradicionais. No entanto estudos envolvendo análises de qualidade de água ainda são um grande desafio devido ao baixo sinal proveniente do corpo d'água e à interferência de fatores externos (ou fatores ambientais) que afetam as imagens de diferentes maneiras. Ainda, outros efeitos podem ser adicionados na superfície da água, tais como reflexão especular Steinmetz *et al.* (2011); Harmel *et al.* (2018), mistura espectral por alvos vizinhos (DE KEUKELAERE *et al.*, 2018), entre outros. Questões importantes como as características do sensor, a sensibilidade espectral em cada banda para atingir uma boa relação sinal-ruído e a calibração entre detectores também devem ser modeladas (WARREN *et al.*, 2019; EUGENIO *et al.*, 2020).

De fato, muitos estudos aprimoraram e desenvolveram técnicas de correção das imagens (BERNARDO *et al.*, 2017; WANG *et al.*, 2019; WARREN *et al.* 2019), porém a maioria dos algoritmos para correção atmosférica (CA) foram desenvolvidos para sensores de satélite de média resolução espacial (ou baixa) para oceanos, limitando suas aplicações para águas interiores menores e mais complexas opticamente (MÉLIN, 2022). Em suma, um fator limitante no monitoramento da qualidade da água, ainda hoje, é a correção atmosférica, ou seja, se o método empregado for de má qualidade, quaisquer resultados derivados da refletância da água estão sujeitos a grandes incertezas (WARREN *et al.*, 2019).

Os trabalhos que se preocupam com essa questão desenvolvem soluções para corpos d'água isolados, ou rotinas adaptadas de correção atmosférica. Também existem os casos que manipulam dados em ambientes altamente eutrofizados, nos quais a intensidade do sinal é prioritariamente de Componentes Opticamente Ativos (COA) (BERNARDO *et al.*, 2017; Wang *et al.*, 2019; WARREN *et al.*, 2019). Por exemplo, Eugenio *et al.* (2020) ajustaram um modelo de transferência radiativa para estimar as concentrações de Clorofila-a (Chla) usando imagens multiespectrais (satélite *Worldview*) e hiperespectrais (drones e aéreas). Apesar das correções realizadas, a estimativa da concentração de Chl-a ainda apresentou um Erro Quadrático Médio da Raiz (RMSE) de 3,49, o que pode ser inviável para corpos d'água com estado trófico melhor que mesotróficos. Por isso calibrações e correções precisas são necessárias para levar em consideração a resposta espectral dos sensores, ângulos de visada, geometrias de iluminação solar, efeitos atmosféricos e distúrbios do brilho solar.

Assim, há uma necessidade de amplificar o entendimento das características ópticas de diferentes corpos d'água e eliminar os efeitos de absorção e espalhamento de componentes atmosféricos, tais como moléculas atmosféricas, aerossóis e partículas de nuvens.

Dessa forma, a presente pesquisa prevê avaliar diferentes técnicas de correções atmosféricas em imagens Landsat 8 do sensor OLI e do Sentinel 2 do sensor MSI em um ambiente aquático tropical oligotrófico. Dentre os modelos escolhidos e testados nesse trabalho estão o FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*) (ANDERSON *et al.*, 2002a), o 6S (*Second Simulation of the Satellite Signal in the Solar Spectrum*) (VERMOTE *et al.*, 2016), o ACOLITE (*Atmospheric Correction for OLI 'lite'*) (BERNSTEIN *et al.*, 2005), o Sen2Cor (MAIN-KNORN *et al.*, 2017), o L8SR (*Landsat 8 Surface Reflectance Product*) e o *Aquatic Reflectance* (L8PAR) (OGASHAWARA *et al.*, 2020), cujas respostas espectrais após as correções serão comparadas com dados espectrais obtidos em campo. Por meio de análises estatísticas de agrupamento espera-se compreender os processos de reconstrução do sinal na aplicação da correção atmosférica.

## II. MATERIAIS E MÉTODOS

O Lago Paranoá (Figura 1), criado em 1960 junto com a fundação de Brasília, é cercado por construções e usado para atividades recreativas. Em 2016, o Distrito Federal enfrentou uma crise hídrica devido ao longo período de estiagem que culminou em racionamento de água na cidade devido ao baixo nível das barragens de abastecimento. Isso ressaltou a necessidade de usar a água do Lago Paranoá para o abastecimento público (PASSOS *et al.*, 2020) (Figura 1).

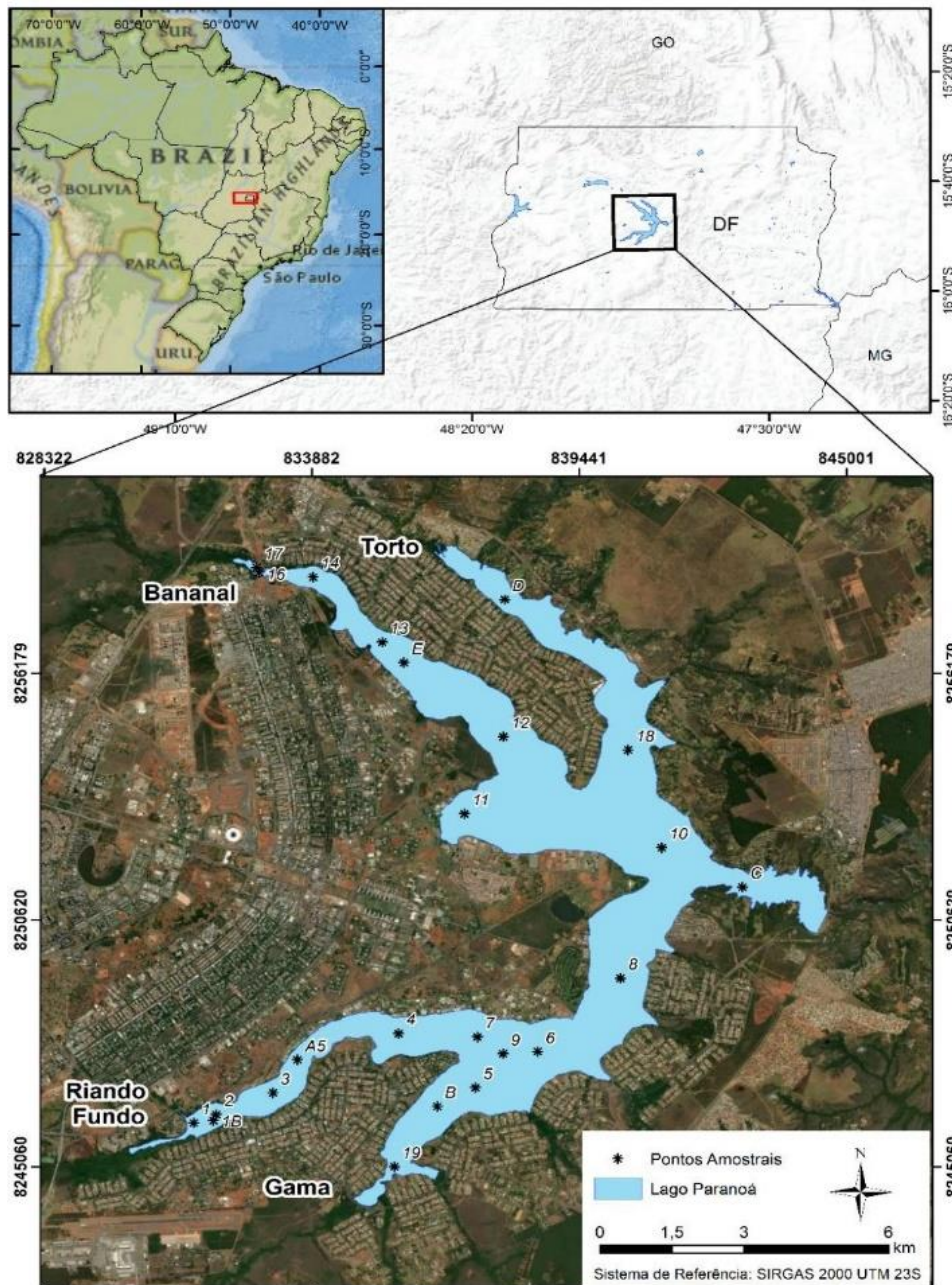


Figura 1 - Localização do Lago Paranoá, Brasília/DF, contendo os campos amostrados planejados (números) realizados em conjunto com a Companhia de Saneamento do Distrito Federal (CAESB). (Os autores, 2023)

Atualmente, o sistema de captação de água para abastecimento público do Lago Paranoá está implementado e em funcionamento e torna-se essencial a constante e periódica vigilância da qualidade da água. O reservatório foi selecionado como estudo de caso pelo fato das estimativas de variáveis limnológicas periódicas indicarem baixas concentrações, o que o caracteriza como um corpo d'água oligotrófico (BATISTA; FONSECA, 2018). Essa característica auxilia no entendimento da aplicação dos algoritmos de correção atmosféricas permitindo analisar a variabilidade das correções no dado de reflectância da água.

