

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**COMPORTAMENTO ESPAÇO-TEMPORAL DA  
CONCENTRAÇÃO DE CLOROFILA-A NOS CORPOS  
HÍDRICOS DO DISTRITO FEDERAL POR MEIO DO  
SENSORIAMENTO REMOTO**

**IARA RESENDE DA FONSECA**

**ORIENTADORA: REJANE ENNES CICERELLI**

**DISSERTAÇÃO DE MESTRADO EM TECNOLOGIA  
AMBIENTAL E RECURSOS HÍDRICOS**

**BRASÍLIA / DF**

**DEZEMBRO 2023**

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**COMPORTAMENTO ESPAÇO-TEMPORAL DA  
CONCENTRAÇÃO DE CLOROFILA-A NOS CORPOS  
HÍDRICOS DO DISTRITO FEDERAL POR MEIO DO  
SENSORIAMENTO REMOTO**

**IARA RESENDE DA FONSECA**

**DISSERTAÇÃO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA CIVIL E  
AMBIENTAL DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE  
BRASÍLIA COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A  
OBTENÇÃO DO GRAU DE MESTRE EM TECNOLOGIA AMBIENTAL E  
RECURSOS HÍDRICOS.**

**APROVADA POR:**

**REJANE ENNES CICERELLI, Dra. (UnB)  
(ORIENTADORA)**

**RAQUEL MORAES SOARES, Dra. (UnB)  
(EXAMINADOR INTERNO)**

**DHALTON LUIZ TOSETTO VENTURA, Dr. (ANA)  
(EXAMINADOR EXTERNO)**

**BRASÍLIA/DF, 15 DE DEZEMBRO DE 2023**

## FICHA CATALOGRÁFICA

Fonseca, Iara Resende da

Comportamento espaço-temporal da concentração de clorofila-a nos corpos hídricos do Distrito Federal por meio do sensoriamento remoto/ Iara Resende da Fonseca;

Orientadora: Rejane Ennes Cicerelli. – Brasília, 2023

116 p.

Dissertação (Mestrado – Mestrado em Tecnologia Ambiental e Recursos Hídricos) – Universidade de Brasília, 2023.

1. Clorofila-a
2. Sensoriamento remoto
3. *Google Earth Engine*
4. Reservatórios

## REFERÊNCIA BIBLIOGRÁFICA

FONSECA, I.R. (2023). Comportamento espaço-temporal da concentração de clorofila-a nos corpos hídricos do Distrito Federal por meio do sensoriamento remoto. Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 116 p.

## CESSÃO DE DIREITOS

NOME DO AUTOR: Iara Resende da Fonseca

TÍTULO DA DISSERTAÇÃO: Comportamento espaço-temporal da concentração de clorofila-a nos corpos hídricos do Distrito Federal por meio do sensoriamento remoto.

GRAU: Mestre ANO: 2023

É concedida à Universidade de Brasília permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

---

Iara Resende da Fonseca

iararesendef@gmail.com

## AGRADECIMENTOS

A Deus e à Nossa Senhora da Abadia, por terem me dado força e me conduzido a essa conquista.

Aos meus pais José e Cassimira por terem me dado todo o amor, suporte e condições para poder me dedicar aos estudos e à minha formação profissional. Ao meu irmão Lucas por toda a parceria durante o processo.

À minha orientadora Rejane, pela confiança e paciência na execução deste trabalho. E principalmente, por todo o conhecimento e dedicação em me ensinar uma área nova e tão desafiadora na minha trajetória profissional.

Ao Rodrigo, pelo amor, por acreditar em mim e por não me deixar desistir.

Aos meus amigos e amigas de vida, Ana Luísa, Anna Clara, Alice, Iandra, JV, Júlia, Luís, Luíza, Nona, Michele, Mirella, Rebeca, Theus e Thaianna. E muitas outras pessoas especiais que me escutaram e me ajudaram nos desafios dessa caminhada.

À doutoranda Larissa Valadão pelas ajudas e pelos ricos conhecimentos repassados.

À minha equipe do SNIS-SINISA, em especial à equipe técnica de resíduos sólidos e ao “clube da marmita”, por todos os conselhos e apoio durante esse período do mestrado.

À CAESB, em especial ao Bruno Dias, pela presteza em fornecer os dados necessários para o trabalho.

Ao Instituto de Geociências e professores, pelas disciplinas e infraestrutura ofertadas.

Ao professor Ricardo Minoti e à professora Raquel Soares, pelas correções e orientações na disciplina Metodologia Científica e no Seminário 1.

Ao Programa de Pós-Graduação em Tecnologia Ambiental e Recursos Hídricos pela oportunidade, infraestrutura e pelas disciplinas ofertadas.

## RESUMO

Os mananciais de abastecimento urbano são sistemas aquáticos complexos e que exigem um monitoramento contínuo para a detecção de interferências pontuais e difusas que prejudiquem a qualidade da água e coloquem a saúde da população em risco. O sensoriamento remoto se destaca como uma ferramenta que pode permitir uma ação rápida dos gestores perante situações adversas à qualidade em função de seu alto potencial de análise temporal e espacial. Contudo, estudos empíricos contínuos são necessários para o entendimento dos ambientes e suas relações com os dados obtidos por sensores orbitais, terrestres ou aerotransportados. No caso do Distrito Federal, a proximidade dos centros urbanos e agrossilvopastoris dos mananciais de abastecimento público oferece riscos proeminentes da mudança repentina da qualidade da água. Além disso, ambientes aquáticos são desafiadores para o Sensoriamento Remoto em virtude das baixas concentrações de variáveis limnológicas já evidenciadas nos últimos anos. Nesse sentido, o presente estudo tem como objetivo propor um método de estimativa espaço temporal de clorofila-a preciso e acurado para os reservatórios do Distrito Federal, por meio de um modelo semiempírico baseado na série histórica de imagens Landsat. Para isso, foram obtidos dados de clorofila-a coletados em campo pela CAESB e dados de reflectância de superfície dos satélites Landsat do período de 1984 a 2023 adquiridos por intermédio de processamento em nuvem do *Google Earth Engine*. O estudo se empenhou em encontrar um modelo semiempírico para a predição das concentrações de clorofila-a para todos os reservatórios do Distrito Federal: Lago Paranoá, Descoberto e Santa Maria. Como resultado, foi encontrado um modelo referente à série histórica dos dados do Landsat 5, de 1984 a 2011, utilizando a razão de banda azul e verde em um ajuste polinomial satisfatório ( $R^2 = 0,69$  e  $RMSE = 12,88 \mu\text{g/L}$ ). E um modelo para os dados dos sensores OLI, de 2013 a 2023, referente aos satélites Landsat 8 e 9, com a utilização da razão das bandas espectrais vermelho e verde e um ajuste exponencial dos dados ( $R^2 = 0,69$  e  $RMSE = 3,36 \mu\text{g/L}$ ). Os modelos possibilitaram a produção de mapas de distribuição espacial da clorofila-a ao longo da série história de 1985 a 2023, em que foi possível observar a evolução da qualidade da água do Lago Paranoá. Portanto, o sensoriamento remoto permitiu o estudo dos corpos hídricos do Distrito Federal e pode ser promissora a região.

**Palavras-chave:** Clorofila-a. Landsat. Reservatórios de abastecimento urbano. Google Earth Engine.

## ABSTRACT

Urban water supply reservoirs are complex lentic systems that require continuous monitoring to detect diffuse pollution interferences that could compromise water quality and pose risks to public health. Remote sensing stands out as a tool that can enable quick action by authorities in response to quality-related adverse situations due to its high temporal and spatial potential. However, continuous empirical studies are necessary to understand the environments and their relationships with the data obtained from orbital, terrestrial, or airborne sensors. In the case of the Federal District in Brazil, the proximity of urban centers to public water supply sources presents prominent risks of sudden changes in water quality. Moreover, such aquatic environments are challenging for remote sensing due to the low concentrations of limnological variables that have been observed in recent years. In this sense, the present study aims to propose a precise and accurate spatiotemporal estimation method for chlorophyll-a in the reservoirs of the Federal District, using a semi-empirical model based on the historical series of Landsat images. To achieve this, chlorophyll-a data collected in the field by CAESB (Water and Sanitation Company of the Federal District) and surface reflectance data from Landsat satellites from 1984 to 2023 were obtained through cloud processing in Google Earth Engine. The study sought to find a semi-empirical model for predicting chlorophyll-a concentrations for all reservoirs in the Federal District: Paranoá Lake, Descoberto, and Santa Maria. As a result, a model was found for the Landsat 5 data series from 1984 to 2011, using the ratio of blue and green bands in a satisfactory polynomial fit ( $R^2 = 0.69$  and  $RMSE = 12.88 \mu\text{g/L}$ ). Another model was developed for the OLI sensor data, corresponding to Landsat 8 and 9 satellites, using the ratio of red and green spectral bands and an exponential fit of the data ( $R^2 = 0.69$  and  $RMSE = 3.36 \mu\text{g/L}$ ). The models allowed the production of spatial distribution maps of chlorophyll-a throughout the historical series from 1985 to 2023, revealing the evolution of water quality in Paranoá Lake. Therefore, remote sensing facilitated the study of water bodies in the Federal District and showed promising prospects for the region.

Keywords: Chlorophyll-a, Landsat, Urban water supply reservoirs, Google Earth Engine.

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>1</b>
<b>2</b>	<b>OBJETIVOS .....</b>	<b>4</b>
2.1	Geral.....	4
2.2	Específicos .....	4
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA .....</b>	<b>5</b>
3.1	Qualidade da água em reservatórios de usos múltiplos.....	5
3.2	Sensoriamento remoto e qualidade da água .....	10
3.3	Componentes opticamente ativos.....	16
3.4	<i>Google Earth Engine</i> para a estimativa de COA .....	19
3.5	Modelos para a estimativa de clorofila-a .....	22
3.6	Testes e técnicas estatísticas para aplicação de modelos .....	28
<b>4</b>	<b>METODOLOGIA.....</b>	<b>32</b>
4.1	Área de estudo.....	33
4.2	Levantamento e compatibilização de dados.....	34
4.3	Seleção dos modelos preditivos .....	37
4.4	Calibração e validação dos modelos .....	38
<b>5</b>	<b>RESULTADOS .....</b>	<b>40</b>
5.1	Análise limnológica.....	40
5.2	Análise dos dados de reflectância de superfície.....	47
5.3	Avaliação dos modelos preditivos para estimativa de clorofila-a.....	48
5.4	Modelo preditivo de clorofila-a.....	52
5.4.1	Landsat 5.....	53
5.4.2	Landsat 8 e 9.....	57
5.5	Mapas de distribuição espacial da clorofila-a .....	62
<b>6</b>	<b>CONCLUSÃO E RECOMENDAÇÕES .....</b>	<b>68</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>70</b>
	<b>APÊNDICE.....</b>	<b>86</b>
1.	<b>Script do Google Earth Engine.....</b>	<b>86</b>

<b>2. Artigo da dissertação .....</b>	<b>92</b>
---------------------------------------	-----------

## LISTA DE FIGURAS

Figura 3.1 - Localização dos reservatórios Descoberto, Santa Maria, Lago Paranoá e Corumbá .....	7
Figura 3.2 - Cronologia dos lançamentos dos satélites nas missões Landsat e Sentinel 2 ....	12
Figura 3.3 - Esquema da interação da radiação solar com a superfície da água e seus constituintes e como é realizado o processamento digital para o cálculo da reflectância da superfície.....	14
Figura 3.4 - Curvas de reflectância espectral suavizadas de pontos amostrados no médio curso do Rio Tietê. As curvas espectrais em destaque representam a variação espectral relacionada com a concentração de ficocianina (setas vermelhas) e clorofila-a (setas verdes) em $\mu\text{g/L}$ .	18
Figura 3.5 - Ilustração do método Monte Carlo assumindo 10.000 iterações com 70% dos dados para calibração do modelo.....	29
Figura 4.1 - Etapas metodológicas do estudo .....	32
Figura 4.2 - Localização da área de estudo.....	33
Figura 4.3 - Ilustração do buffer aplicado em três pontos no lago Paranoá (LP_A4, LP_A5 e LP_B).....	36
Figura 5.1 - Dados de concentração de clorofila-a do Lago Paranoá coletados pela CAESB .....	41
Figura 5.2 - Dados de concentração de clorofila-a do reservatório Descoberto coletados pela CAESB.....	41
Figura 5.3 - Dados de concentração de clorofila-a do reservatório Santa Maria coletados pela CAESB.....	42
Figura 5.4 - Gráfico de caixa com a distribuição de concentração de clorofila-a nos reservatórios estudados .....	44
Figura 5.5 - Distribuição dos dados de clorofila-a e valores p do teste Kruskal-Wallis por agrupamentos: agregado, com todos os reservatórios, e individualmente para cada reservatório analisado. ....	46
Figura 5.6 - Distribuição dos dados de clorofila-a e valores p do teste Kruskal-Wallis por sensores analisados na série histórica do estudo.....	47
Figura 5.7 - Curva de reflectância média dos dados extraídos da plataforma GEE a partir do comprimento de onda central das bandas e intervalos das bandas espectrais de cada sensor utilizado no estudo. Sendo, LD5: Landsat 5, LD89: Landsat 8 e 9, B: banda do azul, G: banda do verde, R: Banda do vermelho e NIR: banda do infravermelho.....	47

Figura 5.8 - Ajuste polinomial para os dados de clorofila-a com a razão B/G do Landsat 5 para 141 pontos amostrais.....	54
Figura 5.9 - Histograma da distribuição do R <sup>2</sup> nas 10.000 iterações do método Monte Carlo para o modelo azul-verde.....	55
Figura 5.10 - Performance do modelo B/G com e sem o ajuste do método Monte Carlo (MC) .....	56
Figura 5.11 - Ajuste polinomial para os dados de clorofila-a com a razão R/G do Landsat 8 e 9.....	58
Figura 5.12 - Histograma da distribuição do R <sup>2</sup> nas 10.000 iterações do método Monte Carlo para o modelo preditivos com a razão R/G.....	58
Figura 5.13 - Performance do modelo R/G com e sem o ajuste do método Monte Carlo (MC) .....	59
Figura 5.14 - Distribuição espacial de clorofila-a no Lago Paranoá de acordo com os modelos preditivos do estudo .....	63
Figura 5.15 - Distribuição espacial de clorofila-a no reservatório Descoberto de acordo com os modelos preditivos do estudo .....	65
Figura 5.16 - Distribuição espacial de clorofila-a no reservatório Santa Maria de acordo com os modelos preditivos do estudo .....	66

## LISTA DE TABELAS

Tabela 3.1 - Características dos satélites Landsat utilizados no estudo. Resolução espacial (R, espacial), Resolução radiométrica (R. radiométrica), intervalo espectral e comprimento de onda central ( $\lambda$ central) .....	11
Tabela 3.2 - Exemplos de propriedades ópticas utilizadas no estudo de sistemas aquáticos	16
Tabela 3.3 - Exemplos de parâmetros de qualidade da água e suas atividades ópticas .....	17
Tabela 3.4 - Exemplos de modelos de clorofila-a da literatura. As abreviações das bandas são referentes à B = banda do azul, R = banda do vermelho, G = banda do verde e NIR = banda do infravermelho .....	23
Tabela 4.1 - Coordenadas geográficas em graus decimais dos pontos dos reservatórios deslocados utilizados no estudo .....	35
Tabela 4.2 - Modelos preditivos testados no estudo .....	38
Tabela 5.1 - Estatística descritiva das amostras de clorofila-a dos reservatórios .....	40
Tabela 5.2 - Compatibilização das imagens Landsat com os dados de campo.....	42
Tabela 5.3 - Compatibilização das imagens Landsat discretizadas por reservatórios .....	43
Tabela 5.4 - Compatibilização das imagens Landsat nos períodos de precipitação zero, sem a presença de nuvem nas imagens e coleta de 1m de profundidade .....	43
Tabela 5.5 - Compatibilização das imagens Landsat nos períodos de precipitação zero, sem a presença de nuvem nas imagens e coleta de 1m de profundidade .....	44
Tabela 5.6 - Resumo dos modelos de única banda aplicados e seus ajustes lineares. Agrupamento por todos os sensores testados, pelo Landsat 5 (TM) e pelos Landsat 8 e 9 (OLI e OLI-2) .....	49
Tabela 5.7 - Resumo dos modelos de índices e razões de bandas aplicados e seus ajustes lineares. Agrupamento para todos os sensores da série Landsat estudados (Landsat 5, 8 e 9) .....	50
Tabela 5.8 - Resumo dos modelos de índices e razões de bandas aplicados e seus ajustes lineares. Agrupamento para o sensor do Landsat 5. ....	51
Tabela 5.9 - Resumo dos modelos de índices e razões de bandas aplicados e seus ajustes lineares. Agrupamento para os sensores dos Landsat 8 e 9. ....	52
Tabela 5.10 - Ajustes testados para os dados referentes ao Landsat 5 .....	53
Tabela 5.11 - Tabela comparativa dos estudos que utilizaram a razão de bandas B/G para estimativa de clorofila-a.....	57
Tabela 5.12 - Ajustes testados para os dados referentes aos Landsat 8 e 9 .....	57

Tabela 5.13 - Tabela comparativa dos estudos que utilizaram as bandas vermelho e verde para estimativa de clorofila-a.....	59
Tabela 5.14 - Dados dos pontos utilizados para a validação dos dados de clorofila-a do modelo R/G para todos os reservatórios .....	61
Tabela 5.15 - Resultados da métricas da validação do modelo R/G para os Landsat 8 e 9...	61

## LISTA DE ABREVIATURAS

- ABNT – Associação Brasileira de Normas Técnicas
- ADASA – Agência Reguladora de Águas, Energia e Saneamento do Distrito Federal
- ANA – Agência Nacional de Águas e Saneamento
- CAESB – Companhia de Saneamento Ambiental do Distrito Federal
- COA – Componentes Ópticamente Ativos
- CONAMA – Conselho Nacional do Meio Ambiente
- ESA – European Space Agency
- ETE – Estação de Tratamento de Esgoto
- GEE – Google Earth Engine
- INMET – Instituto Nacional de Meteorologia
- NASA – National Aeronautics and Space Administration
- POA – Propriedades Óticas Aparentes
- POI – Propriedades Óticas Inerentes
- RMSE - Root Mean Square Error
- SWIR – Shortwave Infrared
- NRMSE – Normalized Root Mean Square Error
- MAPE – Mean Absolute Percentage Error

# 1 INTRODUÇÃO

Ecossistemas aquáticos são transformados pela sociedade moderna no intuito de suprir as crescentes demandas das atividades antrópicas, incluindo a urbanização. Dentre estes ecossistemas, os reservatórios urbanos se destacam pela complexidade e importância na segurança da saúde pública (LI et al., 2022; SHI et al., 2017). Abastecimento urbano, irrigação, geração de energia elétrica, navegação, recreação são usos conhecidos de um reservatório e, para integrar todos esses usos, rotinas de monitoramento e acompanhamento da qualidade da água devem ser desempenhados para manutenção dos serviços ecossistêmicos do ambiente aquático (TUNDISI, 2008).