### **Aquisição de dados remotos e limnológicos**

Ao todo foram realizadas quatro campanhas de campo (17/08/2020; 04/10/2020; 05/05/2017 e 27/07/2017), ocorridas concomitantemente à passagem dos satélites Landsat 8 e Sentinel-2. Nesses dias foram adquiridas as (i) imagens orbitais, (ii) dados de reflectância de campo e (iii) variáveis limnológicas para avaliação da qualidade da água. A metodologia inicial do estudo era a compreensão do ciclo hidrológico completo, porém, devido a problemas de logística enfrentado com necessidade de manutenção e calibração dos equipamentos durante o desenvolvimento da pesquisa, bem como a pandemia foram realizadas as 4 coletas supracitadas.

As imagens orbitais foram adquiridas pré-processadas nas categorias *Provisional Landsat-8 Surface Reflectance Algorithm* (L8SR) e *L8PAR (Landsat-8 Provisional Aquatic Reflectance Product)* para imagens do Landsat 8 OLI, enquanto para o Sentinel-2 MSI foram obtidos os dados de reflectância do topo da atmosfera (TOA).

Para a aquisição dos dados de Reflectância de Sensoriamento Remoto ( $R_{rs}$ ) de campo, foi utilizado um conjunto de espectrorradiômetros TriOS RAMSES, que têm intervalo de comprimento de onda entre 300nm a 950nm com medições a cada 2,2nm. Os radiômetros foram posicionados considerando a metodologia de radiometria fora da água, para a aquisição dos dados de  $R_{rs}$  da água e podendo ser considerados como verdade de campo para os valores de reflectância obtidos pelas correções atmosféricas que foram aplicadas. A  $R_{rs}$  foi calculada por meio da equação de Mobley (1999).

$$R_{rs} = \frac{L_u - L_d * \rho}{E_d} \quad (1)$$

Sendo,  $L_u$  a radiância ascendente da superfície da água;  $L_d$  a radiância da atmosfera que usada para conseguir corrigir os efeitos de espalhamento e absorção da radiação eletromagnética na coluna de ar;  $E_d$  a irradiância descendente sobre a água de superfície;  $\rho$  um fator proporcional que depende das condições do céu, velocidade do vento, ângulo solar zenital e geometria de visada, e utilizando-se o valor sugerido de 0,028 para as condições de aquisição, foram coletados os dados para a reflectância de sensoriamento remoto ( $R_{rs}$ ).



As medidas das curvas espectrais foram obtidas em um intervalo de, aproximadamente, dois minutos em cada ponto de coleta, sendo gerada uma curva espectral a cada 10 segundos. Assim, o produto da resposta espectral final para cada ponto é a média das curvas espectrais geradas no intervalo de tempo da coleta, permitindo o cálculo da reflectância de superfície individualmente por meio do software MSDA\_XE (*Multi Sensor Data Acquisition System - Extended Edition*) e com o auxílio do *The R Project for Statistical Computing*.

Os dados do espectrorradiômetro RAMSES (TriOS) para estarem concordantes com os intervalos dos comprimentos de onda dos sensores Landsat 8 OLI e Sentinel-2 MSI foram reamostrados fazendo uso da ferramenta *Spectral Resampling* presente no software *Environment for Visualizing Images* (ENVI).

Os dados limnológicos foram coletados por meio da sonda multiparamétrica EXO 2 do fabricante YSI, que fornece informações como condutividade, oxigênio dissolvido (ótico), Sólidos Dissolvidos Totais (TDS), turbidez, potencial hidrogeniônico – pH, e temperatura da água.

### **Algoritmos de Correção Atmosférica**

Ao todo, foram comparados quatro algoritmos de correção atmosférica para os dados Landsat: (i) FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*) (Anderson *et al.*, 2002b), (ii) 6S (*Second Simulation of a Satellite Signal in the Solar Spectrum*) (WANG *et al.*, 2018), (iii) ACOLITE (VANHELLEMONT; RUDDICK, 2015), além das imagens de reflectância (iv) TOA (*Top Of Atmosphere*); (v) L8SR (*Landsat 8 Surface Reflectance Product*) e (vi) *Aquatic Reflectance* (L8PAR) (OGASHAWARA *et al.*, 2020).

Para as imagens Sentinel foram comparados os algoritmos de correção atmosférica: (i) FLAASH (*Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes*) (ANDERSON *et al.*, 2002b), (ii) 6S (*Second Simulation of a Satellite Signal in the Solar Spectrum*) (WANG *et al.*, 2018), (iii) ACOLITE (VANHELLEMONT; RUDDICK, 2015), (iv) Sen2Cor (MAIN-KNORN *et al.*, 2017), além das imagens de reflectância (iv) TOA (*Top Of Atmosphere*)

O algoritmo FLAASH (*Fast Line-of-sight Atmospheric Analysis of Hypercubes*) é baseado no modelo de transferência radioativa. Corrige os comprimentos de ondas da região do visível (380 a 760nm) por meio do infravermelho próximo (760 a 1200nm) e do infravermelho de ondas curtas (1200 a 3000nm) (COOLEY *et al.*, 2002). O 6S (*Second simulation of a Satellite Signal in the Solar Spectrum*) é um aprimoramento no modelo 5S, que considera os efeitos da radiação na atmosfera como um todo, de forma a eliminar os efeitos do espalhamento Rayleigh e dos aerossóis, ampliando as aplicações desse algoritmo. É um dos algoritmos mais utilizados devido às rigorosas validações e elaborados códigos de transferência radiativa (VERMOTE *et al.*, 2016). O algoritmo de correção atmosférica ACOLITE é um processador genérico desenvolvido na RBINS (*Belgian Institute of Natural Sciences*) para correção atmosférica e processamento para aplicações em águas costeiras e

interiores, e realiza a correção utilizando o ajuste de espectro escuro (VANHELLEMONT, 2020). Este foi validado com dados de superfície, principalmente no hemisfério norte (VANHELLEMONT, 2020).

O *Provisional Landsat-8 Surface Reflectance Algorithm* (L8SR) é o produto de reflectância da superfície gerado a partir de um algoritmo de correção atmosférica que foi desenvolvido usando a *Second Simulation of the Satellite Signal in the Solar Spectrum Vectorial* (6SV), refinado para aproveitar as bandas espectrais OLI, com melhor resolução radiométrica e relação sinal/ruído. Além disso, o algoritmo usa a nova banda de aerossol OLI *Coastal* (0,433–0,450  $\mu\text{m}$ ), que é particularmente útil para recuperar as propriedades do aerossol (VERMOTE *et al.*, 2016).

*Aquatic Reflectance* (AR) é um produto fornecido pela USGS (*United States Geological Survey*) na partir do dia primeiro de abril de 2020 e é conhecido por L8PAR (*Landsat 8 Provesional Aquatic Reflectance*). Este produto calcula a refletância aquática que foi dividida por  $\pi$  para o cálculo de  $R_{rs}$ . O produto é baseado no *R<sub>rs</sub> Algorithm Theoretical Basis Document* (ATBD) desenvolvido pelo *Ocean Biology Processing Group* (OBPG) da Agência Espacial Americana (NASA) (OGASHAWARA *et al.*, 2020).

Para corrigir os dados do satélite Sentinel-2 a ESA oferece o Sen2Cor (versão 2.8.0), baseado no modelo ATCOR, que determina os parâmetros a partir de Modelos de Transferência Radiativa calculados sobre o tipo de sensor, geometria solar, topografia do terreno e parâmetros atmosféricos. Mais detalhes sobre o processador SEN2COR e sua calibração podem ser obtidos em Main-Knorn *et al.* (2017).

Para cada processador foi definido o uso da configuração padrão, já que esses costumam ser as melhores opções para análises comparativas de séries temporais em áreas que não se conhece as condições atmosféricas (Tabela 1).

Tabela 1 - Parâmetros similares utilizados durante a aplicação dos algoritmos de correção atmosférica.

Parâmetro utilizado nas correções atmosféricas	Imagens Landsat-8	Imagens sentinel-2
Visibilidade*	20 km	20 km
Modelo Atmosférico	Tropical	Tropical
Modelo Aerossol	Urbano	Urbano
Temperatura	27°C	27°C
Altitude do sensor	705 km	786 km
Tipo do sensor	Multiespectral	Multiespectral

\*Nota: Visibilidade refere-se à distância em que objetos podem ser claramente vistos, frequentemente medida em quilômetros. (Os autores, 2023)

Ressalta-se que anteriormente à aplicação dos algoritmos de correção atmosférica foram retirados valores inválidos de pixel, ou seja, valores com interferência de efeitos como nuvem e sombra de nuvem. Para

tal, foi utilizado o plugin Idepix, inserido no software *Sentinel Applications Platform* (SNAP), que permitiu a identificação de pixels inválidos para os sensores MSI e OLI e a criação da máscara de nuvens para identificação dos valores que poderiam ser usados e quais deveriam ser excluídos.

### **Análises estatísticas aplicadas**

Foram coletados 48 elementos amostrais no Lago Paranoá durante as campanhas de campo e aplicadas 28 correções atmosféricas nas imagens, considerando datas e cenas dos satélites Landsat-8 e Sentinel-2. As relações existentes entre os dados de reflectância obtidos em campo (referência) e os valores de reflectância de superfície advindos dos sensores Landsat 8 OLI e Sentinel-2 MSI, foram analisadas com base em dois métodos estatísticos: Análise Discriminante (CARVALHO *et al.*, 2020) e Análise de covariância.

Foram consideradas como variáveis independentes os dados coletados in situ e as variáveis dependentes as reflectâncias corrigidas. Para obter os valores de reflectância dos pixels nas imagens originais e corrigidas, calculou-se a média em cada banda espectral utilizando uma janela de 3x3, que tinha sobreposição com o ponto de campo.

Primeiramente foi aplicado o teste de Kolmogorov-Smirnov, que consiste em um teste não paramétrico, ideal para aplicação em pequenas amostras, sem restrições excessivas e permite medir o grau de concordância entre a distribuição de um conjunto de dados e uma distribuição teórica específica. Ou seja, permite dizer se as amostras seguem uma distribuição normal ou não. Posteriormente foi realizada uma análise de correlação de Pearson para avaliar a relação linear entre os dados de campo com os orbitais. Analisada a consistência dos dados, foram aplicadas as técnicas de agrupamento.

A análise discriminante (AD) é uma técnica estatística multivariada e faz parte de um modelo estatístico preditivo que tem sido amplamente utilizada para o mapeamento de variáveis ambientais (KRAVCHENKO *et al.*, 2002; NANNI *et al.*, 2004). Esse método estatístico utiliza técnicas de estatística multivariada que permitem separar os objetos de uma única população, reflectâncias obtidas pelas diversas correções atmosféricas, no caso desse estudo, em diferentes classes, por isso a escolha desse método para a avaliação dos resultados obtidos na pesquisa. Além disso, a AD tem sido utilizada para discriminar e classificar objetos ou dados específicos com base na redução da dimensionalidade dos dados de determinada população. Ou seja, a análise discriminante permite determinar uma associação de classe usando uma ou várias funções discriminantes com base em combinações lineares das variáveis, e dessa forma é possível prever a melhor discriminação entre as classes (SAPATINAS, 2005). Alguns estudos voltados para a análise de dados espectrais têm utilizado essa técnica para



classificar a proximidade de dados de reflectância coletados de formas distintas (DUBE *et al.*, 2017; NYAMEKYE *et al.*, 2021).

A análise discriminante foi realizada especificamente para as principais bandas que capturam a resposta espectral da água, que incluem as bandas azul costal, azul, verde, vermelho e infravermelho próximo para os sensores Landsat-8 e Sentinel-2. O objetivo foi evitar que valores discrepantes (*outliers*) tivessem um impacto significativo nos resultados da análise. Logo, a AD foi realizada da seguinte forma: para cada data de campo e sua respectiva imagem obtida através dos sensores OLI e MSI, as análises foram conduzidas separadamente. Os valores dos *endmembers* discriminadores nos dois principais eixos foram então representados em um gráfico. Isso foi feito com o propósito de permitir uma análise futura da acurácia e precisão de cada método avaliado.

Como forma de analisar os padrões de comportamento entre as variáveis dependentes e independentes no intervalo de tempo dos dados coletados, utilizou-se o método de Análise de covariância (ANCOVA). Essa análise foi realizada separadamente para cada tipo de imagem orbital (Landsat-8/OLI e Sentinel-2/MSI) e para cada algoritmo de CA utilizado, considerando todas as datas durante o processamento de cada algoritmo.

Quando se trata de analisar estatisticamente determinado grupo de dados por diversas vezes, há um número expressivo de variáveis e é preciso determinar àquela que será o foco do estudo, ou seja, qual será a variável dependente, que nessa pesquisa se trata dos dados de reflectância obtidos através das correções atmosféricas. As análises foram feitas separadamente, considerando cada algoritmo de correção e cada banda para todas as datas disponíveis. Com base nessas análises foi possível observar quais métodos de correção tiveram diferenças significativas por meio do Teste t de *Student* para identificação das variáveis dependentes significativas ( $Pr < 0,005$ ), mostrando variações para os valores de reflectância ao longo da janela temporal de análise. Dessa forma é possível analisar qual algoritmo de correção e qual banda mostrou resposta mais próxima aos dados de campo coletados *in situ*.

### III. RESULTADOS E DISCUSSÃO

#### Análise dados remotos e limnológicos

A análise das curvas espectrais obtidas em campo com espectrorradiômetro podem ser observadas na Figura 2. Nota-se que as curvas espectrais têm um comportamento similar quando se trata da região do azul (430 a 500nm), ou seja, valores muito baixos no principal intervalo de resposta de corpos aquáticos no espectro eletromagnético. Além disso, outro fator importante é baixa resposta espectral, que fica em torno de 1%, ou seja, um desafio para o processo de correção dos efeitos atmosféricos em relação a esses estudos.

Além das características intrínsecas citadas, é possível notar que o campo do dia 04/10/2020 mostra valores mais elevados de reflectância, atingindo picos de 0,016 (1,6%) na região do verde (550 a 560nm) enquanto os demais campos atingiram picos de no máximo 1,4% também na região do verde. As curvas espectrais de todos os levantamentos mostram uma região de reflectância máxima no verde entre 550 e 570nm, ocasionada pela presença da clorofila-a (Chl-a). As curvas também apresentaram uma feição de absorção no vermelho, 671nm, e pico de reflectância no infravermelho próximo (700nm), associado à presença da clorofila-a. Também se percebe a ocorrência de outro pico pouco representativo em 750nm, que pode ser atribuído à somatória do espalhamento por células do fitoplâncton e por TSS (KIRK, 1994; DEKKER; PETERS, 1993).

Nesse caso, pode-se dizer que apesar de baixas concentrações, há um padrão das curvas espectrais apresentarem um comportamento tênue representando a presença de Chl-a (BINDING *et al.*, 2020; MACIEL *et al.*, 2019).

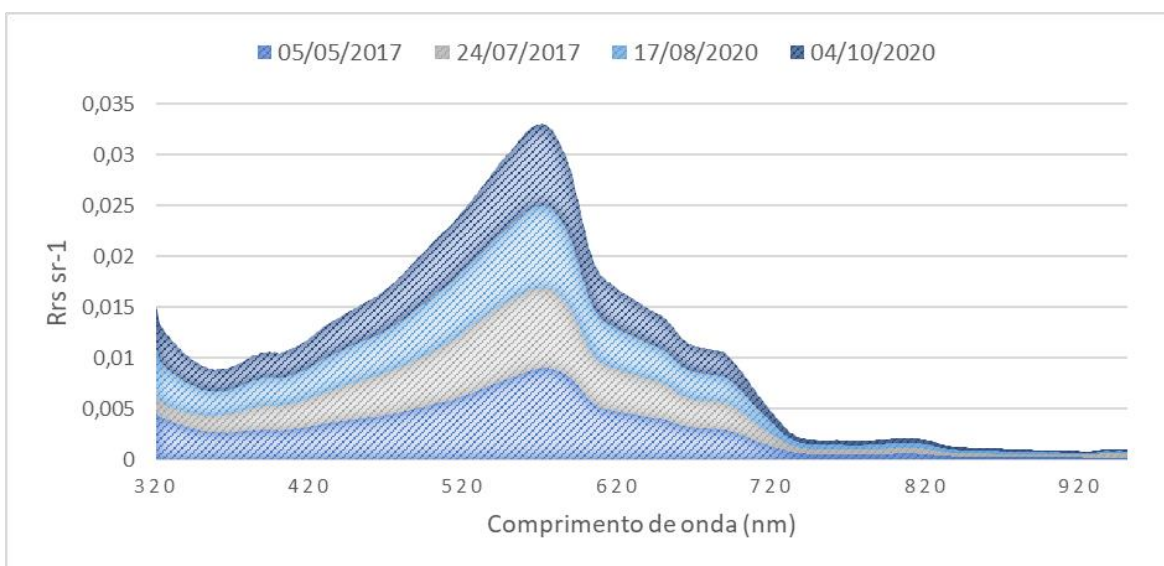


Figura 2 – Curvas espectrais obtidas durante as campanhas de campo realizadas. (Os autores, 2023)

Conforme exemplifica a Figura 2 a média das curvas de campo reamostradas, fica evidente que as assinaturas espectrais têm um aspecto ascendente da região do azul (430 a 500nm) para a região do verde (550 a 560nm) e tendendo a cair em sequência, com valores mais baixos na região do vermelho (650 a 660nm) e do infravermelho próximo (860 a 870nm). Feições características da presença da Chl-a, tais como a feição de absorção em 670nm, ou a de reflexão em 700nm são ocultadas no processo de generalização realizado pela reamostragem.