Contudo, mudanças demográficas, de uso e cobertura da terra e de mudanças climáticas ameaçam esses ambientes e nem sempre o poder público está preparado para garantir uma rápida reposta no caso da ocorrência de desastres ambientais (KONDRATYEVA et al., 2020; PAINTER; VENKITESWARAN; BAULCH, 2023; ZANGO et al., 2022).

Segundo Tundisi e Tundisi (2008), uma base de dados consolidada e transformada em instrumento de gestão pode ser uma das formas mais eficazes de enfrentar o problema de escassez de água, estresse de água e deterioração da qualidade. Para o monitoramento tradicional, são utilizados métodos de medição pontual da qualidade de água realizados em campo e laboratório, que demandam tempo e dinheiro. Sendo assim, faz-se necessário apoiar o monitoramento tradicional com tecnologias que forneça respostas mais ágeis quanto às mudanças do ambiente, que espacializem os fatores influentes, permitindo assim a identificação de poluições difusas e atuações rápidas contra agentes causadores da degradação de um corpo hídrico.

Nos últimos anos, com o rápido desenvolvimento das tecnologias de sensoriamento remoto, em escalas globais e regionais, a obtenção de informações multitemporais através sensores de imageamento e modelos matemáticos, tornou possível o acompanhamento das alterações nos ambientes aquáticos (FENG et al., 2022). Apesar da evolução, o sensoriamento remoto em ambientes aquáticos ainda encontra dificuldades e limitações. As limitações estão ligadas às características do sistema satélite-sensor, uma vez que o monitoramento de ambientes aquáticos continentais demanda um conjunto fundamental de bandas espectrais na região visível, além de uma resolução espacial suficiente para observação de ambientes de diferentes formas e dimensões (BARBOSA; NOVO; MARTINS, 2019).

O desafio é encontrar tecnologias gratuitas e de livre acesso para atender as elevadas exigências tecnológicas que requerem o estudo de um corpo d'água pela técnica de sensoriamento remoto. Dentre as ferramentas utilizadas para os estudos de sensoriamento remoto, o *Google Earth Engine* (GEE) se destaca por ser uma plataforma em nuvem com alta capacidade de processamento de grandes bancos de dados geoespaciais e de livre acesso (GORELICK et al., 2017).

Além disso, os estudos para quantificação e monitoramento de clorofila-a evoluem na aplicação de imagens de satélite gratuitas e sem restrições de licenças ou outros mecanismos de controle. Na década de 90, Gitelson (1992) identificou que o pico de reflectância próximo ao comprimento de onda de 700nm era diretamente relacionado com a concentração de clorofila-a na água, e sua constatação impulsionou diversos progressos na área. Os modelos de estimativa de clorofila-a relacionam a primeira e a segunda faixa de absorção nos comprimentos de onda de 442nm e 665nm, respectivamente (BRICAUD; ROESLER; ZANEVELD, 1995), e aliado com o pico de reflectância em 700nm (GITELSON, 1992). Entretanto, a quantificação dessas feições são um desafio em ambientes oligotróficos (GUANTER et al., 2010).

No Distrito Federal os reservatórios de abastecimento urbano são classificados como oligotróficos, ou seja, de baixa produtividade primária e concentrações baixas de clorofila-a (MACHADO; BAPTISTA, 2016; SOUZA, 2018). Entretanto, faz-se necessário apoiar o monitoramento desses corpos hídricos para permitir respostas rápidas e identificação das possíveis interferências na qualidade de água desses mananciais, e o sensoriamento remoto se mostrou como uma tecnologia aplicável no monitoramento da região (BORGES et al., 2020; MACHADO; BAPTISTA, 2016; MAGALHÃES et al., 2022).

No Brasil, Araújo et al. (2023) analisou a incidência de florações de cianobactérias em São Paulo a partir da série histórica Landsat processada no *Google Earth Engine* e relacionou com as mudanças de uso e ocupação da terra e com fatores climáticos. Lobo et al. (2021), criou um algoritmo para monitoramento de clorofila-a na bacia do Rio Tietê e implementou, no GEE, um aplicativo para monitorar temporalmente as concentrações do pigmento.

Diante do exposto, o presente estudo tem como objetivo apoiar na elaboração de um sistema de monitoramento de clorofila-a para os reservatórios do Distrito Federal, através de um modelo semiempírico baseado na série histórica de imagens Landsat. Para isso, serão utilizados dados de campo coletados pela Companhia de Saneamento Ambiental do Distrito

Federal (CAESB) e dados de reflectância de superfície dos sensores da série Landsat processados na plataforma *Google Earth Engine*. O trabalho fornecerá uma base para concepção de um sistema de monitoramento contínuo dos reservatórios do DF no intuito de apoiar medidas de remediação e mitigação a desastres ambientais em ambientes aquáticos.

## **2 OBJETIVOS**

### **2.1 Geral**

Propor um modelo de estimativa espaço temporal de clorofila-a preciso e acurado para os reservatórios do Distrito Federal, por meio de um modelo semiempírico baseado na série histórica de imagens dos satélites Landsat.

### **2.2 Específicos**

- Estabelecer um protocolo para extração de dados espectrais das imagens Landsat concomitante aos dados de concentração de clorofila-a coletados em campo pela CAESB desde o início da passagem de sensores da série.
- Identificação de cenas com maior potencial de assertividade para a produção do modelo através da testagem de composições dos dados considerando máscara de nuvens, qualidade das imagens, precipitação e data de aquisição dos dados.
- Determinar e avaliar quais combinações de bandas espectrais são mais eficientes para quantificar a concentração de clorofila-a nos reservatórios do Distrito Federal.
- Desenvolver mapas de concentração de clorofila-a para diferentes períodos da série histórica e analisar possíveis fontes de poluição nos ambientes.

### **3 FUNDAMENTAÇÃO TEÓRICA E REVISÃO BIBLIOGRÁFICA**

#### **3.1 Qualidade da água em reservatórios de usos múltiplos**

A construção de reservatórios tem sido uma prática humana por milhares de anos, com muitas experiências acumuladas ao longo do tempo. Inicialmente construídos para reservar alguns metros cúbicos de água para abastecimento ou irrigação, esses ecossistemas aquáticos, tornaram-se grandes empreendimentos de alta tecnologia e alto custo, sendo utilizados simultaneamente para inúmeros e múltiplos fins (TUNDISI; TUNDISI, 2008).

Os principais ecossistemas aquáticos são fortemente influenciados pela ocupação antrópica e suas atividades, as quais alteraram os fluxos de nutrientes limitadores de crescimento no ecossistema das águas receptoras, modificando assim a qualidade da água e a produtividade dos lagos e reservatórios (POLIS; ANDERSON; HOLT, 1997; SMITH, 2003). Além disso, os lagos são efetivos guardiões para mudanças climáticas por serem sensíveis ao clima, respondem rapidamente às mudanças e integram informações sobre as mudanças na bacia hidrográfica (ADRIAN et al., 2009).

A limnologia tem se preocupado em identificar organismos e variáveis ambientais que possam caracterizar ecossistemas aquáticos quanto ao seu estado trófico. Esteves (1998) apresenta os reservatórios, ou lagos artificiais, dentre as tipologias de sistemas lacustres brasileiros. O autor avalia estes sistemas como ambientes de grande instabilidade limnológica devido ao baixo tempo de residência da água, e com susceptibilidade a uma grande variação do nível d'água em pouco tempo, a depender das necessidades de uso da água.

Segundo Tundisi e Tundisi (2008), a limnologia básica tem a função de proporcionar conhecimento para o manejo correto do ecossistema aquático, podendo ser aplicada em caráter preventivo, ou de prognóstico, bem como para a correção/recuperação de lagos, represas e rios, em escala de planejamento regional.

No Brasil, um importante instrumento da Política Nacional de Recursos Hídricos (BRASIL, 1997) é o enquadramento dos corpos d'água em classes segundo seus usos preponderantes, visando garantir a qualidade da água compatível com os usos mais exigentes e diminuir os custos de combate à poluição das águas mediante ações preventivas. O enquadramento possui um papel central dentro das políticas de gestão dos recursos hídricos, por se tratar de um

instrumento de planejamento que possui interfaces com os demais aspectos da gestão de recursos hídricos e de meio ambiente (RIBEIRO; HORA, 2020).

O enquadramento é normatizado pela Resolução nº 357/2005 (CONAMA, 2005) que estabelece as diretrizes ambientais para aplicação do instrumento em águas doces, salobras e salinas. Para as águas doces, a norma estabelece 5 cinco classes: classe especial, classe 1, classe 2, classe 3 e classe 4. A classe especial é destinada aos usos mais exigentes, que requerem uma melhor qualidade da água, em contrapartida, a classe 4, é destinada aos usos menos exigentes como navegação e harmonia paisagística.

Em âmbito regional, o crescimento acelerado da população do Distrito Federal, além de mudanças importantes no uso e cobertura do solo, trouxe complexidades na gestão dos recursos hídricos. Os dois principais usos da água no DF, em relação à demanda de quantidade, são, reconhecidamente, o abastecimento público e a irrigação (ADASA et al., 2018).

Somlyody e Altafin (1992), destacaram em seu estudo grandes problemas da gestão de recursos hídricos no DF, o primeiro foi o crescente aumento da população que não acompanhava as tecnologias de tratamento e que acarretavam aportes de nutrientes no Lago Paranoá. E o segundo, enfatizado como outro grande problema do Distrito Federal na época, era o sistema de abastecimento baseado em dois grandes reservatórios que não seriam suficientes para acompanhar o crescimento populacional na região, na época o abastecimento era realizado pelos reservatórios Descoberto e Santa Maria.

Entre os anos 2015 e 2018 o Distrito Federal enfrentou um período de escassez hídrica. Segundo o Relatório de Gestão da Crise Hídrica (ADASA et al., 2018), as discussões sobre as principais causas da crise hídrica no DF envolvem questões relacionadas ao crescimento populacional, à ocupação do território, a problemas decorrentes de fatores climáticos, ao planejamento e à gestão adequada dos recursos hídricos, à existência de infraestrutura adequada para garantir a quantidade de água necessária para todas as finalidades. Durante a crise, em novembro de 2017, o reservatório Descoberto atingiu 5,3% de seu volume útil e o Santa Maria 21,6% (ADASA, 2023a).

Além disto, em 2016, foi observada a ocorrência de florações de cianobactérias no Lago Paranoá que acarretou a suspensão das atividades de pesca e recreação na região do braço do Riacho Fundo até que as concentrações de cianobactérias voltassem a normalidade

(COLLISCHONN; VALTER; DE MELO, 2021). Segundo relatórios (ADASA et al., 2016; ADASA; ENGEPLUS, 2020), o ocorrido foi causado por uma conjunção de ações humanas na bacia, dentre essas as cargas difusas trazidas pelas galerias de águas pluviais, pelas cargas dos tributários, em especial o Riacho Fundo, pelos efluentes de embarcações e por conta dos nutrientes liberados dos sedimentos de fundo, devido ao menor nível da água.

Atualmente, quatro reservatórios são utilizados para abastecimento urbano no DF: Descoberto, Santa Maria, Lago Paranoá e o Corumbá (Figura 3.1). Sendo este último, incorporado no sistema de abastecimento de água do DF no início de 2022 (CAESB, 2023a). Os reservatórios fazem parte da Região Hidrográfica do Paraná, sendo os reservatórios Santa Maria e Lago Paranoá pertencentes à bacia hidrográfica do Paranoá e o reservatório Descoberto localizado na bacia hidrográfica do Rio Descoberto (ADASA, 2023b).

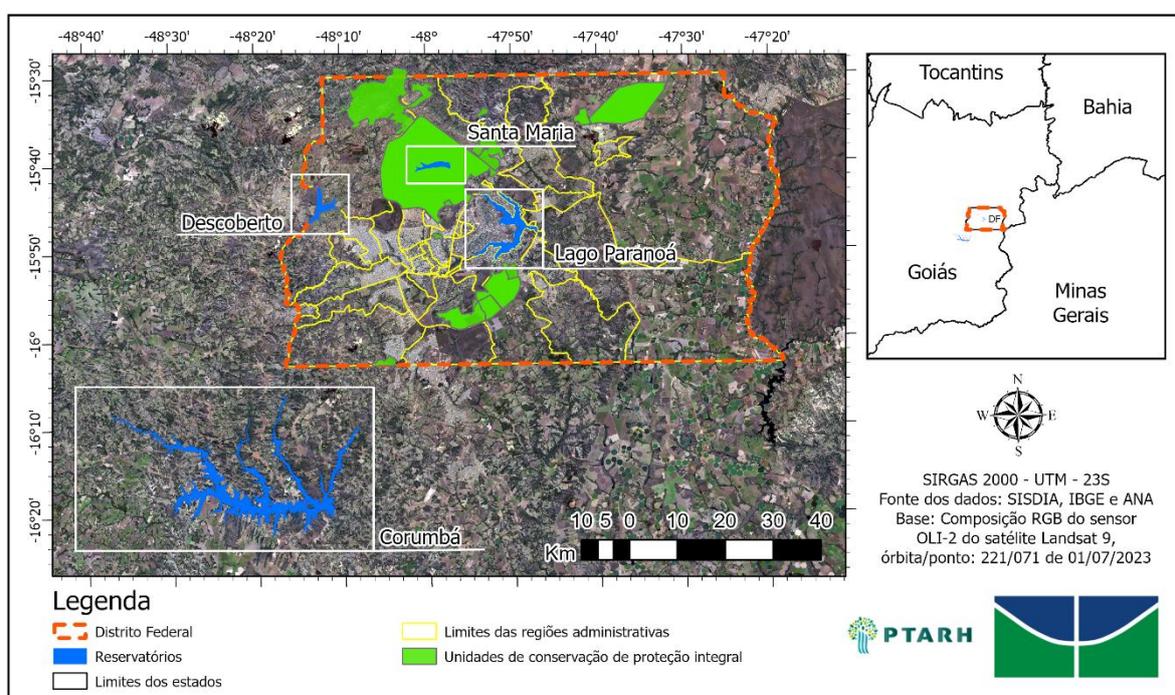


Figura 3.1 - Localização dos reservatórios Descoberto, Santa Maria, Lago Paranoá e Corumbá

Fonte: Elaborado pela autora

O subsistema de abastecimento do Torto/Santa Maria, formado pelos reservatórios Santa Maria e Lago Paranoá, é responsável pelo abastecimento de 20,2% da população do Distrito Federal (ADASA et al., 2018). Segundo o Relatório de Qualidade de Água (CAESB, 2023b), o subsistema é responsável pelo abastecimento das regiões: Plano Piloto, Sudoeste,

Octogonal, Cruzeiro, SIA, SCIA, SIN, SPO, Estrutural, Lago Norte, Lago Sul, Jardim Botânico, Guará I e II, Zona baixa de Águas Claras, Park Way (Quadras de 01 a 05), Núcleo Bandeirante, Candangolândia, Paranoá, Taquari, Condomínios RK e Império dos Nobres, Varjão, Itapoã.

O sistema do Descoberto, o qual o reservatório Descoberto faz parte, abastece cerca de 64% da população, sendo interligado ao Sistema Torto-Santa Maria de modo a permitir transferência de água entre os reservatórios (ADASA et al., 2018). O Subsistema é responsável por atender a porção oeste do Distrito Federal, sendo correspondente às regiões de: Taguatinga, Ceilândia, Vicente Pires, Zona Alta de Águas Claras, Samambaia, Riacho Fundo I e II, Recanto das Emas, Arniqueira, Park Way (a partir da Quadra 06), Santa Maria, Gama, Novo Gama (CAESB, 2023b).

Segundo a classificação do Conselho de Recursos Hídricos do Distrito Federal, disposta na Resolução nº 02/2014 (CRH-DF, 2014), os reservatórios Descoberto e Lago Paranoá se enquadram na classe 2 da Resolução CONAMA 357/2005, enquanto o manancial Santa Maria é qualificado como classe especial. O reservatório Santa Maria apresenta seu perímetro inserido no Parque Nacional de Brasília, unidade de proteção integral criada pelo Decreto nº 241/1961 (BRASIL, 1961), e sua classificação veda o lançamento de efluentes ou disposição de resíduos domésticos, agropecuários, de aquicultura, industriais e de quaisquer outras fontes poluentes, mesmo que tratados.

Determinados reservatórios tropicais urbanos, como é o caso do Lago Paranoá e do Descoberto, são particularmente vulneráveis aos impactos antrópicos por receberem todos os tipos de materiais e poluentes da bacia de drenagem, que incluem nutrientes como fosforo e nitrogênio, seja por lixiviação do solo e/ou descarga de efluentes domésticos brutos ou tratados, levando à deterioração da qualidade da água e seus impactos socioambientais consequentes (DA SILVA et al., 2021a; FONTANA et al., 2014). Além de se localizar na região central urbanizada no Distrito Federal, o Lago Paranoá recebe efluentes de duas estações de tratamento de esgoto, ETE Norte e ETE Sul (CAESB, 2023b).

Quanto aos aspectos qualitativos dos reservatórios, Lorz et al. (2012) afirma que a qualidade das águas superficiais do Lago Paranoá no Distrito Federal, analisada no estudo pelos parâmetros COD e NH<sub>4</sub><sup>+</sup>, depende fortemente da influência das áreas urbanas, mas menciona também que as contribuições de áreas rurais não devem ser negligenciadas. O autor levanta

também a necessidade da sinergia das ações nacionais de proteção aos recursos hídricos para o desenvolvimento de tecnologias, informações e monitoramento, como o Plano Nacional de Recursos Hídricos, o Programa Produtor de Água e o PRODES, Programa de despoluição de bacias hidrográficas.

No Lago Paranoá, Da Silva et al. (2021) mostraram em seu estudo que a sazonalidade, definida por um período de chuva e outro de seca, é o principal fator que governa a variação da qualidade da água no Lago. Barbosa et al. (2019) demonstrou que embora as condições climáticas e a profundidade sejam fatores importantes na retenção de nutrientes em lagos e reservatórios, no Lago Paranoá, a retenção de nitrogênio e fósforo é fortemente influenciada pelas cargas de entrada e pelo tempo de detenção hidráulica.