Com relação as imagens orbitais, observou-se que a imagem Landsat 8 OLI de 04/10/2020 apresentou valores maximizados de reflectância, que se devem pelo efeito da reflexão especular. Apesar disso, a imagem

foi mantida na análise no intuito de observar os efeitos ocasionados na cena por meio da análise de agrupamento. As demais imagens apresentaram padrão de resposta similar aos dados de campo.

Quanto aos dados de campo, durante as campanhas de campo realizadas as condições meteorológicas eram favoráveis, com poucas nuvens e condições de vento abaixo do limite, exceto para a data de 04/10/2020. Nesse dia houve ventos mais fortes, ondulando a superfície da água, de modo que na imagem orbital do Satélite Landsat-8 fosse visível o efeito de reflexão especular na imagem.

Table 2 - Summary of physical, chemical, and biological limnological variables collected in Lake Paranoá during the field campaigns of the study.

Data	Estatística descritiva	Chl-a (mg/l)	pH	Turbidez (NTU)	Temperatura (°C)
05/05/2017	Média	5,25	N/A	N/A	N/A
	Mínima	4,29	N/A	N/A	N/A
	Máxima	12,01	N/A	N/A	N/A
	DP*	2,10	N/A	N/A	N/A
24/07/2017	Média	4,68	N/A	N/A	N/A
	Mínima	1,09	N/A	N/A	N/A
	Máxima	10,38	N/A	N/A	N/A
	DP*	2,89	N/A	N/A	N/A
17/08/2020	Média	3,18	5,26	57,67	27,66
	Mínima	0,95	5,15	2,34	27,44
	Máxima	9,54	5,39	121,51	27,92
	DP*	1,91	0,08	44,56	0,17
04/10/2020	Média	6,07	7,42	42,32	26,58
	Mínima	0,00	6,95	37,60	25,30
	Máxima	16,12	7,80	56,00	29,20
	DP*	4,73	0,27	5,54	0,96

\*Note: DP: Desvio padrão. (Os autores, 2023)

### Correlação de Pearson dos dados de campo com as imagens corrigidas

Para avaliar a similaridade entre os dados de campo e das imagens corrigidas, uma das primeiras análises é a correlação simples. Percebe-se que a banda no NIR em todos os casos apresenta menor relação com os dados de campo pelo fato da resposta de campo nessa região ser próxima do nulo. A banda do azul, em ambos os sensores apresentou correlação baixa em função da alta interferência atmosférica sofrida nessa região espectral. Para as bandas verde e vermelho os valores tendem a ser muito correlacionados (Tabela 3).

Para ambos os sensores a correção atmosférica utilizando o 6S apresentou menor correlação com os dados de campo. O sensor Sentinel MSI teve uma correlação inferior das alcançadas pelo sensor Landsat 8 OLI.

Tabela 3 - Correlação linear de Pearson entre as  $R_{rs}$  coletadas in situ e as reflectâncias obtidas através da correção atmosférica e correção de *sunlint* para cada banda do Landsat8/OLI e Sentinel 2 MSI.

Sensor	Banda	FLAASH	6S	ACOLITE
OLI	Azul Costal	-0,44	-0,56	-0,72
	B	-0,11	-0,2	-0,35
	G	0,69	0,63	0,72
	R	0,86	0,48	0,94
	NIR	0,08	-0,15	0,13
Sentinel	B	-0,81	-0,82	-0,82
	G	0,28	0,24	0,29
	R	0,25	0,09	0,23
	RedEd1	0,36	0,33	0,33
	RedEd2	0,41	0,28	0,36
	RedEd3	0,43	0,5	0,38
	NIR	0,17	0,36	0,16

(Os autores, 2023)

### Análise Discriminante da $R_{rs}$

A análise discriminante canônica é uma boa ferramenta para identificar a relação de precisão e acurácia dos algoritmos de correção atmosférica. A diferença de aplicação da AD para uma análise de principal componente (PCA) é que na PCA as variáveis são reescritas como combinações lineares, no qual cada componente descreve uma porção da variabilidade presente nas variáveis originais. A AD, por sua vez, discrimina as amostras com base em membros já identificados e utilizados para estimar pesos de uma função discriminante.

E quando observamos a motivação da aplicação da AD, subentende-se que temos como objetivo da análise: 1) Redução de dimensionalidade para simplificação do problema e 2) Melhorar a capacidade de discriminação entre as classes, que nesse caso, são os diferentes algoritmos de correção atmosférica testados. As correlações canônicas têm como princípio básico desenvolver uma combinação linear em cada um dos conjuntos de variáveis (dependentes e independentes) tal que a correlação entre os dois conjuntos seja maximizada, ou seja, indica a qualidade da discriminação de determinado conjunto de dados com base nos eixos discriminantes criados ( $F_n$ ).

De acordo com as correlações canônicas obtidas pelos eixos discriminantes verificou-se que na totalidade de datas de campo, considerando os algoritmos de correção atmosférica aplicados para as imagens orbitais de cada sensor e os eixos discriminantes propostos, os dois principais eixos  $F_1$  e  $F_2$  representaram, no mínimo, 97% da totalidade de informações, ou seja, uma boa qualidade de discriminação dos dados com uma

baixa mistura de pontos. A partir do momento em que é feita a redução da dimensionalidade dos dados e esses são discriminados em classes é possível realizar certas inferências conforme vamos comentar com base na Figura 3 (Landsat-8 OLI) e Figura 4 (Sentinel-2/MSI).

Para a análise da Figura 3 considerou-se a proximidade entre dados de reflectância de superfície orbitais aplicadas as técnicas de correção atmosférica e os dados de campo reamostrados (similaridade de quadrante e proximidade dos vetores). Em relação a precisão na Figura 3, nota-se que os dados de reflectância corrigidos com o 6S apresentaram maior proximidade com os dados de campo, contudo observou-se uma certa homogeneidade no padrão da dispersão dos dados, quando comparados com os dados do campo. O ACOLITE aparentemente apresentou padrão similar quanto à proximidade dos dados de campo, porém destaca-se a manutenção da variabilidade na resposta espectral. O FLAASH, na maioria dos campos também apresentou um padrão similar, porém com comportamento um pouco distinto dos dados de campo. As imagens obtidas em 24/07/2017 e 04/10/2020 foram as que mais se aproximaram aos dados de reflectância de campo após o processo de correção atmosférica utilizando as técnicas empregadas pelo ACOLITE (ACL) e 6S.

O 6S apresentou para a todos os campos contribuições semelhantes com os dados nos dois eixos aos dados localizados prioritariamente no quarto quadrante, cujas contribuições nos eixos  $F_1$  e  $F_2$  foram negativas, exceto para o campo de 24/07/2017. Quanto aos dados do FLAASH também tiveram um comportamento similar apesar de mais distantes.

Os dados do TOA mostraram-se pouco relacionados aos dados de campo, no entanto do eixo 1 explica grande parte a variabilidade do dado. Os dados de *Aquatic Reflectance* (AR) apresentaram alta dispersão no grupo, não havendo um padrão de entre as imagens (24/07/17; 17/08/2020; 04/10/2020), ou seja, entre os eixos analisados. Assim, sugere-se que a correção realizada não foi capaz de melhorar a qualidade dos valores de reflectância da água. O estudo de Ogashawara *et al.* (2020) mostrou uma relação ruim com o  $R_{rs}$  in situ de seis lagos alemães turvos/eutróficos. Os autores relatam que o principal problema do L8PAR foi a estimativa de valores negativos para reflectância aquática em águas interiores.

Para os dados de *Provisional Landsat-8 Surface Reflectance Algorithm* (L8SR), também não se mostrou um dado acurado aos dados de campo, além disso não houve um padrão na distribuição entre os eixos, o que pode indicar padrão de informações distintas entre as imagens adquiridas e não coincidentes com o dado de campo.

O algoritmo 6S (*Second Simulation of a Satellite Signal in the Solar Spectrum*) é um dos códigos que simula a transferência radiativa e é um dos mais utilizados, com uma vasta quantidade de dados e validações já



publicados ao longo dos anos (VERMOTE *et al.*, 2016; EUGENIO *et al.*, 2017; YANG *et al.*, 2022; ROGER *et al.*, 2022). No entanto, segundo Pisanti *et al.* (2022) ele não é capaz de separar e filtrar adequadamente a reflexão que de fato é proveniente do alvo. Essa característica para aplicação em ambientes aquáticos precisa ser considerada já que esses ambientes não apresentam grande variação espacial da  $R_{rs}$  como em ambientes terrestres, podendo ocasionar em uma remoção dos efeitos atmosféricos mas também da própria resposta da água quando aplicado, portanto, é imprescindível que os parâmetros como: visibilidade, data e hora de aquisição e informações de angulação do sensor sejam parametrizadas, pois assim a abordagem física é mais precisa que a imagem puramente abordada (PISANTI *et al.*, 2022). Tal percepção também pode ser indicada na presente pesquisa, haja vista que a AD indicou dados com baixa variabilidade após a aplicação dessa técnica de correção.