Batista e Fonseca (2018) em um estudo sobre a dinâmica do fitoplâncton analisada em um perfil vertical na região central do Lago Paranoá classificaram o Lago como oligotrófico, devido às baixas concentrações de fósforo total, solúvel e da biomassa algal. Além disso o estudo realizou o levantamento dos grupos fitoplanctônicos presentes no Lago e apesar da condição oligotrófica observada, as concentrações de células de cianobactérias registradas apontaram a necessidade de intensificação de monitoramento e análise de cianotoxinas em uma frequência semanal como orienta a Portaria MS nº 2.914/2011.

Quanto a região do Descoberto, os problemas encontrados na bacia estão intimamente ligados à ocupação intensiva, diversificada e desordenada, incluindo atividades agrícolas, pecuária e extrativismo mineral (MAGALHÃES et al., 2022). Em estudo de qualidade da água através do sensoriamento remoto, Chelotti et al. (2019), obtiveram uma boa correlação dos valores de reflectância dos sensores dos satélites MODIS e Landsat 8 com os valores de reflectância obtidos em campo, além disso, os autores concluíram que os maiores valores de turbidez estavam associados aos maiores volumes de chuva no reservatório Descoberto, indicando a aplicabilidade dos sensores para medições de sólidos suspensos mesmo em baixas concentrações de sedimento.

Além disso, o reservatório Descoberto é susceptível a maiores variações de volume devido a maior demanda de água e aos longos períodos de estiagem no Distrito Federal. A deterioração da qualidade dos mananciais e do suprimento de água é resultado do constante aumento no volume de água utilizado para vários fins e do aumento da poluição e contaminação hídrica (TUNDISI, 2003). Ademais, a carga de nutrientes nos corpos hídricos em períodos de escassez

favorece aumento da concentração desses nutrientes nos reservatórios, devido a diminuição do volume de água, favorecendo o processo de eutrofização e diminuição da qualidade da água (SOUZA, 2018).

### **3.2 Sensoriamento remoto e qualidade da água**

O monitoramento periódico da qualidade da água é essencial para garantir a segurança da saúde humana e a preservação do meio ambiente, especialmente em corpos d'água interiores que se submetem às mais diversas pressões antrópicas e aos diversos usos múltiplos. A construção de um banco de informações científicas com base em dados limnológicos é um passo importante no estabelecimento de programas de planejamento regional com bases ecológicas, possibilitando equacionar rapidamente os problemas existentes e planejar soluções alternativas e medidas adequadas, utilizando-se do sistema aquático como catalisador e “coletor de eventos” ao longo das bacias hidrográficas (TUNDISI; TUNDISI, 2008).

A aquisição dos parâmetros da qualidade da água por métodos convencionais ou de campo é importante para a construção de uma base de dados limnológicos para acompanhamento das condições do ambiente aquático. Entretanto, os métodos convencionais para a coleta de parâmetros para monitoramento da qualidade da água possuem limitações como: custo e tempo das análises laboratoriais, não permitem um registro amostral de variações espaço-temporais e monitoramento contínuo em locais de difícil acesso e podem não representar a realidade do reservatório por questões transporte da amostra (BARBOSA; NOVO; MARTINS, 2019; PARK; KIM; LEE, 2020). Diante dessas limitações, o sensoriamento remoto se destaca como uma técnica com potencial de apoiar as rotinas tradicionais de monitoramento de corpos aquáticos.

Neste contexto, foram desenvolvidas tecnologias de imageamento espacial para o estudo de sistemas aquáticos. Dentre essas tecnologias destacam-se o *Sea-viewing Wide Field-of-view Sensor* (SeaWiFS), sensor da NASA com 1100 metros de resolução espacial e o *Medium Resolution Imaging Spectrometer* (MERIS), sensor da *European Space Agency* (ESA) com resolução entre 300 e 1200 metros (ICCG, 2023). Entretanto, essas tecnologias para o estudo de ecossistemas aquáticos são voltadas para as águas oceânicas e como afirmam Barbosa, Novo e Martins (2019), são sensores de moderada resolução espacial, e isso limita, na maioria dos casos, os estudos em corpos d'água menores, como rios estreitos e pequenos lagos.

Devido a essa limitação, diversos estudos utilizam como ferramenta para o monitoramento de águas interiores as imagens dos programas Landsat (NASA) e Copernicus Sentinel-2 (ESA) (CAIRO et al., 2020; CARDALL; TANNER; WILLIAMS, 2021; MAGALHÃES et al., 2022; WATANABE et al., 2018). Por apresentarem uma melhor resolução espacial comparado aos sensores utilizados em estudos de águas oceânicas, essas missões, que apesar de serem projetadas para estudos terrestres, impulsionam e complementam os estudos e metodologias de aplicação em águas continentais (BARBOSA; NOVO; MARTINS, 2019).

A série Landsat da agência espacial americana NASA teve início em 1972 com o lançamento do Landsat 1, primeiro satélite a atuar diretamente em pesquisas de recursos naturais (INPE, 2022). Os satélites Landsat 1, 2, 3, 4 e 5 contavam com o sensor *Multispectral Scanner* (MSS) com resolução espacial 68 x 83m e 4 bandas espectrais. Os satélites 4 e 5 da série possuíam também o sensor *Thematic Mapper* (TM), que possuía 6 bandas com resolução de 30 metros e 1 banda do termal com resolução de 120 metros e resolução radiométrica de 8 bits, que significa que o pixel pode detectar um grau de variação de 256 ( $2^8$ ) níveis de cinza. O sexto satélite da série não atingiu a velocidade necessária para entrar em órbita. Seis anos após a falha do Landsat 6, o Landsat 7 foi lançado com uma versão melhorada do sensor TM, o *Enhanced Thematic Mapper Plus* (ETM+), que possuía uma banda pancromática adicional de 15 metros (NASA, 2023).

Tabela 3.1 - Características dos satélites Landsat utilizados no estudo. Resolução espacial (R, espacial), Resolução radiométrica (R. radiométrica), intervalo espectral e comprimento de onda central ( $\lambda$  central)

	<b>Landsat 5</b>		<b>Landsat 8</b>		<b>Landsat 9</b>	
	R. espacial = 30 m R. radiométrica = 8 bits		R. espacial = 30 m R. radiométrica = 12 bits		R. espacial = 30 m R. radiométrica = 14 bits	
	<b>Intervalo</b> ( $\mu\text{m}$ )	<b><math>\lambda</math> central</b> ( $\mu\text{m}$ )	<b>Intervalo</b> ( $\mu\text{m}$ )	<b><math>\lambda</math> central</b> ( $\mu\text{m}$ )	<b>Intervalo</b> ( $\mu\text{m}$ )	<b><math>\lambda</math> central</b> ( $\mu\text{m}$ )
<b>Banda azul</b>	0,45 – 0,52	0,485	0,45 – 0,51	0,480	0,45 – 0,51	0,480
<b>Banda verde</b>	0,52 – 0,60	0,560	0,53 – 0,59	0,560	0,53 – 0,59	0,560
<b>Banda vermelha</b>	0,63 – 0,69	0,660	0,64 – 0,67	0,655	0,64 – 0,67	0,655
<b>Banda infravermelha</b>	0,76 – 0,90	0,830	0,85 – 0,88	0,865	0,85 – 0,88	0,865

Após 13 anos, houve o lançamento do Landsat 8, equipado com sensores *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS), operando em 11 bandas, com resoluções de 30 metros (visível, NIR, SWIR), 100 metros (termal) e 15 metros (pancromática), e resolução radiométrica de 12 bits, ou seja, o pixel pode detectar uma variação de  $2^{12}$  ou 4.096 níveis de cinza. O Landsat 9 foi lançado em 2021, com versões aprimoradas dos sensores da missão anterior, possuindo o OLI-2, com 14 bits, e o TIRS-2. As imagens do Landsat 9 para a região

do Distrito Federal estão disponíveis desde 05 de novembro de 2021. A Tabela 3.1 mostra as características dos satélites Landsat 5, 8 e 9.

A missão Copernicus Sentinel 2 da agência espacial europeia ESA possui 2 satélites (Sentinel 2A e Sentinel 2B) na mesma órbita mas separados por 180°. Os satélites são equipados com o sensor *MultiSpectral Instrument* (MSI) com 13 bandas espectrais e resoluções de 10 a 60 metros (ESA, 2023). A Figura 3.2 mostra a cronologia do lançamento dos satélites das séries Landsat e Sentinel 2.

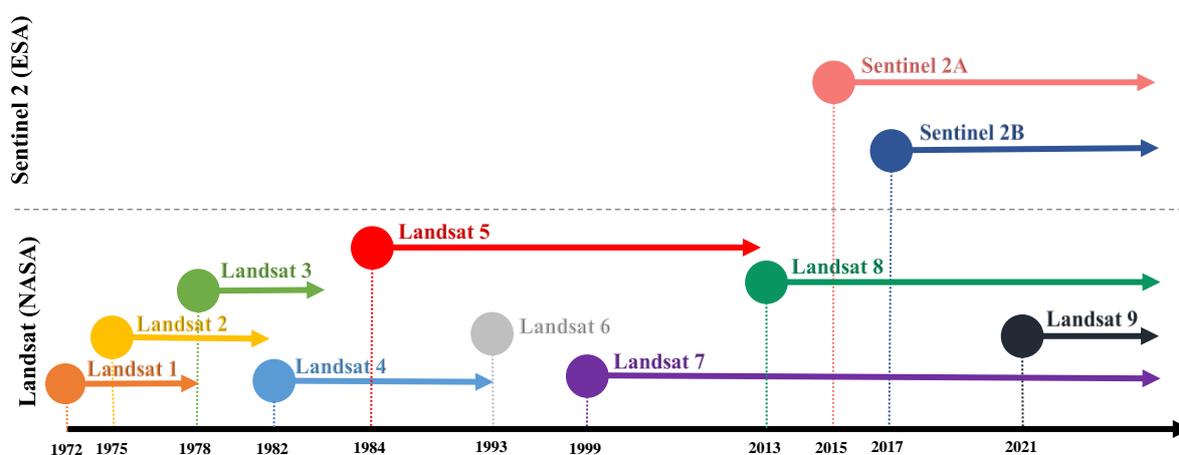


Figura 3.2 - Cronologia dos lançamentos dos satélites nas missões Landsat e Sentinel 2

Fonte: Adaptado de Jensen (2009), NASA (2023) e ESA (2023)

A variabilidade de sensores orbitais, aerotransportados e de campo tornou possível o desenvolvimento de técnicas de sensoriamento remoto para o estudo da qualidade da água, que começaram na década de 1970. As técnicas de concepção, permitem por meio da obtenção de valores de reflectância, a estimativa de parâmetros de qualidade da água, ou vice e versa. Ritchie, Schiebe e Mchenry (1976) foram os primeiros a estimar sedimentos em suspensão. O primeiro modelo bio-óptico que relacionava as propriedades ópticas de um lago foi proposto por um grupo de pesquisa no Canadá por Bukata et al. (1979, 1981) e por Jerome, Bukata e Bruton (1983).

Em relação a pigmentos fitoplanctônicos, Gitelson (1992) realizou um estudo do pico de reflectância próximo a 700nm das águas com concentrações de clorofila-a, o que impulsionou estudos na área pelo forte contraste entre o espalhamento e absorção nesse comprimento de onda. Han (1997) realizou um estudo da reflectância de águas puras e de águas com altas concentrações de sólidos em suspensão e clorofila-a, e nas situações analisadas, foi possível

observar que a clorofila-a possui uma feição de absorção centrada em 690nm. Quanto a aplicabilidade dos sensores espectrais Landsat, Vicent et al. (2004) avaliaram a detecção do florescimento de cianobactérias por meio de imagens dos sensores TM da série, e concluíram que o sensor é capaz de detectar o pigmento algal ficocianina mesmo com suas características das bandas espectrais desfavoráveis para essa mensuração.

No Brasil, os estudos para aplicação de algoritmos para monitoramento da qualidade da água vêm se intensificando nos últimos 5 anos. Watanabe et al. (2018) aplicou algoritmos de estimativa de clorofila-a utilizando imagens dos satélites Landsat 8 e Sentinel 2A para o reservatório de Barra Bonita em São Paulo. Lobo et al. (2021) desenvolveu um sistema de monitoramento de clorofila-a na plataforma *Google Earth Engine* para diversos corpos d'água no Brasil utilizando imagens da missão Sentinel 2A.

No âmbito do Distrito Federal, Piromal, Oliveira e Moreno (2007) concluíram em seu trabalho que é possível a implementação de um programa de monitoramento dos corpos hídricos do Distrito Federal através de imagens MODIS e CBERS. As composições coloridas com as imagens do ano de 2006, mesmo com a resolução espacial moderada, foram capazes de captar diferentes respostas espectrais devido a presença de matéria orgânica na barragem Corumbá 4, e para as barragens do rio Descoberto, Santa Maria e para o Lago Paranoá foi observado um comportamento constante durante o ano todo, inferindo uma boa qualidade da água destes reservatórios. Entretanto a análise foi baseada na diferença dos espectros observados, não envolveu modelagem.

Em 2016, utilizando imagens de melhor resolução, Machado e Baptista (2016) testaram uma metodologia de sensoriamento remoto para mapear o estado trófico do lago Paranoá ao longo dos anos. O estudo utilizou-se de quatro cenas do Landsat 5, referentes aos anos de 1984, 1994, 1997 e 2001, e a partir de algoritmos empíricos para cálculo de fósforo total, clorofila-a e transparência, os autores calcularam o índice de estado trófico que mostrou a evolução do lago para condições oligotróficas. O mapeamento realizado no estudo mostrou clareza na evolução da qualidade de água do Lago e aplicabilidade da geotecnologia na região, sugerindo o desenvolvimento de modelos empíricos que relacionem as propriedades do Lago com dados de sensoriamento remoto.

Para o monitoramento dos parâmetros de qualidade da água em águas interiores é necessária uma resolução espacial compatível com o tamanho do corpo d'água, para permitir a detecção

das feições espectrais, e uma resolução temporal capaz de captar as variações desses parâmetros, para permitir uma maior frequência de monitoramento. A combinação de imagens dos satélites das missões Landsat e Sentinel permitirá o aumento da frequência das observações, o que potencializa a importância desses dados multiespectrais para as futuras aplicações em águas continentais (BARBOSA; NOVO; MARTINS, 2019).

A despeito dos avanços, algumas questões ainda são mantidas, como por exemplo, a estimativa da reflectância de superfície para aplicação do sensoriamento remoto da água. A correção atmosférica acurada é crucial para o estudo das águas superficiais devido à baixa reflectância da água, que pode ser altamente influenciada pelos constituintes atmosféricos, como os aerossóis, vapor de água, ozônio, oxigênio e dióxido de carbono (GAO et al., 2009; IOCCG, 2010). A Figura 3.3 ilustra a complexidade da interação da radiação solar com a água e como é realizado o processamento digital para o cálculo da reflectância de superfície, partindo dos valores de níveis digitais captados pelo sensor.

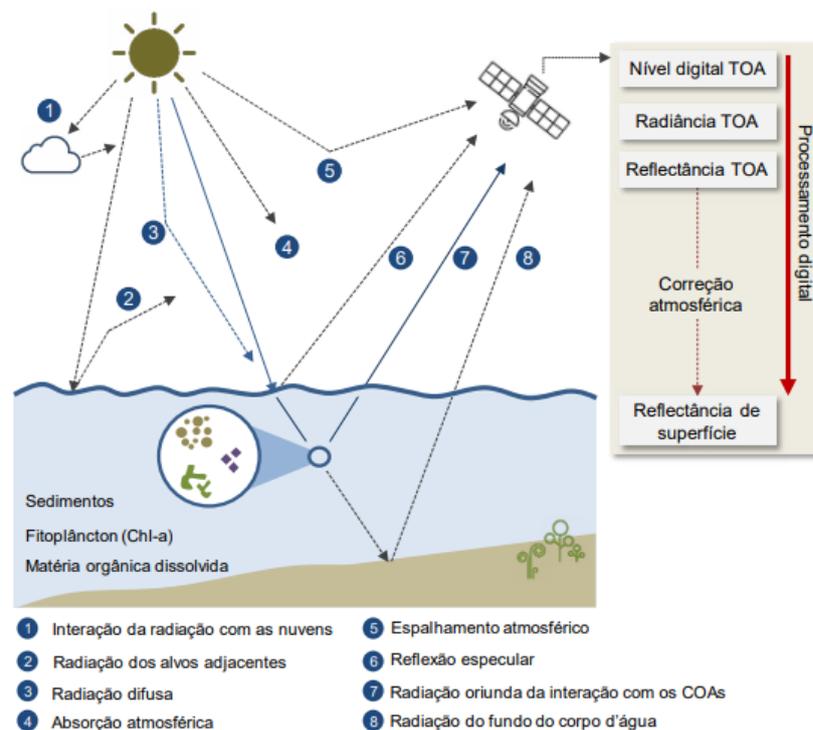


Figura 3.3 - Esquema da interação da radiação solar com a superfície da água e seus constituintes e como é realizado o processamento digital para o cálculo da reflectância da superfície

Fonte: Barbosa, Novo e Martins (2019)

Segundo Vermote et al. (2016), os efeitos atmosféricos introduzem uma perturbação não negligenciável na reflectância observada no Landsat, essa perturbação depende da geometria de iluminação e da observação, da concentração de aerossóis e de outros gases presentes na localidade. A parcela da radiação que não interage com o alvo pode ser espalhada diretamente (espalhamento de Rayleigh) para o sensor e ocasionar um “ruído atmosférico” no sinal registrado pelo sensor, muitas vezes representando mais de 80% da radiância registrada pelo sensor (PAHLEVAN et al., 2014). Tal fato reduz a sensibilidade do sensor para observação de alvos de baixa reflectância, principalmente corpos d’água, que naturalmente são alvos que absorvem a maior parte da radiação eletromagnética.

Além disso, Barbosa, Novo e Martins (2019) pontuam que a carga óptica dos aerossóis e suas fontes são bastante heterogêneas em ambientes terrestres, complicando ainda mais a correção o efeito de espalhamento deste constituinte. Em análises de séries temporais os desafios são ainda maiores para a correção atmosférica, isso pelo fato da utilização de sensores diferentes que possuem características radiométricas diferentes (LOBO; COSTA; NOVO, 2015). Além disso, as condições ambientais de cada cena analisada no período da série histórica são diferentes, dificultando ainda mais a aplicação de um método de correção atmosférica para todas as imagens em conjunto. Mesmo com o avanço na aplicação de ferramentas de processamento em nuvem, como o *Google Earth Engine*, a aplicabilidade de correção atmosférica é um desafio nos estudos de séries temporais.

Uma outra correção elencada por Barbosa, Novo e Martins (2019) para estudos de ecossistemas aquáticos é a correção do espalhamento especular da superfície da água, o *sunlint*. A correção deve considerar os fatores que condicionam a ondulação da superfície, como o vento, a geometria da iluminação, ângulo solar, entre outros. Esse efeito prejudica a identificação e quantificação dos componentes no ambiente aquático, visto que a radiação não atinge a superfície do alvo, sendo refletida nas primeiras camadas moleculares da água. Uma das formas de correção do efeito, é baseada na premissa de que o sinal remanescente na banda do infravermelho de ondas curtas (SWIR) é relacionado ao efeito especular da água (WANG et al., 2007), esta correção foi aplicada nos estudos de Cairo et al. (2020), Lobo et al. (2021) e Lobo, Costa e Novo (2015).

### 3.3 Componentes opticamente ativos

As substâncias presentes nas águas naturais que interagem com radiação solar e, portanto, são responsáveis pelos processos de absorção e de espalhamento da luz, são denominadas de componentes ou constituintes opticamente ativos (COAs). Para a quantificação dos componentes, é necessário o conhecimento das propriedades óticas do ecossistema aquático em questão, que são classificadas como inerentes ou aparentes. As propriedades óticas inerentes (POI) são aquelas que não sofrem alterações ocasionadas por eventos externos, dependem da composição e da concentração de substâncias presentes na água. Por outro lado, as propriedades óticas aparentes (POA) dependem tanto das variáveis inerentes quanto das condições ambientais a qual o corpo d'água está submetido, como por exemplo o campo de luz disponível, ou seja, a propagação da radiação eletromagnética no meio aquático (BARBOSA; NOVO; MARTINS, 2019).

As propriedades inerentes são difíceis de serem medidas em campo enquanto as aparentes, por depender de condições ambientais do corpo d'água, precisam ser mensuradas em campo (MOBLEY, 1994). A Tabela 3.2 mostra alguns exemplos de propriedades e suas classificações.

Tabela 3.2 - Exemplos de propriedades óticas utilizadas no estudo de sistemas aquáticos

Propriedade Ótica	Classificação	Unidade de medida	Simbologia
Coefficiente de absorção	Inerente	$m^{-1}$	$a$
Coefficiente de espalhamento	Inerente	$m^{-1}$	$b$
Radiância multidirecional	Aparente	$m^{-1}$	$L$
Coefficiente de atenuação difuso	Aparente	$m^{-1}$	$K_d$
Reflectância de Sensoriamento Remoto	Aparente	$m^{-1}$	$R_{RS}$

Fonte: Adaptado de Mobley (2021).

Se as propriedades óticas inerentes dos COAs forem suficientemente conhecidas, é possível determinar suas contribuições na radiância ascendente da coluna d'água, e com isso, estimar suas concentrações (BARBOSA; NOVO; MARTINS, 2019). Além dos componentes opticamente ativos, existem os constituintes opticamente inativos. Estes componentes são de grande importância para a caracterização da qualidade da água, mas possuem características óticas de difícil quantificação e são um desafio de estudo para a área (GHOLIZADEH;

MELESSE; REDDI, 2016). A Tabela 3.3 mostra os principais parâmetros de qualidade da água e sua classificação quanto a atividade óptica.

Tabela 3.3 - Exemplos de parâmetros de qualidade da água e suas atividades ópticas

<b>Parâmetro de qualidade da água</b>	<b>Abreviação [Unidade]</b>	<b>Atividade óptica</b>
Clorofila-a	Chl-a [mg/L]	Ativa
Matéria Orgânica Dissolvida	CDOM [mg/L]	Ativa
Total de Sólidos Suspensos	TSS [mg/L]	Ativa
Carbono Orgânico Total	COT [mg/L]	Ativa
Demanda Química de Oxigênio	DQO [mg/L]	Inativa
Fósforo Total	PT [mg/L]	Inativa

Fonte: Adaptado de Gholizadeh, Melesse e Reddi (2016)

Um exemplo de constituinte opticamente ativo amplamente estudado no sensoriamento remoto é a clorofila-a. A clorofila-a é um dos pigmentos principais das algas, sendo o pigmento responsável pela transformação de energia no processo da fotossíntese (TUNDISI; TUNDISI, 2008). As microalgas são essenciais para avaliação da qualidade da água dos ambientes aquáticos por conta de suas rápidas respostas às mudanças ambientais, e sua predominância no ambiente está condicionada principalmente à temperatura da água, aos nutrientes (fósforo e nitrogênio) e à presença de luz (REYNOLDS, 2006; TIAN et al., 2018; TÖRÖK et al., 2017).

A fluorescência induzida pelo pigmento clorofila-a é um indicador de biomassa fitoplanctônica e de produção primária em ecossistemas aquáticos (FALKOWSKI; KIEFER, 1985). De acordo com Barbosa, Novo e Martins (2019), a clorofila-a possui fortes bandas de absorção no azul (~430nm) e no vermelho (~665nm), enquanto o pico de reflectância ocorre na região do verde (~550 nm) e início do NIR (~710 nm). Em função dessas características, medidas remotas da concentração de clorofila-a em corpos d'água são usadas como indicativo da abundância de fitoplâncton. A Figura 3.4 evidencia a diferença nos espectros de reflectância de águas com alta e baixa concentração de clorofila-a.

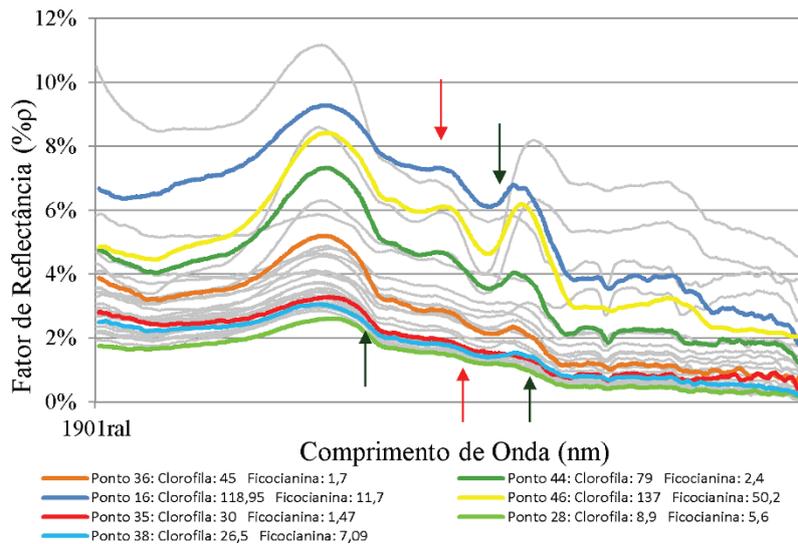


Figura 3.4 - Curvas de reflectância espectral suavizadas de pontos amostrados no médio curso do Rio Tietê. As curvas espectrais em destaque representam a variação espectral relacionada com a concentração de ficocianina (setas vermelhas) e clorofila-a (setas verdes) em µg/L

Fonte: Cicerelli e Galo (2015)

Como pode-se observar na Figura 3.4, a resposta espectral da curva referente a menor concentração de clorofila-a, que seria a curva do ponto 28 com concentração de 8,9 µg/L, apresenta uma resposta espectral baixa que exige um refinamento da técnica para atingir um bom desempenho para estimativa. Além disso, conforme sinalizado pelas setas na Figura 3.4, para águas com baixas concentrações de clorofila-a, o segundo pico de reflexão no comprimento de onda de 700nm não é perceptível quanto nas maiores concentrações. A estimativa de concentrações de clorofila-a a partir de dados de sensoriamento remoto exige o desenvolvimento de algoritmos com uma sensibilidade maior para a concentração de clorofila do que para outros constituintes presentes na água (GURLIN; GITELSON; MOSES, 2011). Além disso, a presença de fitoplâncton no espectro da água não é uma função linear de sua biomassa presente no ambiente aquático, expressa pela concentração de clorofila-a, essa interferência depende também da distribuição e posição de suas espécies na coluna d'água (LOBO et al., 2012).

Baseado na resposta espectral da clorofila-a, são feitas as estimativas das concentrações por modelos bio-ópticos. Quanto às concentrações permitidas para o pigmento clorofila-a, a resolução CONAMA nº 357/2005 estabelece para os corpos d'água de classe 1 o valor máximo de 10 µg/L e para a classe 2, 30 µg/L. A classe 1 é destinada à usos mais restritivos como abastecimento urbano após tratamento convencional e recreação de contato primário e

a classe 2, são para usos menos restritivos como pesca amadora e recreação de contato secundário.

### **3.4 *Google Earth Engine* para a estimativa de COA**

A necessidade de analisar as dinâmicas do ecossistema em vários períodos a partir de imagens de satélite que demandam um alto desempenho computacional para armazenamento e análise, levanta a exigência de aplicação de tecnologias computacionais. Com o aumento da disponibilidade de informações geoespaciais, obter imagens, analisar e manipular séries históricas a partir de imagens de satélites não se torna mais viável em computadores desktop (HIRD et al., 2017).

Plataformas de computação em nuvem são formas eficientes de armazenamento, acesso e análise de bancos de dados de poderosos servidores, onde se torna possível a virtualização de supercomputadores para seus usuários (AMANI et al., 2020). Existem diferentes servidores de computação em nuvem para *big data* geoespacial, dentre estes estão os sistemas pagos Earth Observation da *Amazon Web Services* (AWS) lançado em 2006, e o Microsoft Azure, lançado em 2016. Além desses, lançado em 2010, o *Google Earth Engine* (GEE) se destaca por usar a infraestrutura computacional da Google e permitir o acesso gratuito a um catálogo de dados de vários petabytes pronto para análise com uma tecnologia de computação intrinsecamente paralela de alto desempenho (AMANI et al., 2020; GORELICK et al., 2017; TAMIMINIA et al., 2020).

O *Google Earth Engine* foi lançado em 2010, contudo, foi difícil fazer o uso da ferramenta até o ano de 2015. Como resultado disso, poucas publicações foram realizadas entre o período de 2010 a 2015. Após 2015, o número de publicações e citações cresceu exponencialmente devido a significativa melhora da interface, cubo de dados e ambiente programador (ZHAO et al., 2021).

De acordo com Gorelick et al. (2017) o catálogo da plataforma do GEE abriga um grande repositório de dados geoespaciais, incluindo observações de diversos satélites e sistemas de imagens aéreas, variáveis ambientais, previsões climáticas e meteorológicas, dados de cobertura do solo, dados topográficos e socioeconômicos. Além disso, permite aos usuários o acesso e análise utilizando a interface do *Earth Engine* para dados provenientes do catálogo público como também de dados privados inseridos na plataforma pelo próprio usuário.

Um grande avanço foi observado nos estudos de águas superficiais com a aplicação da Plataforma que permitiu a análise de grandes volumes de imagens e informações. Em 2016, Pekel et al. (2016), utilizaram cerca de 3 milhões de imagens do satélite Landsat para monitorar e quantificar as mudanças das águas superficiais nos últimos 30 anos. A análise permitiu a criação de um portal na internet que permite a visualização das mudanças nos corpos aquáticos do mundo inteiro, permitindo estudos e evidenciando os impactos das mudanças climáticas nas disponibilidades hídricas globais.

Quanto aos estudos no GEE sobre qualidade das águas interiores, Griffin et al. (2018) afirma ter sido o primeiro trabalho que estimou os parâmetros através da Plataforma. Os autores deste estudo estimaram matéria orgânica dissolvida e carbono orgânico dissolvido de seis lagos no Ártico utilizando imagens de reflectância de superfície Landsat 5 TM e 7 ETM+. Ao todo, foram analisadas 420 imagens entre o período de 2000 a 2013, apenas entre os meses de maio a outubro para haver a mínima interferência do gelo. Os autores destacaram a importância e a facilidade de processamento da ferramenta, o que aperfeiçoou a análise e permitiu a extração dos dados das imagens Landsat de forma eficiente e baseado em diversos critérios de localização, cobertura de nuvens e períodos de tempo.

No mesmo ano, Lin et al. (2018) testou modelos de regressão linear múltipla, modelos aditivos generalizados e modelos de *machine learning* (*random forest* e *boosted regression trees*), para estimativa de clorofila-a em 483 lagos nos Estados Unidos utilizando o GEE e seu catálogo de imagens de reflectância de superfície do sensor Landsat TM/ETM+. Os dados para treinar os algoritmos foram obtidos de coletas de campo em 2007, considerando a janela de 8 dias para compatibilização das imagens, e compreenderam concentrações de clorofila-a de 0,07 a 349,2 µg/L. Como resultado do trabalho, Lin et al. (2018) obteve resultados satisfatórios utilizando os modelos de *machine learning*, que inclusive foi capaz de prever uma floração em 2009, confirmando o potencial da técnica como uma ferramenta de monitoramento.

Quatro anos depois, Kislik et al. (2022) declara ser o primeiro estudo que utilizou imagens Sentinel na plataforma Google Earth Engine que analisou uma longa série temporal, de 2015 a 2020, para monitoramento da dinâmica das florações de algas em reservatórios pequenos, que juntos, somam a área de 10km<sup>2</sup>. Neste estudo, os autores reuniram informações de campo de dois reservatórios na bacia do rio Klamath no norte da Califórnia (EUA) e compararam com quatro índices espectrais: Normalized Difference Vegetation Index (NDVI), Normalized Difference Chlorophyll Index (NDCI), B8AB4 e B3B2. Após testes de qualidade da imagem

utilizando a banda QA60, aplicação do algoritmo de correção atmosférica SIAC e compatibilização dos dados de campo adotando janelas de 5 dias, os autores aplicaram os modelos espectrais em 33 imagens Sentinel-2.

No Brasil, o estudo Lobo et al. (2021) possibilitou através do GEE, a criação da primeira plataforma online de monitoramento que oferece alta resolução espacial de informações sobre os parâmetros de qualidade da água. A Plataforma permite o monitoramento de clorofila-a e do índice do estado trófico de importantes corpos hídricos brasileiros, possibilitando ao usuário a seleção da região e da data de interesse, tornando-se uma importante ferramenta para os tomadores de decisão das regiões estudadas.

Para o desenvolvimento da plataforma de monitoramento, Lobo et al. (2021) calibraram e validaram algoritmos preditivos para a mensuração de clorofila-a e do índice de estado trófico da bacia do Rio Tietê, em São Paulo, a partir de dados *in situ* coletados entre 2015 e 2020. Os autores aplicaram o modelo Normalized Difference Chlorophyll Index (NDCI), utilizado no estudo de Watanabe et al. (2018) para a mesma região, a partir dos dados espectrais de imagens de reflectância de topo da atmosfera Sentinel-2 aplicadas correções atmosféricas e de efeitos *sun glint*. Para a predição do modelo com dados de campo foi adotado o intervalo de  $\pm 2$  dias, o que totalizou em 136 pares de dados *in situ* com dados obtidos pelo modelo NDCI.

O artigo menciona a calibração a partir de coletas realizadas na bacia do Tietê, mas o sistema de monitoramento atualmente já contém corpos hídricos de Minas Gerais, Paraná, Rio de Janeiro, Goiás, Rio Grande do Sul e Argentina. Contudo, compreende-se que cada corpo hídrico apresenta sua especificidade para modelagem, devido às presenças de outros constituintes e condições ambientais locais específicas. Apesar disso, Lobo et al. (2021) aplicou um modelo universal para todos os corpos hídricos do sistema de monitoramento. Entretanto, o estudo não menciona uma prática de verificação da acurácia do modelo com novos dados coletados em campo, ou seja, uma verificação com amostras independentes das utilizadas para a elaboração do modelo.

### 3.5 Modelos para a estimativa de clorofila-a

Os modelos bio-ópticos tornam possível o acompanhamento da qualidade de água por intermédio de imagens de satélite. Segundo Barbosa, Novo e Martins (2019), existem duas abordagens por meio das quais dados espectrais de sensoriamento remoto podem ser utilizados para a estimativa de concentrações de COAs: i) Empírica: que se baseia no desenvolvimento de regressões estatísticas bi ou multivariadas entre medidas concomitantes de reflectância e de concentrações dos COAs, e quando as feições espectrais são conhecidas e incluídas na análise a abordagem é denominada de semiempírica; ii) Analítica/Semi-analítica: que fundamenta-se em relações diretas e inversas entre os COAs, POIs e POAs, por meio de soluções da Equação de Transferência Radiativa.

Para a modelagem bio-óptica de clorofila-a são utilizados modelos empíricos e semianalíticos, nos quais, em sua maioria necessita de comprimentos de onda próximos de 675nm e 700nm (GHOLIZADEH; MELESSE; REDDI, 2016). Além dos estudos com modelos empíricos e semianalíticos, análises através de algoritmos de aprendizagem de máquina “*machine learning*” são aplicados na quantificação de clorofila-a (LI et al., 2021).

A definição desses modelos depende de um conhecimento prévio sobre o comportamento espectral dos COAs, e assim podemos propor diferentes combinações de bandas espectrais (única banda, razão de bandas) para ajustar melhor essa relação (BARBOSA; NOVO; MARTINS, 2019). Gross (2019) concluiu em seu estudo que os modelos empíricos de banda única desenvolvidos por regressão simples são inadequados para estimar clorofila-a, pois, não há um único comprimento de onda das regiões do visível e do infravermelho próximo que seja afetado apenas pela variável clorofila-a fitoplanctônica, mesmo em águas que contenham apenas fitoplâncton.

Em relação aos modelos empíricos e semiempíricos, uma abordagem amplamente utilizada nos estudos de estimativa do pigmento clorofila-a é a razão de bandas espectrais. Os algoritmos baseados em razões de bandas espectrais podem reduzir as influências atmosféricas e de superfície no sinal captado pelos sensores de imageamento (LILLESAND; KIEFER, 2015). As razões mais utilizadas para a estimativa de clorofila-a são as razões das bandas azul e verde, e infravermelho e vermelho (ODERMATT et al., 2012). A Tabela 3.4 mostra alguns exemplos de modelos de clorofila-a encontrados na literatura.