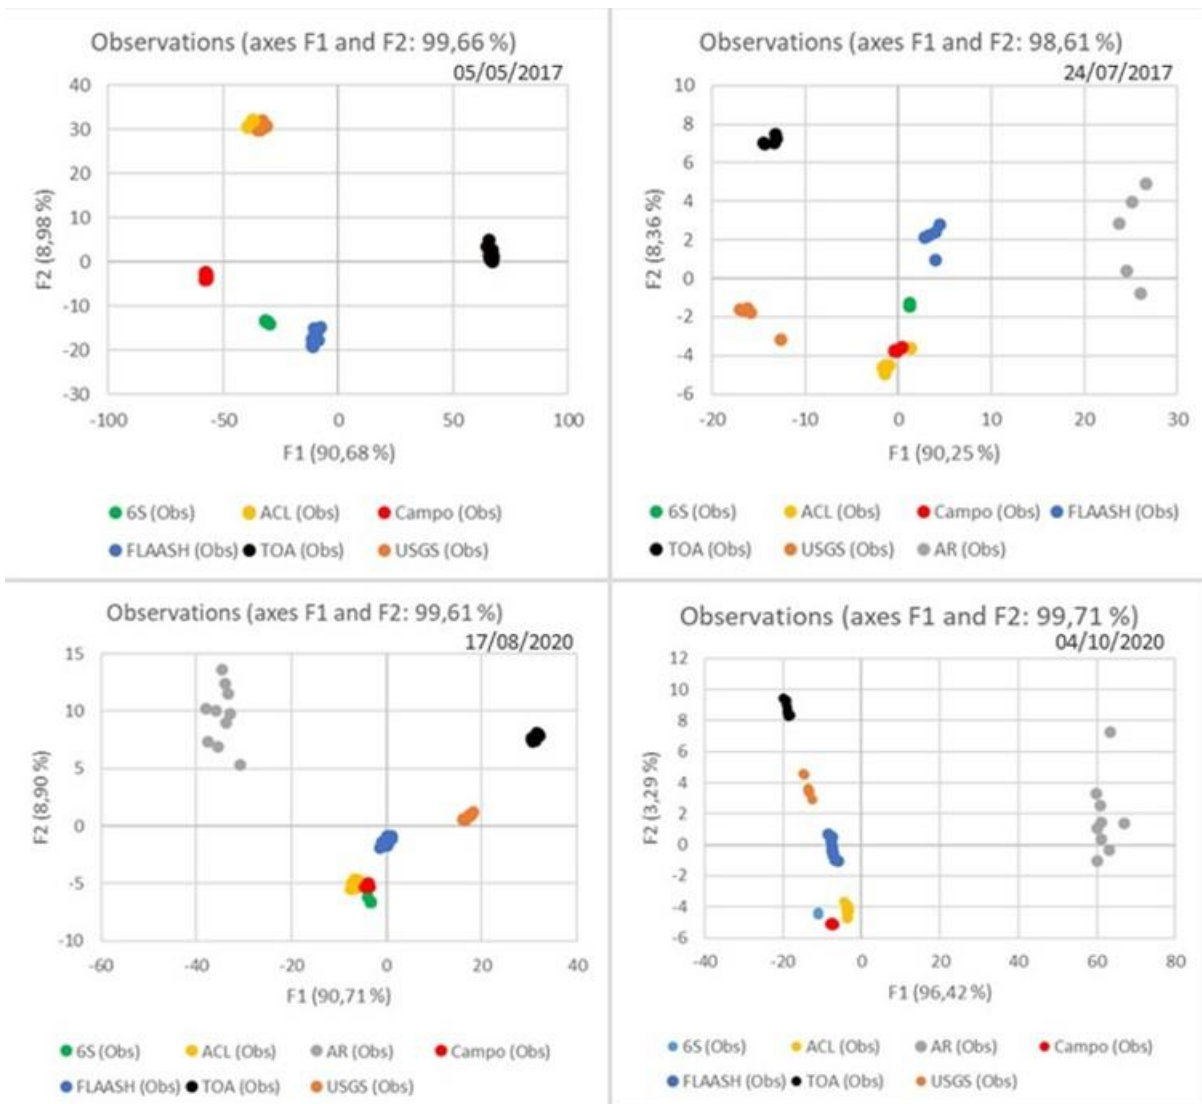


Figura 3 - Correlação das classes obtidas por meio da Análise Discriminante correlacionando os dados entre os principais eixos discriminantes (F1 e F2) para os algoritmos aplicados em imagens provenientes do Landsat-8/OLI nas respectivas datas de campo. AR: *Aquatic reflectance*; ACL: *ACOLITE*. (Os autores, 2023)

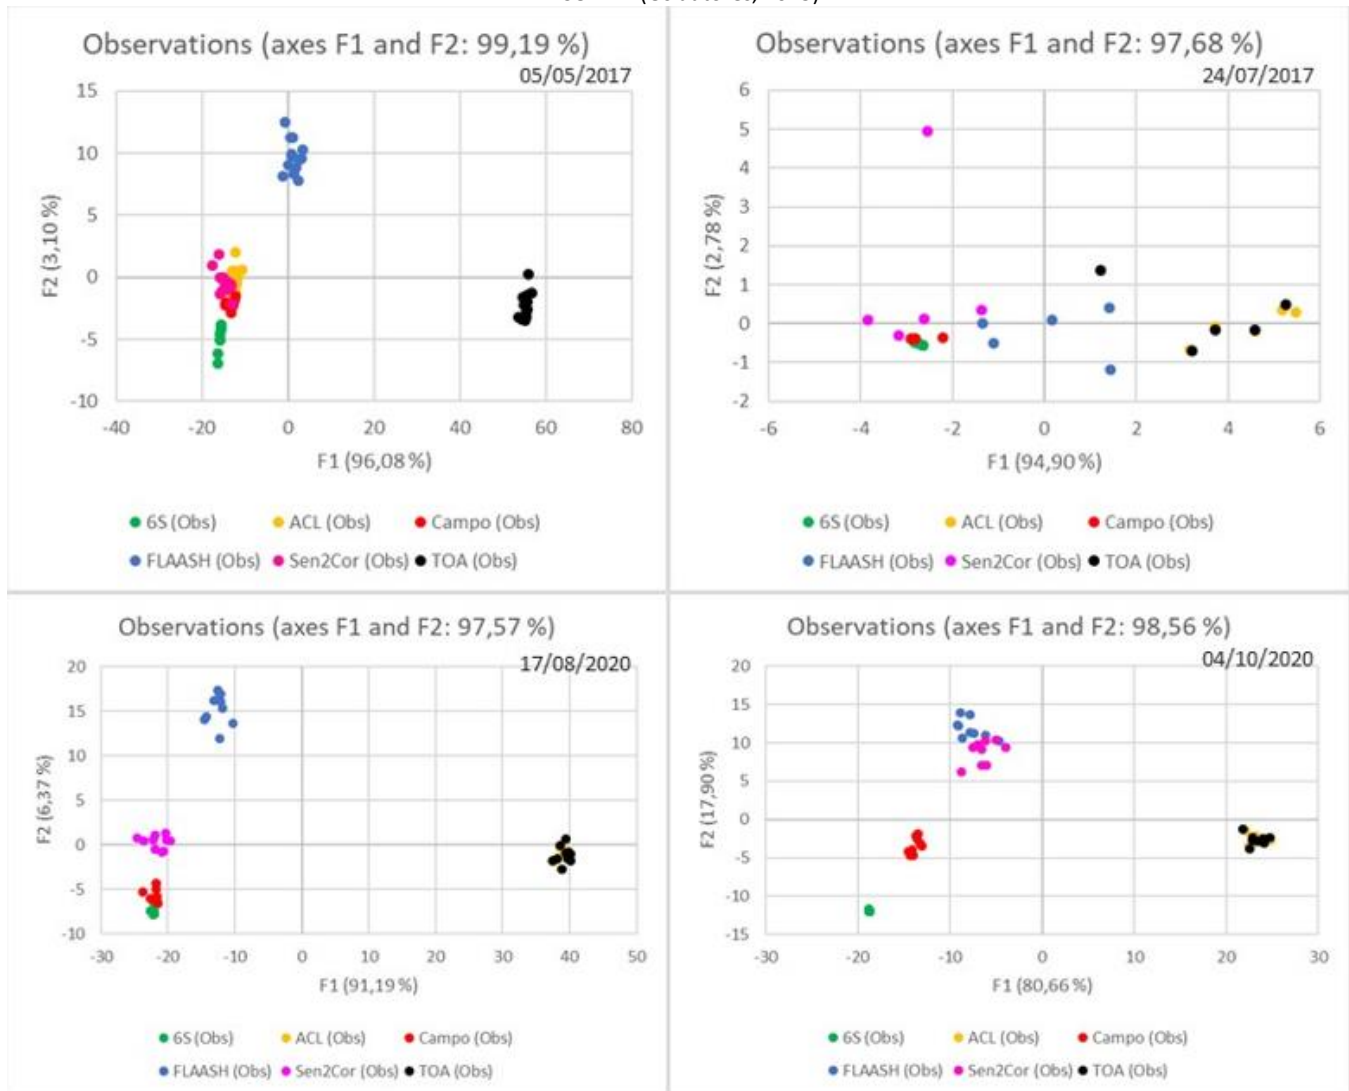


Figura 4 - Correlação das classes obtidas por meio da Análise Discriminante correlacionando os dados entre os principais eixos discriminantes (F1 e F2) para os algoritmos aplicados em imagens provenientes do Sentinel-2/MSI nas respectivas datas de campo. (Os autores, 2023)

O ACOLITE também mostrou resultados significativos e vem sendo amplamente abordado em aplicações nos corpos d'água (MACIEL; PEDOCCHI, 2022; CABALLERO *et al.*, 2022). Esse algoritmo tem o ajuste de pixel escuro (DSF) que foi originalmente desenvolvido para aplicações em corpos aquáticos com altas resoluções espaciais, mas mostrou alto potencial para imagens Landsat-8 e Sentinel- 2, principalmente por esses terem a banda do SWIR. Essa banda tem a resposta praticamente nula de  $R_{rs}$ , o que permite um bom desempenho caso essa região não seja afetada por efeitos adjacentes, como por exemplo, o sunglint que é corrigido justamente fazendo a subtração da banda SWIR.