Tabela 3.4 - Exemplos de modelos de clorofila-a da literatura. As abreviações das bandas são referentes à B = banda do azul, R = banda do vermelho, G = banda do verde e NIR = banda do infravermelho

	<b>Equação</b>	<b>Referência</b>
<b>Modelos de duas bandas</b>		
	Chl-a ~ R/G	(GALLEGOS; CORRELL; PIERCE, 1990)
	Chl-a ~ R/NIR	(GITELSON; GRITZ; MERZLYAK, 2002)
	Chl-a ~ NIR/G	(NGUYEN; HA; PHAM, 2020)
	Chl-a ~ R/B	(GITELSON et al., 1996)
	Chl-a ~ B/G	(GORDON; MOREL, 1983)
<b>Modelos de três bandas</b>		
	$Chl-a \sim [R_{RS}^{-1} (660-670) - R_{RS}^{-1} (703.75-713.75)] \times R_{RS} (750-757.5)$	(GITELSON et al., 2008)
<b>Modelos de índices</b>		
NDVI	Chl-a ~ [NIR-R]/ [NIR+R]	(ROUSE, 1974)
GNDVI	Chl-a ~ [NIR-G]/ [NIR+G]	(DAUGHTRY et al., 2000)
NGRDI	Chl-a ~ [G-R]/ [G+R]	(TUCKER, 1979)
SLOPE	Chl-a ~ R-G/655-560	(MISHRA; MISHRA, 2010; WATANABE et al., 2018)
BRGI	Chl-a ~ (B-R)/G	(BOCHAROV et al., 2017)
TGI	Chl-a ~ NIR*R/G	(RAYMOND HUNT et al., 2011)
SHAPE	Chl-a ~ (2R-G-B)/(G-B)	(ESCADAFAL; BELGHITH; BEN MOUSSA, 1994)
NDCI	Chl-a ~ [R <sub>RS</sub> (708) - R <sub>RS</sub> (665)]/ [R <sub>RS</sub> (708) + R <sub>RS</sub> (665)]	(MISHRA; MISHRA, 2011)
<b>Modelos semianalíticos</b>		
	QAABBHR	(WATANABE et al., 2016)
	QAAM14	(MISHRA et al., 2013)
	IIMIW	(LI et al., 2013)

Os modelos baseados na razão das bandas do azul com a verde foram inicialmente desenvolvidos para o estudo de águas oceânicas (GORDON; MOREL, 1983). Esses modelos apresentam um bom desempenho em concentrações de 0 a 10µg/L, entretanto, são considerados menos acurados por conta da influência da resposta da matéria orgânica dissolvida nos primeiros comprimentos de ondas e na primeira faixa de absorção da clorofila-a (ODERMATT et al., 2012). Witter et al. (2009) testou a razão para a estimativa de clorofila no lago Erie em Ohio nos Estados Unidos, onde as concentrações de clorofila para o desenvolvimento do modelo não ultrapassaram 20 µg/L. Os autores, testaram alguns modelos preditivos feitos para águas oceânicas e testaram também o ajuste polinomial para um modelo baseado na razão azul/verde para a localidade. Como resultado deste último modelo, os autores obtiveram ajustes de R<sup>2</sup> que variaram de 0,58 a 0,82, sendo esse último referente a uma abordagem feita pelos autores de analisar separadamente algumas áreas específicas do

lago com um modelo específico local, visto que o lago sofre influências diferentes ao longo de sua área que corroboram para valores maiores ou menores de concentração de clorofila-a.

Em relação a combinação azul e vermelha, Gitelson et al. (1996) testaram a combinação para o Landsat 5, e indicaram a fragilidade da razão em estimar quantidades inferiores a 3 µg/L visto que as reflectância nesses canais de comprimento de onda são inversamente correlacionadas, onde o aumento de concentração de clorofila-a provoca um aumento na radiância na região do vermelho ao mesmo tempo que a absorção na região do azul aumenta por conta da presença do fitoplâncton.

Os algoritmos baseados na relação das bandas do vermelho e do infravermelho são baseados na forte absorção da clorofila-a na região do vermelho (~670nm) e no pico da reflectância na região do infravermelho. Entretanto, a aplicação do modelo para o satélite Landsat 8 é dificultada por conta do posicionamento da banda do infravermelho depois do pico de absorção da clorofila-a (BOUCHER et al., 2018). Gitelson et al. (2008) desenvolveu modelos de duas e três bandas a partir de calibrações de 145 amostras de 2001 e 2002 em lagos e reservatórios de Nebraska nos EUA, onde as concentrações de clorofila-a variaram de 1,2 a 236,5 mg/m<sup>3</sup>. Aplicando as imagens do sensor MERIS foi desenvolvido o modelo de duas bandas (b1: 673–683nm, b2: 743–753nm) e de três bandas (b1: 660–670nm, b2: 703.75–713.75nm, b3: 750–757.5nm). Para o posicionamento das bandas avaliadas, foi levado em consideração que a primeira banda deve ter uma alta sensibilidade para absorção de clorofila-a, a segunda uma sensibilidade mínima para clorofila-a e a terceira, incluída no modelo de três bandas, objetiva diminuir a influência do retroespalhamento.

A posição do pico de reflectância varia em função da concentração de clorofila-a, permitindo a quantificação do pigmento especialmente em águas com alta turbidez e com altas concentrações de clorofila-a (GILERSON et al., 2010; GITELSON, 1992). Uma vantagem desses modelos sobre os modelos baseados na razão azul e verde, é que a região do vermelho sofre menos influência da matéria orgânica dissolvida e de outras partículas em suspensão (GURLIN; GITELSON; MOSES, 2011). No Brasil, aplicando bandas do satélite MERIS, Augusto-Silva et al. (2014) obtiveram resultados satisfatórios utilizando as razões do vermelho e do infravermelho no reservatório Funil no Rio de Janeiro mesmo considerando concentrações abaixo de 20 µg/L para o desenvolvimento do modelo, entretanto o ajuste linear do modelo de duas bandas apresentou um valor de interseção negativo.

Ainda em relação aos estudos que utilizam a razão de bandas do infravermelho para uma abordagem semiempírica de quantificação de clorofila-a, os modelos de Gitelson et al. (2008) foram adaptados para o sensor MSI Sentinel e testado para estudos em águas brasileiras nos trabalhos de Watanabe et al. (2018) e Borges et al. (2020). Watanabe et al. (2018) obteve coeficientes de correlação entre 83 e 84,9% para os modelos de duas e três bandas testados para as imagens do MSI/Sentinel-2A. Borges et al. (2020) realizou um estudo de estimativa de clorofila-a entre os anos 2016 e 2017 no lago Paranoá, em Brasília, também aplicando imagens do sensor MSI para os algoritmos empíricos de duas bandas (2B) e três bandas (3B), obtendo coeficientes de correlação de 85,89% e 84,18% para o 2B e 3B, respectivamente.

Ademais, as bandas espectrais que abrangem a faixa acima de 650nm, como é o caso da infravermelha, são apropriadas para o desenvolvimento de modelos de estimativa de águas interiores complexas com concentrações de clorofila-a acima de 10 µg/L (OGASHAWARA; MISHRA; GITELSON, 2017), além disso, são apropriadas para casos de grandes variações de concentrações de clorofila-a (ZIMBA; GITELSON, 2006). Nguyen, Ha e Pham (2020) utilizaram o algoritmo da razão verde e infravermelho para a predição de clorofila-a no reservatório tropical eutrofizado Tri An no Vietnã, onde obteve-se  $R^2$  de 0,72 e RMSE de 5,95 µg/L para concentrações de clorofila-a que variaram de 15,48 a 1310 µg/L, onde ainda foi possível relacionar as concentrações maiores de sólidos totais suspensos com as maiores concentrações de clorofila-a em períodos de maior precipitação.

Os modelos baseados na razão do verde com o vermelho se destacam por sofrer menos influência dos outros constituintes da água do que as bandas do azul e verde, e por permitir a aplicação de outros sensores que não possuem as bandas espectrais apropriadas para aplicação dos modelos do vermelho e infravermelho (MORADI; KABIRI, 2019). Os modelos da razão verde-vermelho se baseiam no mínimo de absorção no verde e na segunda faixa de absorção no vermelho (HA et al., 2017a).

Le et al. (2013b) destaca em seu estudo que, assim como todos os algoritmos, a utilização da razão com o verde tem desvantagens e uma delas é a sua não adequação para águas rasas devido a influência da reflectância de fundo nessa faixa espectral. Oliveira et al. (2016) teve sucesso na aplicação da razão vermelho/verde em um estudo na Baía de Guanabara (RJ), o ajuste do modelo exponencial desenvolvido alcançou coeficientes de correlação de 0,71 e RMSE de 34,48, para os 162 pares de dados de concentração e imagens do satélite MERIS com correção atmosférica.

Alguns autores aplicam os índices de vegetação NDVI (*Normalized Difference Vegetation Index*), GNDVI (*Green Normalized Difference Vegetation Index*) e NGRDI (*Normalized Green Red Difference Index*) no estudo de concentrações de clorofila-a em ambientes aquáticos. No Chile, utilizando imagens Landsat, Rodríguez-López et al. (2020) obteve correlações ( $R^2$ ) de 0,78 para o NDVI e de 0,65 para o GNDVI no estudo para o lago Laja, onde as concentrações de clorofila-a eram baixas, variando de 0,06 a 3  $\mu\text{g/L}$ . No Brasil, Londe (2008) conseguiu um ajuste linear com  $R^2$  de 0,92 utilizando o NDVI para estimar a concentração de clorofila-a no reservatório Ibitinga em São Paulo, onde as concentrações de clorofila-a variaram de 20  $\mu\text{g/L}$  a 140  $\mu\text{g/L}$ .

Os modelos TGI (RAYMOND HUNT et al., 2011) e SHAPE (ESCADAFAL; BELGHITH; BEN MOUSSA, 1994) foram inicialmente propostos para ambientes terrestres e aplicados em estudos temporais de concentrações de clorofila-a em ambientes aquáticos por Wang e Chen (2024). Wang e Chen (2024) aplicou em seu estudo imagens de diferentes sensores para a mensuração das concentrações de clorofila-a, na proposta, além dos modelos supracitados, os autores aplicaram uma série de outros modelos de estimativa para o treinamento da técnica de *machine learning* utilizada, dentre os modelos aplicados têm-se o BRGI. O modelo BRGI proposto por Bocharov et al. (2017), relacionou os dados de imagens Landsat com baixas concentrações de clorofila-a (2–30  $\mu\text{g/L}$ ) observadas no reservatório Ivankovo na Rússia, e ajuste de  $R^2$  igual a 0,75, onde foi possível identificar a distribuição espacial de clorofila-a no reservatório durante o ano de 2015.

Ainda em relação aos índices, Mishra e Mishra (2012) propuseram um modelo semiempírico denominado NDCI (*Normalized Difference Chlorophyll Index*), similar ao NDVI utilizado para vegetação, o modelo é baseado na diferença espectral nos comprimentos de onda de 708nm e 665nm. O modelo foi elaborado para águas turvas na região Mississippi (EUA), onde os dados de campo de concentração de clorofila-a variaram de 14 a 50mg/m<sup>3</sup>, aplicando as bandas do sensor MERIS. O resultado da aplicação foi satisfatório, apresentando ajustes de  $R^2$  igual a 0,90, concluindo que o índice pode ser utilizado para estimar a clorofila-a a partir de imagens do sensor MERIS.

Os mesmos autores (MISHRA; MISHRA, 2010), anteriormente, haviam proposto um outro modelo empírico denominado SLOPE para a predição de clorofila-a através de imagens MODIS no lago Pontchartrain (EUA). Além disso, os autores relacionaram a concentração de sólidos totais suspensos, calculadas a partir do algoritmo de Miller e McKee (MILLER;

MCKEE, 2004), e concluíram que as concentrações calculadas a partir de dados de sensoriamento remoto são inversamente proporcionais. O crescimento algal foi observado em menores concentrações em períodos com alta concentração de sedimentos, e os autores justificaram ao fato da concentração de sedimentos interferir na incidência de luz solar que pode comprometer o processo de fotossíntese desses organismos algais.

Watanabe et. al. (2018) aplicaram o modelo NDCI e o modelo SLOPE no reservatório Barra Bonita/SP com as imagens dos sensores OLI/Landsat 8 e MSI/Sentinel-2A, onde as concentrações de clorofila-a variaram de 17,7 a 797,8 mg/m<sup>3</sup>. O ajuste do modelo NDCI foi satisfatório para as imagens Sentinel, apresentando um R<sup>2</sup> de 0,832, mostrando que a relação das bandas do infravermelho e vermelho produzem boas correlações com a concentração de clorofila-a. Quanto ao modelo SLOPE, testado pelos autores para as imagens Landsat 8, o modelo foi capaz de detectar as características espectrais de reflectância na região do verde e absorção no vermelho, com ajuste de R<sup>2</sup> igual a 0,60, o modelo apresentou potencialidade no mapeamento das concentrações de clorofila-a. Uma das conclusões dos autores é que o algoritmo subestima a concentração do pigmento e que um único algoritmo não é o suficiente para monitorar as variações espaciais de todo o reservatório, visto que é um reservatório de grandes dimensões (310 km<sup>2</sup>) e sofre diferentes influências ao longo de sua área.

A partir do modelo NDCI utilizado por Watanabe et. al. (2018), Lobo et al. (2021) aplicaram um modelo na mesma região com imagens do sensor MSI/Sentinel 2 no período de 2015 a 2020. Com uma amostra de 136 observações de campo e os valores do índice NDCI, os autores utilizaram um algoritmo a partir da técnica de validação cruzada Monte Carlo. O modelo final apresentou um R<sup>2</sup> de 0,86 e mostrou uma boa performance em estimar concentrações médias a altas de clorofila-a (>10µg/L).

Em relação aos modelos semianalíticos, Li et al. (2013) desenvolveram um modelo baseado nas propriedades ópticas inerentes de águas continentais. Os objetos do estudo foram lagos e reservatórios na China, Australia e nos Estados Unidos com concentrações de clorofila-a entre 1,85 e 285 m/m<sup>3</sup>. O modelo utiliza-se de parâmetros de espalhamento e de absorção nos comprimentos de onda de 630, 647, 665 e 691nm e atingiu bons resultados em todas as localidades aplicadas.

Borges et al. (2020) incorporaram em seu estudo a aplicação de quatro modelos semianalíticos. O estudo reuniu os dados espectrofotométricos de campo e de imagem

Sentinel-2 obteve boas correlações para os modelos em face dos dados laboratoriais de clorofila-a, onde as concentrações variaram entre as concentrações de 0,39mg/m<sup>3</sup> a 52,12mg/m<sup>3</sup>. Dentre os modelos testados, o de melhor desempenho foi o *Inversion Model of Inland Waters* (IIMIW) proposto por Li et al. (2013) com coeficientes de correlação de 85,52%, erro médio relativo de 33,14% e erro quadrático médio de 4,63 mg.m<sup>3</sup>. O modelo IIMIW foi desenvolvido para ambientes com características semelhantes ao Lago Paranoá, sendo o que menos superestimou as concentrações de clorofila-a no estudo, o que é um desafio em modelos preditores de ambientes com baixas concentrações de clorofila-a. Outros modelos semianalíticos testados pelos autores para águas interiores (QAABBHR e QAAM14) não tiveram sucesso na aplicação no Lago Paranoá por terem sido desenvolvidos em ambientes de condições eutróficas.

### 3.6 Testes e técnicas estatísticas para aplicação de modelos

As análises estatísticas são de suma importância para vários estudos científicos. Entretanto, os erros estatísticos são comuns na literatura científica, e cerca de 50% dos artigos publicados têm pelo menos um erro estatístico (CURRAN-EVERETT; BENOS, 2004). Vários procedimentos estatísticos como análises de correlação, regressão e variância são baseadas na premissa de que os dados seguem uma distribuição normal ou Gaussiana (DRISCOLL; LECKY; CROSBY, 2000). Para verificação da premissa, podem ser realizados os testes de normalidade estatísticos como Kolmogorov-Smirnov (K-S), Shapiro-Wilk e Anderson-Darling, que comparam os valores de média e desvio padrão da amostra testada com o de uma distribuição normal, seguindo a hipótese nula de que a amostra é normal (GHASEMI; ZAHEDIASL, 2012).

Caso a premissa de normalidade seja violada, então pode-se empregar o teste não paramétrico de Kruskal-Wallis (H). A hipótese nula do teste assume que a média dos grupos analisados é semelhante (HOFFMAN, 2019; XIA, 2020). A equação do método é descrita a seguir, onde  $k$  é o número de amostras,  $n_j$  é o número de observações na amostra  $j$ ,  $N$  é o número total de observações,  $R_j$  é a soma dos postos (ranks) na amostra  $j$ .

$$H = \frac{12}{N(N + 1)} \sum_{j=1}^k \frac{R_j^2}{n_j} - 3(N + 1)$$

Ressalta-se que em casos de amostras maiores que 30 ou 40 observações, a violação da premissa da normalidade não implica em grandes problemas, e na eventualidade do estudo

apresentar por volta de cem observações, a distribuição dos dados pode ser negligenciada (ALTMAN; BLAND, 1995).

Realizadas as análises dos dados a serem aplicados em modelos preditivos, faz-se necessário o conhecimento das métricas estatísticas que validem o desempenho do modelo e verifiquem a sua eficácia de monitoramento para o estudo de caso em questão, comparando os valores medidos em campo e os valores modelados.

O método de simulação Monte Carlo tem se tornado comum na avaliação de parâmetros estatísticos para a estruturação de equações de modelos (PAXTON et al., 2001). O método consiste em dividir a amostra dos dados em duas partes, em porcentagens a critério do estudo, sendo uma para calibração e outra para validação, e repete as divisões em  $n$  vezes também definidas pelo usuário (XU; LIANG, 2000). No Brasil, os estudos de Augusto-Silva et al. (2014) e Lobo et al. (2021) utilizaram o método para a calibração dos modelos de clorofila-a a partir do sensoriamento remoto. A Figura 3.5 ilustra como o método divide o conjunto amostral para realizar as iterações e calcular a equação do modelo preditor.