Ainda assim, é importante salientar que o algoritmo de CA ACOLITE, utiliza a razão entre bandas R/NIR para corrigir a reflectância da água, o que pode tornar sua aplicabilidade limitada para corpos aquáticos com altas concentrações de Clorofila-a que afetam a absorção nas regiões do vermelho e infravermelho próximo (VANHELLEMONT, 2019; VANHELLEMONT, 2020). Ou seja, caso o Lago Paranoá não tivesse tipicamente baixas concentrações de COAs a resposta do algoritmo deveria ser reavaliada para o entendimento do limite de detecção da concentração de Clorofila-a. Apesar do exposto, Ogashawara *et al.* (2020) também obtiveram bons resultados para um ambiente túrbido e eutrofizado.

A Figura 4 nos mostra as classes discriminadas com base nos algoritmos de correção atmosférica aplicados às imagens orbitais obtidas através do Sentinel-2/MSI. À primeira vista nota-se que as classes obtidas por AD nas imagens do sensor MSI corrigidas atmosféricamente não foram tão bem discriminadas quanto para as imagens orbitais do sensor OLI.

A precisão e acurácia das classes para esse sensor (Sentinel-2/MSI) em específico também mostraram um resultado inferior quando comparado ao observado na Figura 4. Exceto para o algoritmo 6S (*Second Simulation of a Satellite Signal in the Solar Spectrum*) que ainda assim se mostrou mais acurado em relação aos demais, mesmo considerando o algoritmo Sen2Cor desenvolvido pela mesma empresa que colocou em órbita o satélite Sentinel-2/MSI, a *European Space Agency* (ESA) (ABDELAL *et al.*, 2022). Destaca-se, contudo, que o 6S mostra uma tendência de homogeneidade dos dados de reflectância obtidos, o que é evidenciado, quando se compara com o comportamento dos pontos representados dos valores de reflectância de campo.

Para os valores de reflectância advindos da correção atmosférica pelo ACOLITE observou-se um comportamento variável entre as cenas e distante do valor de campo. Destaca-se também que a imagem do campo de 24/07/2017 apresentou um padrão distinto dos demais, com dados espaçados e sem agrupamento, com exceção dos dados de campo e os advindos do processamento em 6S. Os dados de TOA se assemelharam muito com os dados do ACOLITE para os campos de 17/08/2020 e 04/10/2020, exceto para o campo de 05/05/2017 mostrando também dificuldades no processo de correção atmosférica.

O FLAASH não apresentou o mesmo desempenho, quando comparado às imagens Landsat 8, devendo ser utilizado com cautela pelos usuários para correção atmosférica em imagens Sentinel-2/MSI.

É importante ressaltar que os processos de correção atmosférica seguiram as configurações padrão oferecidas pelo software, sendo que o processo de calibração pode evidenciar comportamentos distintos no processo de correção. Vanhellefont (2019), por exemplo relatam que usando uma versão atualizada do processador ACOLITE e a aplicação de um filtro de média móvel nas bandas SWIR, usadas para correção de

aerossóis, pode auxiliar na melhora da qualidade dos resultados alcançados. Pereira-Sandoval *et al.* (2019) relatam que, para as técnicas testadas, apesar da melhoria na qualidade no processo de correção atmosférica, observou-se em dados Sentinel-2/MSI melhor desempenho quando aplicados em águas meso e hipereutróficas, em comparação com oligotróficos, caso do ambiente estudado no presente trabalho. O mesmo autor também relata que outras considerações devem ser contabilizadas, como a elevação dos lagos acima do nível do mar, sua distância do mar e sua morfologia, questões essas não consideradas na configuração inicial dos aplicativos analisados.

Por fim, deve ser feita uma reflexão sobre o efeito de reflexão especular (*sunlint*) nas imagens. O termo *sunlint* ou *Sun glitter* é usado para denominar a condição geométrica específica de aquisição de imagens que ocorre de modo especular entre o alvo e o sensor remoto, quando para um pixel ou uma região da superfície da água, a luz solar é diretamente refletida na direção de visada do satélite, sem o contato volumétrico do alvo.

A imagens adquiridas em 04/10/2020 (Landsat OLI 8) e de 24/07/2017 (Sentinel MSI), apresentaram um padrão de resposta relacionada à reflexão especular, o que provavelmente reduziu a efetividade das técnicas de correção atmosférica. Técnicas de correção de reflexão especular como as desenvolvidas por Maciel *et al.* (2019) e Harmel *et al.* (2018) devem ser testadas antes da aplicação das técnicas de correção atmosférica na tentativa de extração de informações úteis em imagens prejudicadas por essa característica. Assim, sugere-se estudos adicionais e complementares nessa vertente.

### **Análise de covariância da $R_{rs}$**

A análise de covariância foi aplicada com o intuito de analisar no intervalo temporal qual técnica de correção atmosférica pode ser considerada pertencente ao grupo de curvas de reflectância obtidas em campo (referência). Ou seja, qual técnica de correção atmosférica foi capaz de incorporar correções a ponto de se enquadrar no mesmo grupo dos dados de referência.

Conforme citado, essa análise foi realizada separadamente para cada tipo de imagem orbital (Landsat-8/OLI e Sentinel-2/MSI) e para cada algoritmo de CA utilizado, mas considerando todas as datas durante o processamento de cada algoritmo.

Como a variação no tempo agora é considerada em virtude do agrupamento de todas as datas analisadas em uma única série e dados, é importante garantir que os dados de  $R_{rs}$  coletados in situ (variável independente) mostrem uma variação não significativa, indicando uma metodologia assertiva para a coleta das informações, enquanto os dados de  $R_{rs}$  obtidos por correção atmosférica devem mostrar valores significativos para indicar se há detecção de variação da informação na janela temporal. Essas análises foram obtidas por meio do teste t e

os resultados desse processamento estão descritos na Tabela 4. Vale ressaltar que para os dados obtidos através do produto L8PAR não foram considerados para a análise temporal pois apresentaram valores não significativos devido à sua alta variabilidade.

Tabela 4 - Valores do Teste t de Student para identificação das variáveis dependentes significativas ( $Pr < 0,005$ ), considerando aplicações das correções em imagens Landsat-8/OLI.

Algoritmos de CA	FLAASH	Test $Pr >  t $		
		6S	L8SR	ACOLITE
Azul Costal	0,715	0	0,421	0
B	0,78	0,183	0,534	0
G	0,464	0,186	0,853	0
R	0,09	0,126	0,454	0
NIR	0,63	0	0,618	0,055

(Os autores, 2023).

Considerando que todos os valores de campo para o algoritmo de CA e para a banda em questão as variáveis de campo não obtiveram mudanças significativas, podemos considerar que a coleta de dados foi realizada com base em um mesmo padrão e pode ser utilizada como referência.

Para os processamentos aplicados às imagens do Landsat-8/OLI nota-se que o ACOLITE obteve um melhor resultado, pois considerando a janela temporal com as datas de campo realizadas durante essa pesquisa, o algoritmo mostrou variação significativa para as respostas espectrais nas bandas do Azul Costal, Azul, Verde, Vermelho e ficou muito próximo na região do infravermelho próximo (NIR) (Tabela 4). Similar aos resultados observados por Maciel; Pedocchi (2022) e Caballero *et al.* (2022). O algoritmo 6SV foi o segundo com valores significativos para algumas bandas.

Essa análise pode indicar que apesar das variações atmosféricas observadas nas diferentes datas de coleta, o ACOLITE foi capaz de manter a proximidade com os dados de campo na maior parte dos dados, mesmo com imagens diferentes. Assim, o processo de correção atmosférica foi capaz de manter a estabilidade na correção atmosférica, seguindo a tendência de variância dos dados de campo em todos os campos analisados (homogeneidade das inclinações de regressão). Tal constatação, contudo não é capaz de indicar se há semelhança quantitativa, sendo indicado apenas na técnica de análise discriminante. Ou seja, o resultado reforça que o ACOLITE pode ser uma boa alternativa para manipulação dos dados adquiridos em imagens diferentes adquiridas pelo satélite Landsat 8 OLI.

Em seguida, podemos observar a mesma análise considerando a janela temporal como variável aplicada para as imagens orbitais provenientes do Sentinel-2/MSI e corrigidas atmosféricamente com base nos seguintes processamentos (Tabela 5).



Tabela 5 - Valores do Teste t para identificação das variáveis dependentes significativas ( $Pr < 0,005$ ), considerando aplicações das correções em imagens Sentinel-2/MSI.

Algoritmos	Test $Pr >  t $			
	CA	FLAASH	6S	ACOLITE
B	-0,81	-0,82	-0,82	-0,82
G	0,28	0,24	0,29	0,29
R	0,25	0,09	0,23	0,23
RedEd1	0,36	0,33	0,33	0,33
RedEd2	0,41	0,28	0,36	0,36
RedEd3	0,43	0,5	0,38	0,38
NIR	0,17	0,36	0,16	0,16

(Os autores, 2023).

Assim como ocorreu nas análises realizadas para as imagens Landsat-8/OLI, para as imagens provenientes do Sentinel-2/MSI os dados de campo apresentaram valores não significativos ( $Pr > 0,005$ ), exceto para o algoritmo de CA ACOLITE, ou seja, em relação àquele processamento e àquela banda em específico do sensor, os dados de campo seguiram um padrão e podem ser utilizados de base como dados de referência para os demais métodos de correção atmosférica.

O ACOLITE é um método semiempírico que assume algumas condições para ser aplicado na estimativa da carga óptica dos aerossóis, sendo essas menos complexas do que as adotadas pelo FLAASH e 6S, por exemplo, são modelos de transferência radiativa (modelos físicos) e a parametrização é mais complexa, trazendo mais dados de entrada para caracterização da atmosfera (YANG *et al.*, 2022).

Considerando os números observados na Tabela 5 nota-se que os valores mais significativos na quase totalidade das bandas analisadas, os valores de  $R_{rs}$  obtidos através da aplicação do modelo 6S. Mostrando que esse modelo possui variações, na janela temporal analisada, de forma significativa, para praticamente todas as bandas estudadas.

Tendo em vista os resultados observados, tanto para acurácia e precisão dos dados em relação aos  $R_{rs}$  in situ, utilizados como referência, quanto para variação do dado de  $R_{rs}$  em determinada janela temporal os algoritmos 6S e ACOLITE mostraram melhores respostas. Dependendo das condições físicas e químicas do corpo d'água alvo os algoritmos 6s e ACOLITE vêm mostrando boas respostas (VANHELLEMONT, 2019; MACIEL; PEDOCCHI, 2022; CABALLERO *et al.*, 2022; YANG *et al.*, 2022).

E de acordo com Yang *et al.* (2022) que faz um retrospecto da evolução do sensoriamento para análises de qualidade da água, os métodos físicos têm algumas vantagens em relação ao método empírico (grande incerteza nos dados) e semiempírico (necessita de grande quantidade de pontos amostrados), pois esse não

requer muitos pontos de amostragem em campo, e tendo um equipamento de aquisição de dado calibrado, há boas respostas com alta aplicabilidade.

#### IV. CONCLUSÕES

Após a aplicação da metodologia ficou evidente que as técnicas de correção atmosférica, em suas configurações padrão são capazes de aproximar os valores de reflectância orbitais dos satélites Landsat 8 OLI e Sentinel-2 MSI dos valores de reflectância de campo (referência), mesmo em ambientes aquáticos oligotróficos.

Para as imagens Landsat-8/OLI o modelo de correção 6S apresentou tanto acurácia quanto precisão melhores em relação aos demais modelos, acompanhado pela correção proporcionada pelo ACOLITE. Os resultados precisam ser analisados com cautela pois em princípio o modelo 6S além de extrair a informação da atmosfera também reduziu a variabilidade espectral natural do corpo d'água. Nesse caso, entende-se que o ACOLITE apesar de menos assertivo garantiu a manutenção da variabilidade espectral.

Em imagens Sentinel-2/MSI observou-se a priori que as classes obtidas por AD corrigidas atmosféricamente não foram tão bem discriminadas quanto para as imagens orbitais do sensor OLI. O 6S proporcionou respostas muito similares às obtidas nas correções das imagens Landsat, com o mesmo padrão de homogeneizar os dados de reflectância. Enquanto o Acolite não foi capaz de garantir semelhança com os dados de campo, apenas para a imagem de 05/05/2017. Destaca-se o Sen2Cor, técnica desenvolvida pela própria ESA, garantiu bons resultados quanto à precisão e à acurácia, sendo indicado para esse tipo de correção.

As imagens adquiridas em 04/10/2020 (Landsat 8/OLI) e de 24/07/2017 (Sentinel-2/MSI), apresentaram um padrão de resposta relacionada à reflexão especular, o que provavelmente reduziu a efetividade das técnicas de correção atmosférica. Técnicas específicas de correção desse efeito devem ser testadas na tentativa de extração de informações úteis em imagens prejudicadas por essa característica. Assim, sugere-se estudos adicionais e complementares nessa vertente.

Com relação a análise temporal, o ACOLITE destacou-se novamente para imagens Landsat-8/OLI, seguido pelo 6S indicando bandas com resposta mais próxima aos dados de campo coletados in situ. O FLAASH também apresentou bom desempenho ao garantir variáveis dependentes significativas para algumas bandas no visível. O Sen2Cor apresentou uma resposta atípica, que pode indicar especificidades nas correções individuais por imagem. Reforça-se a necessidade de estudos adicionais, principalmente para a realização de análises por séries temporais, além da aquisição de maior número de elementos amostrais de campo em épocas distintas.

## Agradecimentos

Este trabalho foi apoiado pela Fundação de Apoio à Pesquisa do Distrito Federal – FAP-DF (n° 00193.00001143/2021-15 e 00193-00000286/2023-71) por meio dos projetos "Dinâmica da Qualidade da Água nos reservatórios do Distrito Federal (DF) por meio de imagens obtidas por RPAs e por plataformas orbitais" e "Dinâmica do uso e cobertura do solo em bacias hidrográficas por meio de imagens de sensoriamento remoto e seu impacto na qualidade da água dos reservatórios de abastecimento público do DF", e pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) que concedeu a bolsa de pós-graduação.

## V. REFERÊNCIAS

- ABDELAL, Q.; ASSAF, M. N.; AL-RAWABDEH, A.; ARABASI, S.; RAWASHDEH, N. A. Assessment of Sentinel-2 and Landsat-8 OLI for Small-Scale Inland Water Quality Modeling and Monitoring Based on Handheld Hyperspectral Ground Truthing. *Journal of Sensors*, v. 2022, p. 1–19, 2022.
- ANDERSON, G. P.; FELDE, G. W.; HOKE, M. L.; RATKOWSKI, A. J.; COOLEY, T. W.; CHETWYND J. R.; JH, ... & LEWIS. Algoritmo de correção atmosférica baseado em MODTRAN4: FLAASH (análise atmosférica de linha de visão rápida de hipercubos espectrais). In: *Algoritmos e tecnologias para imagens multiespectrais, hiperespectrais e ultraspectrais VIII*. SPIE, 2002. p. 65-71.
- BARBOSA, C. C.; GOMES, L. N. L.; MINOTI, R. T. A modelling approach to simulate Chlorophyta and Cyanobacteria biomasses based on historical data of a Brazilian urban reservoir. *Ambiente e Agua - An Interdisciplinary Journal of Applied Science*, v. 16, n. 5, p. 1–11, 2021.
- BATISTA, B. D.; FONSECA, B. M. Fitoplâncton da região central do Lago Paranoá (DF): uma abordagem ecológica e sanitária. *Engenharia Sanitaria e Ambiental*, v. 23, n. 2, p. 229–241, 2018.
- BERNARDO, N.; WATANABE, F.; RODRIGUES, T.; ALCÂNTARA, E. 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.
- BERNSTEIN, L. S.; ADLER-GOLDEN, S. M.; SUNDBERG, R. L.; *et al.* Validation of the QUick atmospheric correction (QUAC) algorithm for VNIR-SWIR multi- and hyperspectral imagery. In: S. S. Shen; P. E. Lewis (Orgs.). p.668, 2005.
- BINDING, C. E.; STUMPF, R. P.; SHUCHMAN, R. A.; SAYERS, M. J. *Advances in Remote Sensing of Great Lakes Algal Blooms*. p.217–232, 2020.
- BORGES, H. D.; CICERELLI, R. E.; DE ALMEIDA, T.; ROIG, H. L.; OLIVETTI, D. Monitoring cyanobacteria occurrence in freshwater reservoirs using semi-analytical algorithms and orbital remote sensing. *Marine and Freshwater Research*, v. 71, n. 5, 2020.
- CABALLERO, I.; ROMÁN, A.; TOVAR-SÁNCHEZ, A.; NAVARRO, G. Water quality monitoring with Sentinel-2 and Landsat-8 satellites during the 2021 volcanic eruption in La Palma (Canary Islands). *Science of The Total Environment*, v. 822, p. 153433, 2022.