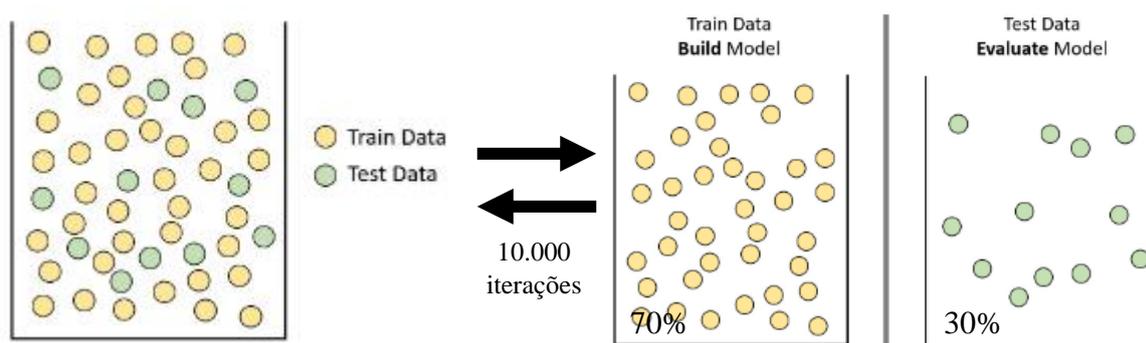


Figura 3.5 - Ilustração do método Monte Carlo assumindo 10.000 iterações com 70% dos dados para calibração do modelo

Fonte: Adaptado de Malone (2023)

Como resultado de cada iteração, o método calcula as métricas estatísticas  $R^2$ , RMSE e MAE, e os histogramas referentes a cada métrica é uma ferramenta de decisão utilizada para os estudos que utilizam a técnica (AUGUSTO-SILVA et al., 2014).

Algumas das métricas estatísticas utilizadas para validação dos modelos são: raiz do erro quadrático médio (*Root Mean Square Error - RMSE*), a raiz do erro quadrático normalizado (*Normalized Root Mean Square Error - NRMSE*), o erro absoluto médio percentual (*Mean Absolute Percentage Error - MAPE*) e o coeficiente de determinação ( $R^2$ ).

Uma das métricas de desempenho mais importante para avaliação de modelos é a raiz erro quadrático médio ou Root Mean Square Error (RMSE). A medida é medida de precisão geral do modelo, e tem como vantagem, apresentar resultados na mesma unidade da variável de estudo. Diversos autores utilizam a métrica para comparação (ARANHA et al., 2022; BORGES et al., 2020; MISHRA; MISHRA, 2012). A fórmula do RMSE é descrita a seguir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

Onde,  $n$  é o número de amostras,  $\hat{y}_i$  são os valores de campo (observados) e  $y_i$  são os valores obtidos através do modelo.

Uma outra variação do RMSE, a raiz do erro quadrático normalizado ou Normalized Root Mean Square Error (NRMSE), é utilizada para comparação de modelos de diferentes escalas. Utilizada no estudo de Watanabe et al. (2018), o parâmetro produz resultados entre 0 e 1, onde o valor mais próximo de 0 representa um melhor ajuste.

$$NRMSE = \frac{RMSE}{y_{max} - y_{min}}$$

Onde  $y_{max}$  e  $y_{min}$  é o valor máximo e mínimo, respectivamente, medido em campo.

O erro absoluto médio percentual ou Mean Absolute Percentage Error (MAPE), é expressa em porcentagem e é bastante utilizada para previsões. É utilizada para verificação dos modelos na maioria dos estudos (LI et al., 2013; LOBO et al., 2021; WATANABE et al., 2018). Sua fórmula é descrita abaixo.

$$MAPE = \frac{\sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\hat{y}_i}}{n}$$

Onde,  $n$  é o número de amostras,  $y_i$  são os valores preditos no modelo e  $\hat{y}_i$  são os valores medidos em campo.

Dentre as técnicas mais utilizadas para verificação de modelos, o coeficiente de correlação ( $R^2$ ) é utilizado para medir as relações entre as variáveis e o que isso representa para o estudo. O resultado é expresso entre 1 e -1, sendo 0 o indicativo de não correlação entre as variáveis. A fórmula do índice de correlação é indicada a seguir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Onde,  $y_i$  são os valores preditos no modelo,  $\hat{y}_i$  os valores medidos em campo.

Desta forma, levantadas as questões acerca do sensoriamento remoto em ambientes aquáticos, sua importância e desafios, faz-se necessário a avaliação da aplicabilidade da técnica para o monitoramento de clorofila-a nos corpos hídricos do Distrito Federal. Além disso, é essencial a concepção de uma base de dados para a elaboração de um sistema de monitoramento contínuo dos reservatórios do DF no intuito de apoiar medidas de remediação e mitigação a desastres ambientais em ambientes aquáticos.

## 4 METODOLOGIA

A metodologia do estudo consiste em etapas de levantamento e compatibilização dos dados de campo e de reflectância de superfície das imagens Landsat, do desenvolvimento dos modelos de estimativa de clorofila-a e análises estatísticas para ajuste. A Figura 4.1 mostra as etapas metodológicas a serem detalhadas nos próximos itens da seção.

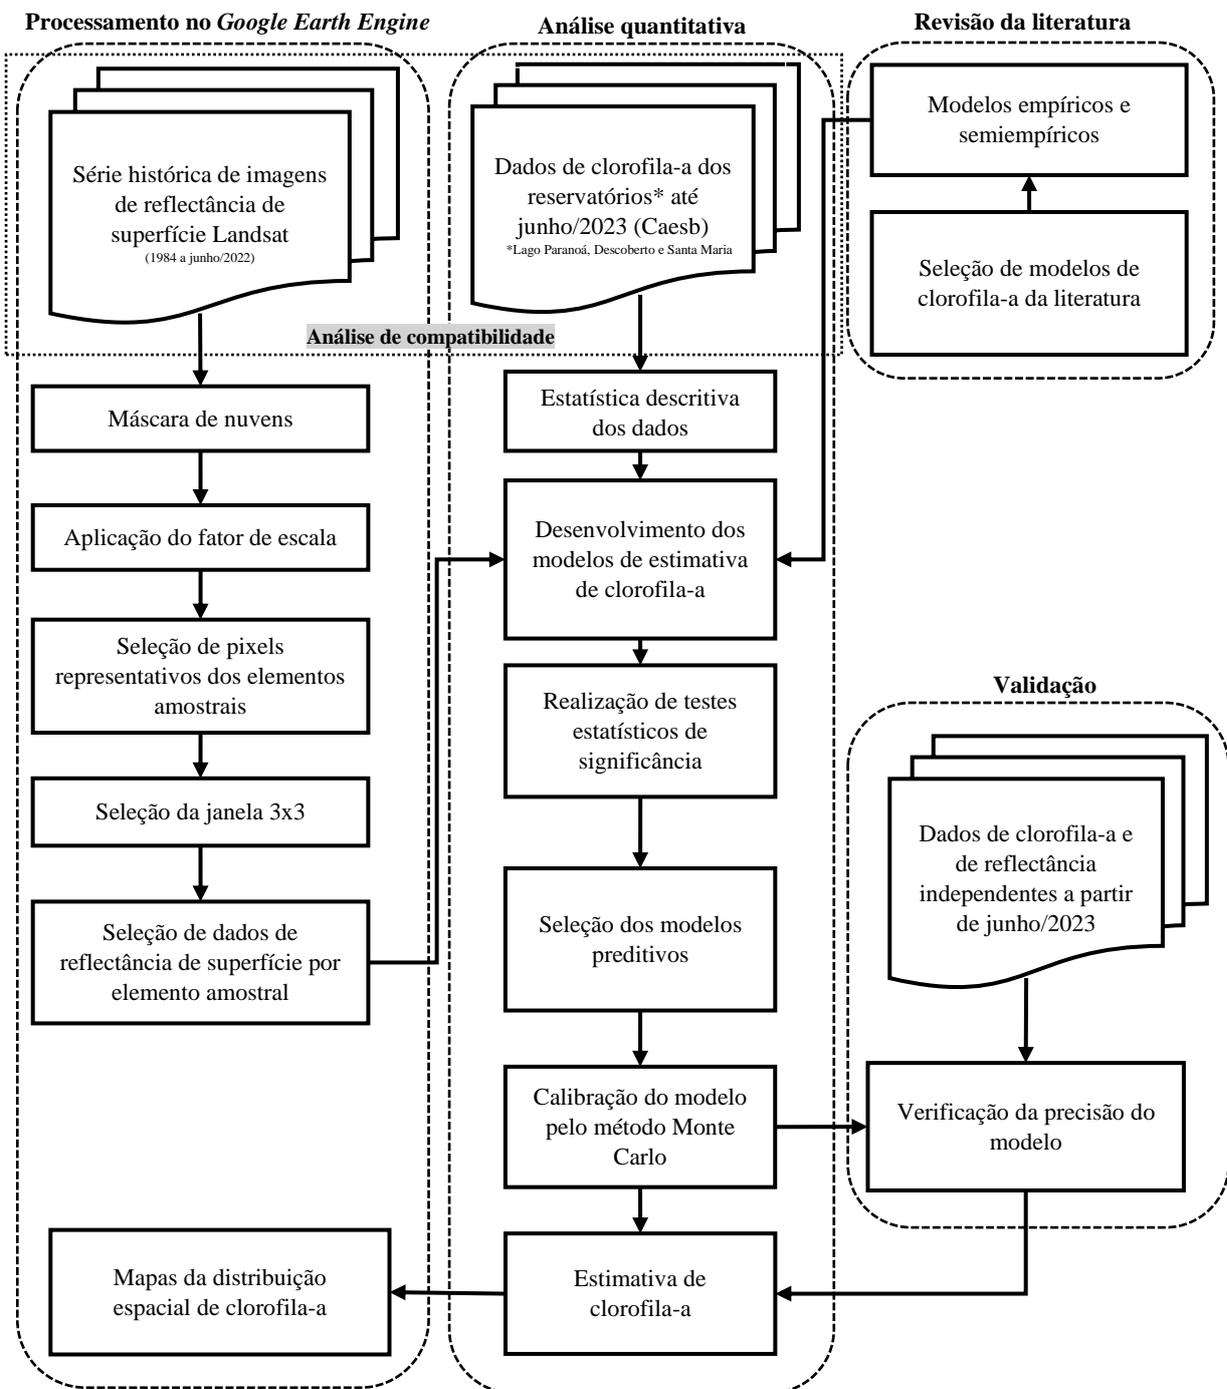


Figura 4.1 - Etapas metodológicas do estudo

Fonte: Elaborado pela autora

#### 4.1 Área de estudo

A área do estudo são três reservatórios de abastecimento urbano do Distrito Federal (DF), Lago Paranoá, Descoberto e Santa Maria, localizados na macrorregião centro-oeste do Brasil (Figura 4.2). A região do DF possui uma área territorial de 5,7 milhões de km<sup>2</sup> e possui uma população residente de 2,8 milhões de habitantes, configurando a maior densidade demográfica dentre as 27 unidades da federação do país (IBGE, 2022).

De acordo com a classificação Köppen, o clima no Distrito Federal é de savana tropical, com inverno seco e os maiores índices de precipitação durante o verão (IPEDF, 2020). Os sistemas de circulação atmosférica associados à posição geográfica do Distrito Federal definem dois períodos: um período seco e frio que vai do final de abril a setembro, e um período quente e chuvoso que vai do final de outubro ao final de março (STEINKE et al., 2020).

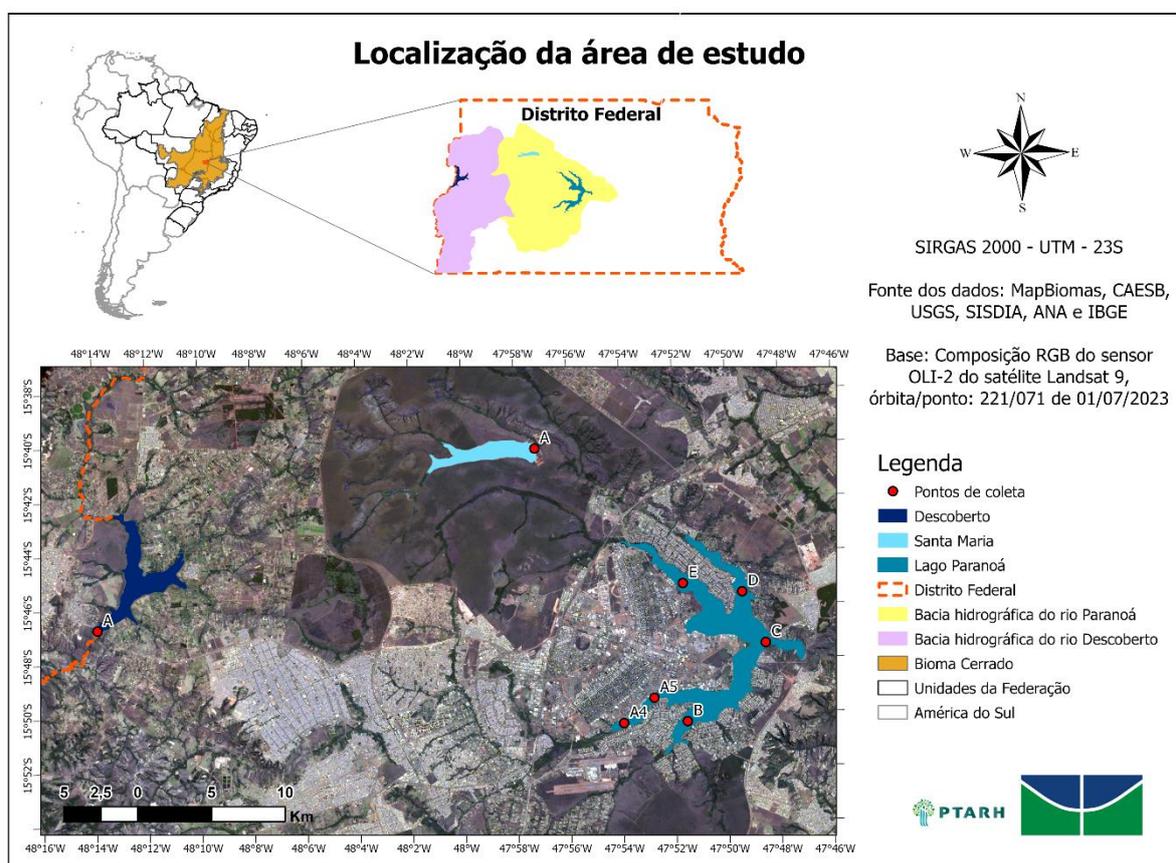


Figura 4.2 - Localização da área de estudo

Fonte: Elaborado pela autora

A região localiza-se no bioma Cerrado, um *hotspot* de biodiversidade global, com mais de 4800 espécies de plantas e vertebrados (STRASSBURG et al., 2017). Além disso, o espaço

geográfico ocupado pelo bioma Cerrado desempenha papel fundamental no processo de distribuição dos recursos hídricos pelo país, constituindo-se o local de origem das grandes regiões hidrográficas brasileiras e do continente sul-americano, fenômeno apelidado de “efeito guarda-chuva” (LIMA, 2011).

A qualidade da água dos três reservatórios objetos deste estudo, são monitorados pela Companhia de Saneamento Ambiental do Distrito Federal nos pontos indicados em vermelho no mapa da Figura 4.2. São seis pontos de amostragem no Lago Paranoá (A4, A5, B, C, D e E), um ponto no reservatório Descoberto (A) e um no Santa Maria (A).

O Lago Paranoá foi criado em 1959 com objetivos paisagísticos, recreativos, de geração de energia elétrica e para a diluição de efluentes (MARQUES, 2021; MENEZES JR.; SINOTI; SARAIVA, 2001). Na década de 70, os braços do Bananal (Ponto E – Figura 4.2) e do Riacho Fundo (Pontos A4 e A5, Figura 4.2) eram considerados eutróficos devido ao lançamento de esgotos sem tratamento (DE OLIVEIRA; KRAU, 1970). Após a implantação das Estações de Tratamento de Esgotos (ETEs) Sul e Norte em 1993, o funcionamento efetivo das ETEs em 1996 e o flushing ocorrido em 1999 a qualidade da água do lago melhorou significativamente, atingindo condições oligotróficas (ANGELINI; BINI; STARLING, 2008; MACHADO; BAPTISTA, 2016). Em 2017, devido à escassez hídrica enfrentada no DF, o Lago Paranoá passou a ser utilizado como reservatório para abastecimento urbano (ADASA et al., 2018).

O reservatório Santa Maria se insere Parque Nacional de Brasília (BRASIL, 1961), e em 2022, foi responsável pelo abastecimento de 11% do Distrito Federal (CAESB, 2023c). O reservatório Descoberto é responsável pelo abastecimento de cerca de 60% da população do DF (ADASA et al., 2018) e está inserido em uma Área de Proteção Ambiental (BRASIL, 1983), porém apesar de serem proibidas atividades que gerem fontes pontuais de contaminantes, a área vem sofrendo constante degradação ambiental principalmente pela poluição difusa advinda da água de escoamento (DE VITO, 2007).

## **4.2 Levantamento e compatibilização de dados**

A primeira fase do escopo metodológico do estudo é a de levantamento e compatibilização dos dados iniciais de concentração de clorofila-a coletadas em campo e das imagens de reflectância de superfície do Landsat. Esta etapa de compatibilização avaliou janelas temporais de defasagem de 0, 1, 2, e 3 dias entre as medições *in situ* e as passagens dos satélites Landsat na região dos reservatórios.

Os dados de concentração de clorofila-a coletados em campo foram fornecidos pela Companhia de Saneamento Ambiental do Distrito Federal (CAESB) e compreenderam o período de janeiro de 1984 a outubro de 2023, totalizando um banco de dados de quase 40 anos de registros do acompanhamento deste parâmetro limnológico. Para estes dados, foram realizados testes de normalidade (Shapiro-Wilk e Kolmogorov-Smirnov) e o teste não paramétrico de Kruskal-Wallis, assim como, análises dos gráficos de caixa (*boxplot*) dos dados para compreender as concentrações ao longo da série histórica analisada e dos reservatórios estudados. Quanto aos dados de sensoriamento remoto, foram utilizadas as coleções 2 das imagens das séries Landsat 5, 8 e 9, referentes às imagens de reflectância de superfície produzidas pela *United States Geological Survey* (USGS) a partir de algoritmos específicos para cada sensor. As imagens referentes a série Landsat 7 não apresentaram uma qualidade radiométrica adequada para a análise dos pontos amostrais.

As imagens Landsat foram trabalhadas dentro da plataforma *Google Earth Engine* (GEE) através da aplicação de um *script* em linguagem *JavaScript* (Apêndice). O script desenvolvido realiza primeiramente a inserção dos pontos de amostragem fornecidos pela Caesb na plataforma em formato *shapefile*. A tabela 4.1 mostra as coordenadas dos pontos amostrais utilizados para a extração dos dados na plataforma GEE, baseado nos pontos amostrais ilustrados na Figura 4.2.