- CARVALHO, G. A.; MINNETT, P. J.; EBECKEN, N. F. F.; LANDAU, L. Classification of Oil Slicks and Look-Alike Slicks: A Linear Discriminant Analysis of Microwave, Infrared, and Optical Satellite Measurements. *Remote Sensing*, v. 12, n. 13, p. 2078, 2020.
- COOLEY, T.; ANDERSON, G. P.; FELDE, G. W.; HOKE, M. L.; RATKOWSKI, A. J.; CHETWYND, JH, ... & LEWIS, P. FLAASH, um algoritmo de correção atmosférica baseado em MODTRAN4, sua aplicação e validação. In: Simpósio internacional de geociências e sensoriamento remoto do IEEE. IEEE, p. 1414-1418, 2002.
- DEKKER, A. G.; PETERS, S. W. M. The use of the Thematic Mapper for the analysis of eutrophic lakes: a case study in the Netherlands. *International Journal of Remote Sensing*, v. 14, n. 5, p. 799–821, 1993.
- DUBE, T.; MUTANGA, O.; SIBANDA, M.; BANGAMWABO, V.; SHOKO, C. Testing the detection and discrimination potential of the new Landsat 8 satellite data on the challenging water hyacinth (*Eichhornia crassipes*) in freshwater ecosystems. *Applied Geography*, v. 84, p. 11–22, 2017.
- EUGENIO, F.; MARCELLO, J.; MARTÍN, J. Multiplatform Earth Observation Systems for Monitoring Water Quality in Vulnerable Inland Ecosystems: Maspalomas Water Lagoon. *Remote Sensing*, v. 12, n. 2, p. 284, 2020.
- EUGENIO, F.; MARCELLO, J.; MARTIN, J.; RODRÍGUEZ-ESPARRAGÓN, D. Benthic Habitat Mapping Using Multispectral High-Resolution Imagery: Evaluation of Shallow Water Atmospheric Correction Techniques. *Sensors*, v. 17, n. 11, p. 2639, 2017.
- GONZÁLEZ-MÁRQUEZ, L. C.; TORRES-BEJARANO, F. M.; TORREGROZA-ESPINOSA, A. C.; HANSEN-RODRÍGUEZ, I. R.; RODRÍGUEZ-GALLEGOS, H. B. Use of LANDSAT 8 images for depth and water quality assessment of El Guájaro reservoir, Colombia. *Journal of South American Earth Sciences*, v. 82, p. 231–238, 2018.
- HARMEL, T.; CHAMI, M.; TORMOS, T.; REYNAUD, N.; DANIS, P. A. 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.
- DE KEUKELAERE, L.; STERCKX, S.; ADRIAENSEN, S.; *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.
- KIRK, J. T. Light and photosynthesis in aquatic ecosystems. 1994.
- KRAVCHENKO, A. N.; BOLLERO, G. A.; OMONODE, R. A.; BULLOCK, D. G. Quantitative Mapping of Soil Drainage Classes Using Topographical Data and Soil Electrical Conductivity. *Soil Science Society of America Journal*, v. 66, n. 1, p. 235–243, 2002.
- MACIEL, D.; NOVO, E.; SANDER DE CARVALHO, L.; *et al.* Retrieving Total and Inorganic Suspended Sediments in Amazon Floodplain Lakes: A Multisensor Approach. *Remote Sensing*, v. 11, n. 15, p. 1744, 2019.
- MACIEL, F. P.; PEDOCCHI, F. Evaluation of ACOLITE atmospheric correction methods for Landsat-8 and Sentinel-2 in the Río de la Plata turbid coastal waters. *International Journal of Remote Sensing*, v. 43, n. 1, p. 215–240, 2022.
- MAIN-KNORN, M.; PFLUG, B.; LOUIS, J.; *et al.* Sen2Cor for Sentinel-2. In: L. Bruzzone; F. Bovolo; J. A. Benediktsson (Orgs.); *Image and Signal Processing for Remote Sensing XXIII*. Anais.... p.3, 2017. SPIE.
- MÉLIN, F. Validation of ocean color remote sensing reflectance data: Analysis of results at European coastal sites. *Remote Sensing of Environment*, v. 280, p. 113153, 2022.
-

- MOBLEY, C. D. Estimation of the remote-sensing reflectance from above-surface measurements. *Applied Optics*, v. 38, n. 36, p. 7442, 1999.
- NANNI, M. R.; DEMATTÊ, J. A. M.; FIORIO, P. R. Análise discriminante dos solos por meio da resposta espectral no nível terrestre. *Pesquisa Agropecuária Brasileira*, v. 39, n. 10, p. 995–1006, 2004.
- NYAMEKYE, C.; GHANSAH, B.; AGYAPONG, E.; KWOFIE, S. Mapping changes in artisanal and small-scale mining (ASM) landscape using machine and deep learning algorithms. - a proxy evaluation of the 2017 ban on ASM in Ghana. *Environmental Challenges*, v. 3, p. 100053, 2021.
- OGASHAWARA, I.; JECHOW, A.; KIEL, C.; *et al.* Performance of the Landsat 8 Provisional Aquatic Reflectance Product for Inland Waters. *Remote Sensing*, v. 12, n. 15, p. 2410, 2020.
- OLIVETTI, D.; ROIG, H.; MARTINEZ, J.-M.; *et al.* Low-Cost Unmanned Aerial Multispectral Imagery for Siltation Monitoring in Reservoirs. *Remote Sensing*, v. 12, n. 11, p. 1855, 2020.
- PASSOS, M. C. DOS; RIBEIRO, F. P.; TEIXEIRA, T. M. DE A.; VALADÃO, M. B. X. Crise hídrica no Distrito Federal, Brasil: uma visão acadêmica. *Research, Society and Development*, v. 9, n. 11, p. e1139119518, 2020.
- PEREIRA-SANDOVAL, M.; RUESCAS, A.; URREGO, P.; *et al.* Evaluation of Atmospheric Correction Algorithms over Spanish Inland Waters for Sentinel-2 Multi Spectral Imagery Data. *Remote Sensing*, v. 11, n. 12, p. 1469, 2019.
- PISANTI, A.; MAGRÌ, S.; FERRANDO, I.; FEDERICI, B. SEA WATER TURBIDITY ANALYSIS FROM SENTINEL-2 IMAGES: ATMOSPHERIC CORRECTION AND BANDS CORRELATION. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. XLVIII-4/W1-2022, p. 371–378, 2022.
- ROGER, J.-C.; VERMOTE, E.; SKAKUN, S.; *et al.* Aerosol models from the AERONET database: application to surface reflectance validation. *Atmospheric Measurement Techniques*, v. 15, n. 5, p. 1123–1144, 2022.
- SAPATINAS, T. Discriminant Analysis and Statistical Pattern Recognition. *Journal of the Royal Statistical Society Series A: Statistics in Society*, v. 168, n. 3, p. 635–636, 2005.
- STEINMETZ, F.; DESCHAMPS, P. Y.; RAMON, D. Atmospheric correction in presence of sun glint: application to MERIS. *Optics Express*, v. 19, n. 10, p. 9783, 2011.
- VANHELLEMONT, Q. Adaptation of the dark spectrum fitting atmospheric correction for aquatic applications of the Landsat and Sentinel-2 archives. *Remote Sensing of Environment*, v. 225, p. 175–192, 2019.
- VANHELLEMONT, Q. Sensitivity analysis of the dark spectrum fitting atmospheric correction for metre- and decametre-scale satellite imagery using autonomous hyperspectral radiometry. *Optics Express*, v. 28, n. 20, p. 29948, 2020.
- 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.
- VERMOTE, E.; JUSTICE, C.; CLAVERIE, M.; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. *Remote Sensing of Environment*, v. 185, p. 46–56, 2016.
- WANG, D.; MA, R.; XUE, K.; LOISELLE, S. The Assessment of Landsat-8 OLI Atmospheric Correction Algorithms for Inland Waters. *Remote Sensing*, v. 11, n. 2, p. 169, 2019.
- WANG, Z.; XIA, J.; WANG, L.; *et al.* Atmospheric Correction Methods for GF-1 WFV1 Data in Hazy Weather. *Journal of the Indian Society of Remote Sensing*, v. 46, n. 3, p. 355–366, 2018.



WARREN, M. A.; SIMIS, S. G. H.; MARTINEZ-VICENTE, V.; *et al.* Assessment of atmospheric correction algorithms for the Sentinel-2A MultiSpectral Imager over coastal and inland waters. *Remote Sensing of Environment*, v. 225, p. 267–289, 2019.

YANG, H.; KONG, J.; HU, H.; *et al.* A Review of Remote Sensing for Water Quality Retrieval: Progress and Challenges. *Remote Sensing*, v. 14, n. 8, p. 1770, 2022.

---