Tabela 4.1 - Coordenadas geográficas em graus decimais dos pontos dos reservatórios deslocados utilizados no estudo

<b>Reservatório</b>	<b>Ponto</b>	Latitude (graus decimais)	Longitude (graus decimais)
Lago Paranoá	A4	-15,83°	-47,89°
	A5	-15,82°	-47,87°
	B	-15,83°	-47,85°
	C	-15,79°	-47,80°
	D	15,75°	-47,82°
	E	-15,75°	-47,86°
Santa Maria	A	-15,67°	-47,96°
Descoberto	A	-15,77 °	-48,22°

Para alguns pontos, foi necessário realizar uma adaptação em virtude da Caesb selecionar regiões muito próximas as margens, o que poderia resultar na coleta de pixels com mistura

espectral de outros alvos. Desse modo, para um melhor desempenho da extração dos dados de reflectância e minimização da influência das margens do reservatório nos pixels de água, os pontos foram minimamente deslocados para o interior de cada reservatório.

Na plataforma, para a transformação dos números digitais dos pixels das imagens em valores de refletância, foi aplicado o fator de escala de 0,0000275 somado a um *offset* de -0,2, conforme instruções da USGS (USGS, 2023). Depois da transformação, foram utilizadas funções de *buffer* e de estatísticas zonais para obtenção da média dos valores dos pixels. No *buffer*, aplicou-se a variação “*no bounds*” da função e a metragem de 45 metros, equivalendo assim, a uma área de amostragem equivalente a janela de pixels 3x3 das imagens. Além disso, aplicou-se uma função de máscara de nuvens que se utiliza da banda “*qa\_pixel*” das coleções Landsat utilizada, diminuindo assim, a interferência de nuvens nas imagens analisadas.

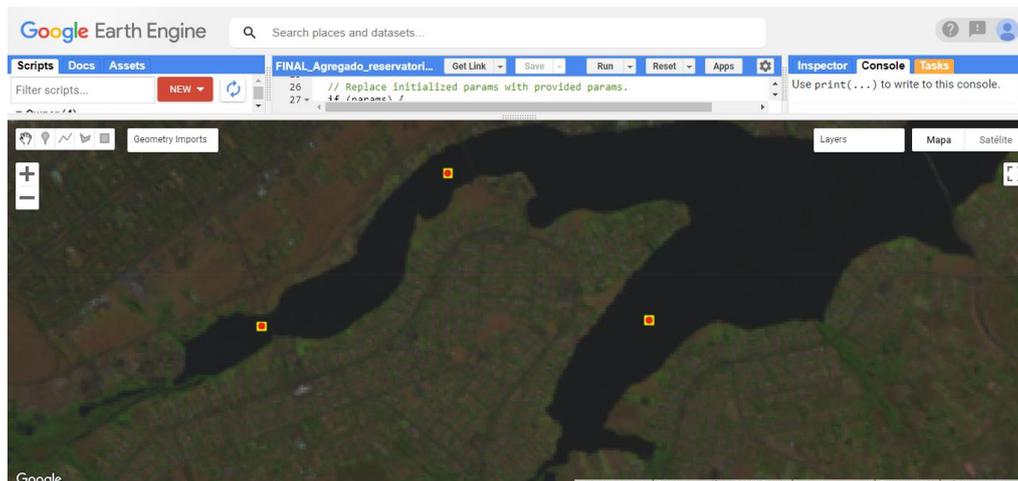


Figura 4.3 - Ilustração do buffer aplicado em três pontos no lago Paranoá (LP\_A4, LP\_A5 e LP\_B)

No mesmo *script*, depois das transformações e aplicações de funções, foi incorporado um código que transformasse os valores de refletância de superfície de todos os sensores em todas as datas da série histórica estudada, em uma planilha .csv para posterior estudo nos softwares *RStudio* e *Microsoft Excel*.

As duas séries temporais dos dados, compreendendo os anos de 1984 a 2023 foram trabalhadas no *RStudio* e as janelas de defasagem foram avaliadas. Após a avaliação optou-se por utilizar a janela de 3 dias de defasagem para considerar um maior número de pares de dados para performar os modelos, compreendendo o total de 1.262 observações.

### 4.3 Seleção dos modelos preditivos

Na etapa de seleção dos modelos preditivos, os dados das razões de bandas e das bandas individuais avaliadas foram produzidos no *RStudio*. Para a produção desses dados foram feitas algumas considerações para garantir a qualidade radiométrica do valor de reflectância a ser utilizado nos modelos.

Primeiro utilizou-se os dados de precipitação do INMET para verificação da ocorrência de chuvas na região do Distrito Federal para inferir a possível presença de nuvens nas imagens. A partir dessa avaliação, selecionou-se apenas as imagens que não continham registros de precipitação na data de passagem do sensor. Além disso, cada imagem foi analisada de forma individual para averiguar a presença ou não de nuvens, o deslocamento das imagens e outras possíveis interferências na qualidade do pixel a ser obtido.

Após a filtragem das imagens com boa qualidade geométrica e radiométrica para utilização no modelo, foi aplicada a correção *sunglint*. Na aplicação da correção, os valores de reflectância das bandas da região do visível (azul, verde, vermelho e infravermelho próximo) foram subtraídas do valor da banda do infravermelho de ondas curtas (SWIR1).

A partir dos dados corrigidos e verificados, foi possível realizar a etapa de desenvolvimento do modelo preditivo de concentração de clorofila-a nos reservatórios. A Tabela 4.2 mostra os modelos preditivos testados, bem como as razões de bandas utilizadas para o desenvolvimento de um modelo preditivo a ser aplicado em todos os reservatórios do Distrito Federal.

Na etapa de testagens de modelos, foram selecionados agrupamentos de critérios de análises para modelagem da clorofila-a, dentre eles: estados tróficos (ultraoligotrófico, oligotrófico, mesotrófico, eutrófico, supereutrófico e hipereutrófico), sensores Landsat (TM, OLI e OLI-2), diferentes limites máximos e mínimos de concentração de clorofila-a, a fim de encontrar um cenário que melhor corresponda às características dos reservatórios e dos sensores estudados.

Após a aplicação dos modelos preditivos listados na Tabela 4.2, foi selecionado o modelo que apresentou um melhor desempenho na predição de clorofila-a, e a equação após a calibração pelo método Monte Carlo foi utilizada para a elaboração de mapas da distribuição espacial do pigmento ao longo da série histórica. Para os mapas, foi utilizada a plataforma do *Google Earth Engine* para aplicação do modelo preditivo, a partir da máscara de água calculada pelo índice NDWI, e em seguida, os *rasters*, que seriam as imagens com as concentrações de

clorofila-a preditas pelos modelos, foram inseridas no ArcGis Pro para a produção dos *layouts* de mapas de distribuição espacial.

Tabela 4.2 - Modelos preditivos testados no estudo

Equação		Referência
<b>Modelos de banda única</b>		
Chl-a ~ B		
Chl-a ~ G		
Chl-a ~ R		
Chl-a ~ NIR		
<b>Modelos de duas bandas</b>		
Chl-a ~ R/G		(GALLEGOS; CORRELL; PIERCE, 1990)
Chl-a ~ R/NIR		(GITELSON; GRITZ; MERZLYAK, 2002)
Chl-a ~ NIR/G		(NGUYEN; HA; PHAM, 2020)
Chl-a ~ R/B		(GITELSON et al., 1996)
Chl-a ~ B/G		(GORDON; MOREL, 1983)
<b>Modelos de índices</b>		
GNDVI	Chl-a ~ [NIR-G]/ [NIR+G]	(DAUGHTRY et al., 2000)
NGRDI	Chl-a ~ [G-R]/ [G+R]	(TUCKER, 1979)
SLOPE	Chl-a ~ R-G/655-560	(MISHRA; MISHRA, 2010; WATANABE et al., 2018)
BRGI	Chl-a ~ (B-R)/G	(BOCHAROV et al., 2017)
TGI	Chl-a ~ NIR*R/G	(RAYMOND HUNT et al., 2011)
SHAPE	Chl-a ~ (2R-G-B)/(G-B)	(ESCADAFAL; BELGHITH; BEN MOUSSA, 1994)
NDCI	Chl-a ~ [R <sub>RS</sub> (708) - R <sub>RS</sub> (665)]/ [R <sub>RS</sub> (708) + R <sub>RS</sub> (665)]	(MISHRA; MISHRA, 2011)

#### 4.4 Calibração e validação dos modelos

Após a seleção dos modelos preditivos para cada satélite, os pares de valores de concentração de clorofila-a de campo e os valores das razões de bandas dos modelos preditivos escolhidos foram calibrados utilizando a técnica de validação Monte Carlo, assim como no estudo de Augusto-Silva et al. (2014). O método foi aplicado através do pacote *caret* no RStudio, com 10.000 iterações, e a cada iteração, 70% das amostras foram utilizadas para calibração e os 30% restantes foram para a validação.

O método retorna histogramas dos parâmetros estatísticos RMSE, MAE e R<sup>2</sup>, e dentre os valores mais frequentes de R<sup>2</sup> foram escolhidas as equações, observando também os menores valores de RMSE e MAE, para cada modelo preditor. O modelo do Landsat 5 apresentou uma melhor resposta no ajuste polinomial de 2<sup>a</sup> ordem, e o modelo dos Landsat 8 e 9, apresentaram um melhor ajuste no modelo exponencial.

A partir da equação definida no Monte Carlo para os sensores OLI (Landsat 8 e 9), foi feita uma validação com dados independentes. A validação do modelo foi realizada com dados de concentração de clorofila-a da CAESB, de junho de 2023 a outubro de 2023. Para essa última validação, foram calculados os parâmetros estatísticos Bias, Raiz do Erro Quadrático Médio (RMSE) e Raiz do Erro Quadrático Normalizada (NRMSE%).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \qquad NRMSE = \frac{RMSE}{y_{max} - y_{min}}$$

$$Bias = \frac{1}{n} \sum_{i=1}^n (y_i - x_i)$$

Entende-se que para esta última validação dos dados dos satélites Landsat 8 e 9 foi realizado para uma amostra pequena de dados, contudo espera-se que novas avaliações sejam realizadas para uma maior aquisição de dados recentes que validem a técnica utilizada neste estudo.

## 5 RESULTADOS

### 5.1 Análise limnológica para compatibilização dos dados

Os dados das concentrações de clorofila-a coletadas *in situ* pela Companhia de Saneamento do Distrito Federal são referentes a três reservatórios de abastecimento público do Distrito Federal: Lago Paranoá, Descoberto e Santa Maria. O período da análise das amostras é coincidente com o início da série histórica do Landsat 5, começando em 1984 e terminando em outubro de 2023. A Tabela 5.1 fornece a descrição estatística de todas as concentrações de clorofila-a obtidas através da Companhia.

Tabela 5.1 - Estatística descritiva das amostras de clorofila-a dos reservatórios

<b>Reservatório</b>	<b>Número de amostras</b>	<b>Máximo (µg/L)</b>	<b>Mínimo (µg/L)</b>	<b>Média (µg/L)</b>	<b>Desvio Padrão (µg/L)</b>
Lago Paranoá	4245	215,60	0,30	21,34	31,57
Descoberto	1769	16,00	0,10	1,30	1,57
Santa Maria	1705	427,50	0,20	6,87	11,36

Na fase de tratamento dos dados, de 8.337 medições de concentração e clorofila-a fornecidos pela CAESB, 618 foram retiradas da análise por apresentarem concentrações iguais a 0 µg/L, sendo 378 delas, referentes ao reservatório Descoberto. De acordo com a Figura 5.1, durante a década de 90 as concentrações de clorofila-a no Lago Paranoá começaram a diminuir, resultado provavelmente da ampliação das estações de tratamento de esgoto que passaram a dispor de tratamento terciário para a remoção de nutrientes (BURNETT; MATTOS; AZZOLIN, 2001).

As concentrações de clorofila-a no Lago Paranoá, conforme mostra a Figura 5.1, apresentam uma grande queda a partir de 1999. Conforme descrito por Angelini *et al.* (2008), a diminuição das concentrações de clorofila-a e consequentemente o aumento da transparência do lago, se deu em 1999 após a abertura abrupta das comportas do reservatório. O evento, conhecido como *flushing*, consistiu na abertura das comportas da Barragem do Paranoá que retira a camada superficial da água e todo o plâncton contido na zona eufótica do lago para a renovação da camada superficial do espelho d'água.

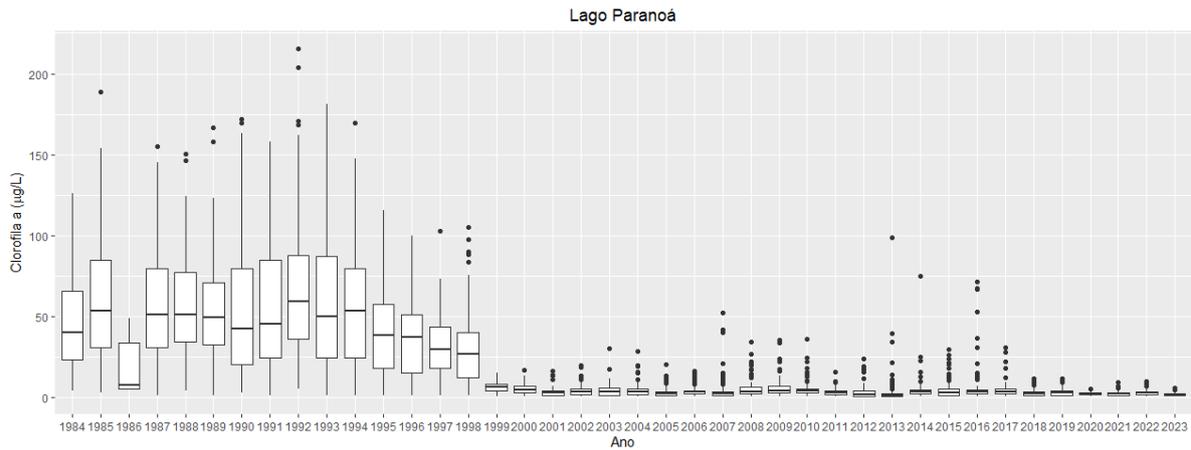


Figura 5.1 - Dados de concentração de clorofila-a do Lago Paranoá coletados pela CAESB

No reservatório do Descoberto, conforme mostra a Figura 5.2, é possível observar valores baixos de concentração de clorofila-a. Os maiores valores são observados em dezembro de 2006 e junho de 2019, onde foram observadas concentrações de  $16\mu\text{g/L}$ .

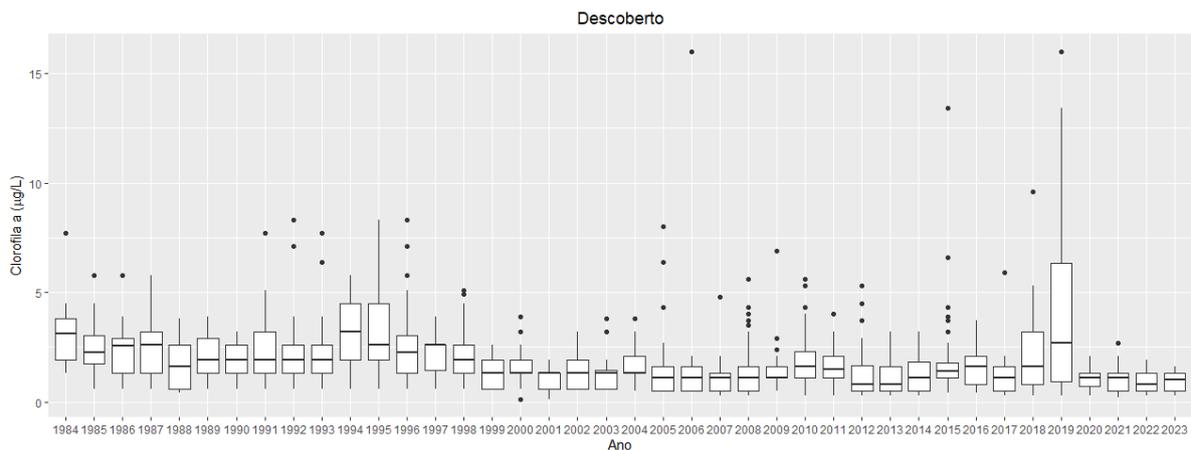


Figura 5.2 - Dados de concentração de clorofila-a do reservatório Descoberto coletados pela CAESB

No reservatório de Santa Maria, conforme mostra a Figura 5.3, também são observados baixos valores de concentração de clorofila-a. As faixas observadas vão de 0 a  $67,5\mu\text{g/L}$ , com um outlier de  $427,5\mu\text{g/L}$  em outubro de 2005. Ressalta-se que entre os anos de 2000 e 2002 não há dados de medições de clorofila-a fornecidos pela Companhia.

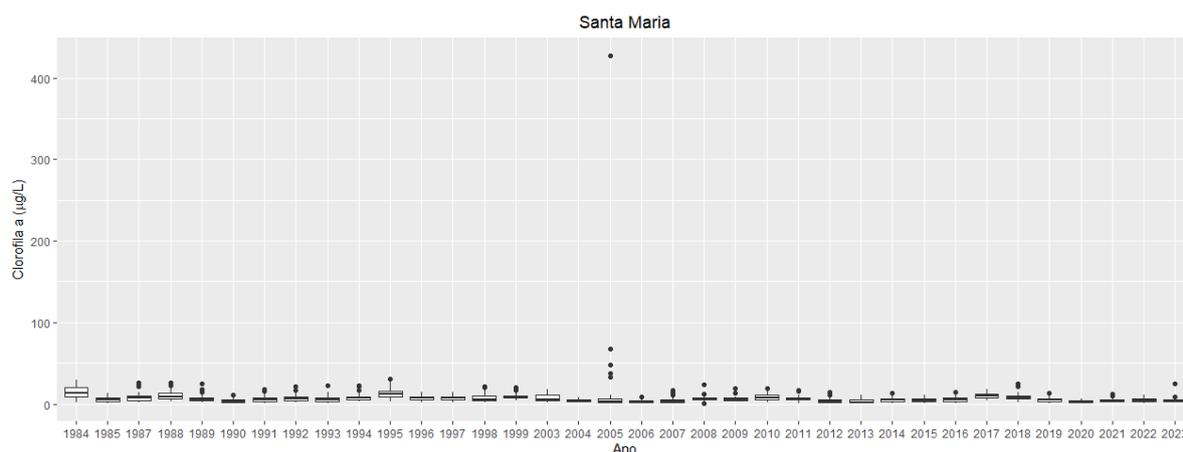


Figura 5.3 - Dados de concentração de clorofila-a do reservatório Santa Maria coletados pela CAESB

Dando sequência ao tratamento dos dados fornecidos pela CAESB, a próxima etapa é compatibilizar os dados de campo com as datas das imagens das missões Landsat. De todo o conjunto de dados disponibilizados pela Companhia, os referentes a 10 de janeiro de 1984 a 15 de junho de 2023 foram utilizados para a primeira etapa de compatibilização dos dados. Primeiramente, foram testadas as janelas de 0, 1, 2 e 3 dias de defasagem da data de campo da CAESB. A Tabela 5.2 mostra os resultados dessa compatibilização com as imagens.

Tabela 5.2 - Compatibilização das imagens Landsat com os dados de campo

<b>Defasagem (dias)</b>	<b>Número de amostras (n)</b>	<b>Concentração de clorofila-a (µg/L)</b>
0	279	0,30 – 119,30
1	694	0,30 – 119,30
2	1131	0,10 – 171,90
3	1491	0,10 – 171,90

Com o intuito de aprofundar o entendimento de como são as distribuições de amostras entre os reservatórios analisados, apresenta-se a Tabela 5.3 com a quantidade de amostras que foram compatíveis com as passagens dos sensores Landsat e os arranjos baseados nos dias de defasagem.

A partir dos dados apresentados na Tabela 5.3, foi realizada uma análise para identificar a ocorrência de chuvas que podem alterar o padrão da qualidade da água, para isso, foram selecionadas apenas as imagens dos dias que registravam precipitação igual a 0mm na base

de dados do INMET. Além disso, foi realizada uma análise da qualidade radiométrica das imagens, a análise foi feita de maneira visual e individualmente para cada imagem compatibilizada com os dados de campo, correspondendo ao total de 225 imagens Landsat analisadas.

Tabela 5.3 - Compatibilização das imagens Landsat discretizadas por reservatórios

<b>Defasagem (dias)</b>	<b>Lago Paranoá</b>		<b>Descoberto</b>		<b>Santa Maria</b>	
	n	Concentração ( $\mu\text{g/L}$ )	n	Concentração ( $\mu\text{g/L}$ )	n	Concentração ( $\mu\text{g/L}$ )
0	186	0,30 – 119,30	30	0,30 – 8,00	63	0,90 – 10,70
1	389	0,30 – 119,30	132	0,30 – 10,70	173	0,60 – 24,40
2	615	0,30 – 171,90	266	0,10 – 10,70	250	0,50 – 24,40
3	797	0,30 – 171,90	361	0,10 – 10,70	333	0,50 – 37,50

Ademais, foram disponibilizados pela Companhia dados de coleta com as profundidades: Superfície, 1 metro, 3 metros, 15 metros, 20 metros, e 1 metro de fundo. Para a análise procurou-se a padronização, e para isso, considerou-se apenas as amostragens de 1 metro da superfície, por estarem em maior número que as observações de superfície e por representar a zona eufótica detectável pelo sensoriamento remoto. Ao final das análises e filtros das amostras iniciais, foi possível obter as quantidades de imagens apresentadas na Tabela 5.4.

Tabela 5.4 - Compatibilização das imagens Landsat nos períodos de precipitação zero, sem a presença de nuvem nas imagens e coleta de 1m de profundidade

<b>Defasagem (dias)</b>	<b>Lago Paranoá</b>		<b>Descoberto</b>		<b>Santa Maria</b>	
	n	Concentração ( $\mu\text{g/L}$ )	n	Concentração ( $\mu\text{g/L}$ )	n	Concentração ( $\mu\text{g/L}$ )
0	55	0,50 – 74,80	2	0,50 – 3,20	9	1,50 – 9,60
1	96	0,50 – 74,80	13	0,50 – 5,30	23	1,10 – 12,80
2	141	0,50 – 75,70	28	0,30 – 5,30	30	0,50 – 12,80
3	204	0,50 – 138,60	37	0,30 – 5,30	36	0,50 – 12,80

Em relação ao agrupamento por satélite estudado, a Tabela 5.5 mostra os números de observações e os intervalos de concentrações de clorofila-a para cada satélite da missão Landsat estudada, aplicado o filtro final de qualidade da imagem e profundidade da coleta.

Nessa visualização, é possível observar uma equivalência do número de amostras analisados no conjunto do sensor TM e no conjunto dos sensores OLI e OLI-2.

Tabela 5.5 - Compatibilização das imagens Landsat nos períodos de precipitação zero, sem a presença de nuvem nas imagens e coleta de 1m de profundidade

Landsat	Lago Paranoá		Descoberto		Santa Maria	
	n	Concentração (µg/L)	n	Concentração (µg/L)	n	Concentração (µg/L)
5/TM	102	1,1 – 138,6	24	0,3 – 3,9	19	0,5 – 12,8
8/OLI	90	0,5 – 74,8	9	0,5 – 5,3	15	1,5 – 12,7
9/OLI-2	12	1,3 – 9,7	4	1,3 – 1,7	2	4,0 – 5,3
Todos	204	0,5 – 138,6	37	0,3 – 5,3	36	0,5 – 12,8

As análises prosseguiram com a janela de 3 dias, e a partir deste conjunto de dados, de 277 pares de amostra, foram aplicados testes de normalidade que atestaram a não normalidade dos dados de concentração de clorofila-a no conjunto a ser estudado. Para o primeiro teste de normalidade, o teste de Shapiro-Wilk foi encontrado um *p-value* de  $2,26e^{-16}$ , valor que rejeita a hipótese de normalidade dos dados de concentração de clorofila-a. O segundo teste de Kolmogorov-Smirnov também apresentou um valor p menor que 0,05 (*p-value*  $< 2,26e^{-16}$ ), atestando a não normalidade da distribuição dos dados. Uma maneira de investigar as possíveis causas da não normalidade dos dados é por meio da detecção de valores discrepantes (outliers) na amostra.

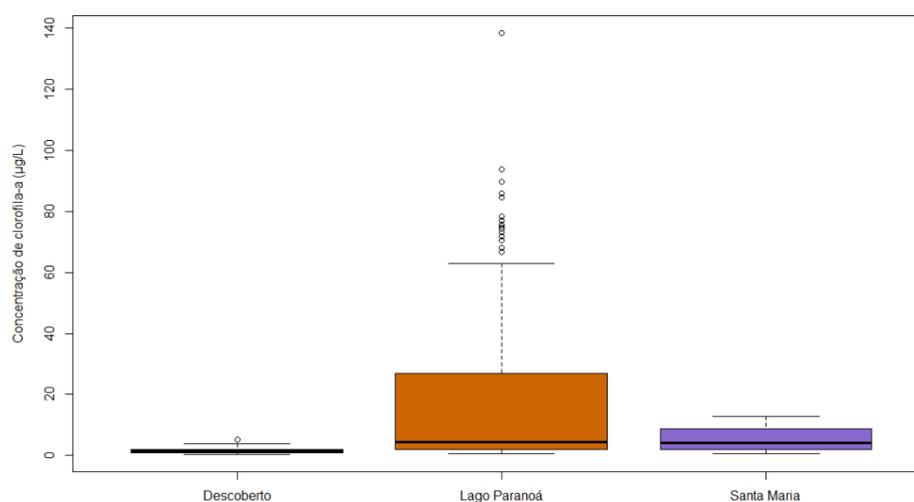


Figura 5.4 - Gráfico de caixa com a distribuição de concentração de clorofila-a nos reservatórios estudados

Para essa finalidade, utilizou-se um gráfico de caixa (*boxplot*) que permitiu identificar a possível existência de outliers nos 277 pares de dados a serem empregados no estudo. A Figura 5.4 ilustra o gráfico de distribuição das concentrações de clorofila-a nos reservatórios estudados.

Ao analisar o gráfico de caixa da Figura 5.4, observa-se um possível outlier na faixa de 130  $\mu\text{g/L}$  do Lago Paranoá. No entanto, é importante ressaltar que essa observação é referente ao ano de 1992 e, conforme indicado na Figura 5.1, o dado é condizente a distribuição das concentrações do ano, portanto, a sua classificação como outlier não é adequada. Desta forma, o valor máximo de observação do Lago Paranoá é condizente com o histórico de evolução da qualidade de água do Lago, devendo ser mantido na análise. Em seu estudo sobre a clorofila-a em reservatórios no cerrado, Barros (2021), optou por manter os valores discrepantes observados por entender que a ocorrência foi relativa a fenômenos comuns no ambiente estudado.

Em face a não normalidade dos dados, aplicou-se o teste não paramétrico de Kruskal-Wallis para identificar se os agrupamentos de reservatórios e satélites Landsat analisados apresentam diferença significativa entre si. As Figuras 5.5 e 5.6 mostram os resultados para cada agrupamento testado.

De acordo com o teste não paramétrico Kruskal-Wallis realizado para os agrupamentos de reservatórios e do conjunto agregado, foi constatada uma diferença significativa entre a distribuição dos dados do reservatório Descoberto ( $p < 0,05$ ) e os demais. Isso nos mostra que a distribuição das concentrações de clorofila-a medidas em campo para o Descoberto apresenta valores diferentes e inferiores em relação aos demais, indicando uma mediana de 1,30  $\mu\text{g/L}$  para este reservatório enquanto os outros apresentaram valores de mediana em torno de 4  $\mu\text{g/L}$ . O estudo de Souza (2018) apontou o reservatório como ultraoligotrófico, isto é, de baixa produtividade e com concentrações de clorofila-a nulos ou bem próximos de zero. Nesse estudo, como apontado anteriormente, foram excluídos 618 registros de concentrações nulas, sendo 378 delas (61,16%), referentes ao Descoberto. A medida foi adotada para contornar a dificuldade em se medir concentrações nulas por meio de sensoriamento remoto e permitir a definição de um modelo global para todos os reservatórios do DF. Ademais, o objetivo do trabalho é apoiar na definição de um modelo de monitoramento para todos os reservatórios do DF, desta forma, optou-se por manter os registros de concentração do Descoberto para o desenvolvimento de um modelo de predição regional de monitoramento.

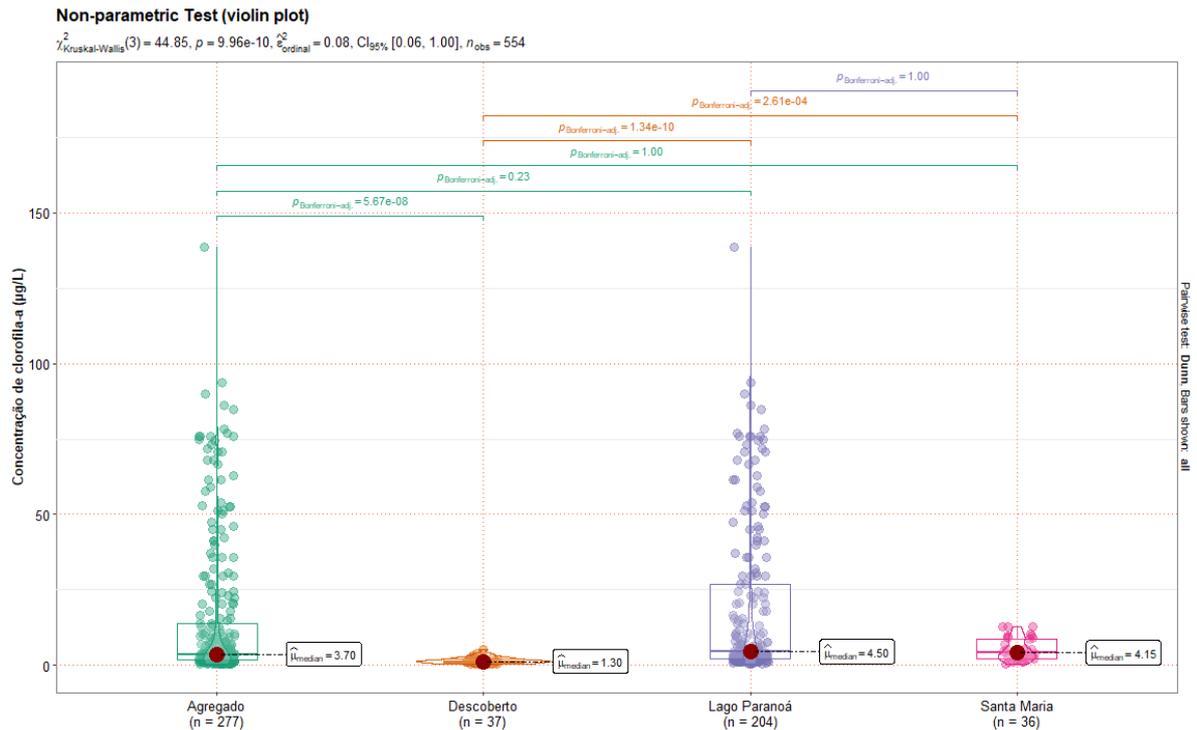


Figura 5.5 - Distribuição dos dados de clorofila-a e valores p do teste Kruskal-Wallis por agrupamentos: agregado, com todos os reservatórios, e individualmente para cada reservatório analisado.

No intuito de entender melhor a distribuição das concentrações entre os conjuntos de séries Landsat aplicadas ao trabalho, realizou o teste de Kruskal-Wallis entre os agrupamentos de satélites (Figura 5.6). Como resultado, observou-se uma diferença significativa ( $p < 0,05$ ) entre as concentrações de clorofila-a observadas durante o período da série histórica compreendida pelo Landsat 5 em relação aos demais. Isso demonstra a evolução do cenário de qualidade da água no território do DF, onde entre os anos 1984 e 2011, período analisado através do Landsat 5, as concentrações eram superiores em relação ao período posterior a 2013, ano inicial dos registros de clorofila-a analisados com por meio do Landsat 8 e 9. Ou seja, as condições limnológicas analisadas por esses satélites se diferem pelo período histórico analisado em cada um.

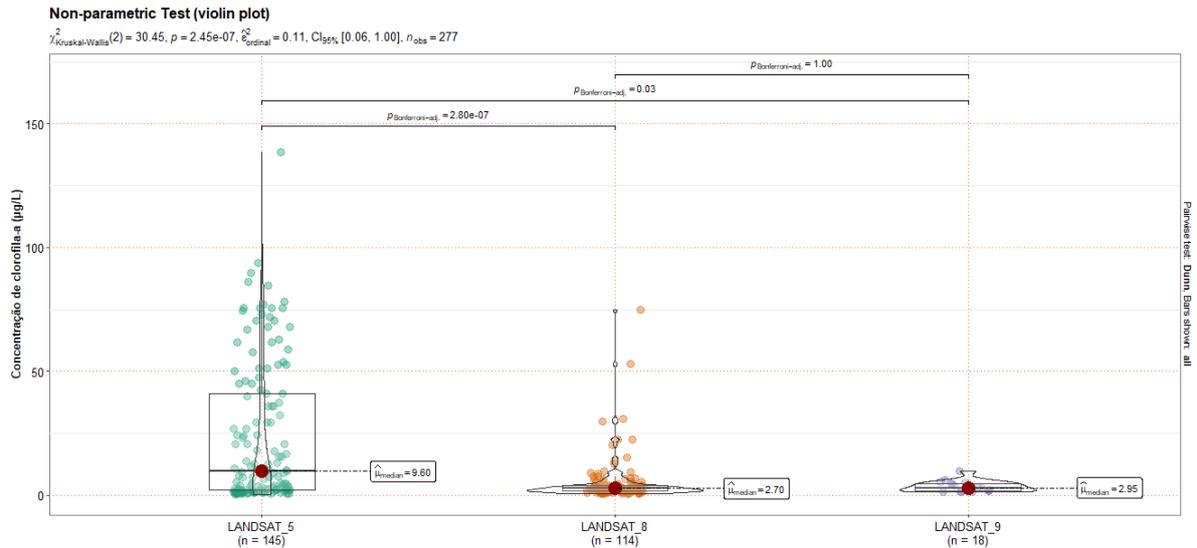


Figura 5.6 - Distribuição dos dados de clorofila-a e valores p do teste Kruskal-Wallis por sensores analisados na série histórica do estudo.

## 5.2 Análise dos dados de reflectância de superfície

Como produto do código implementado no GEE, obteve-se valores de reflectância de superfície para todas as bandas dos sensores Landsat 5 (TM) e Landsat 8 e 9 (OLI e OLI-2). Com o intuito de entender melhor as suas possíveis diferenças, plotou-se um gráfico onde são descritos os comprimentos de onda da faixa do visível, e que serão base para as aplicações dos modelos de clorofila-a. A Figura 5.7 ilustra o comportamento da curva de reflectância para cada um dos sensores estudados.

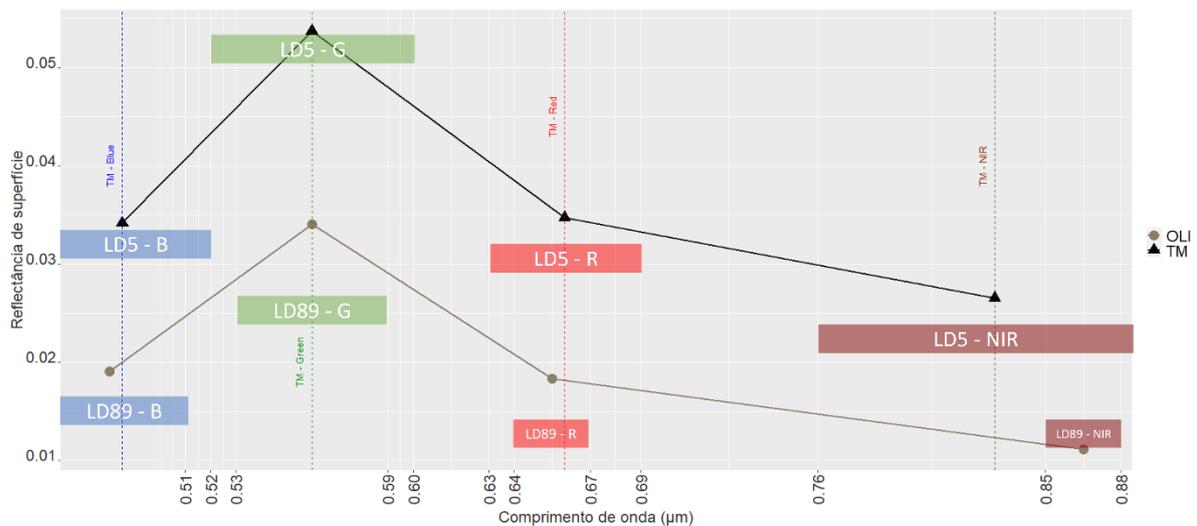


Figura 5.7 - Curva de reflectância média dos dados extraídos da plataforma GEE a partir do comprimento de onda central das bandas e intervalos das bandas espectrais de cada sensor

utilizado no estudo. Sendo, LD5: Landsat 5, LD89: Landsat 8 e 9, B: banda do azul, G: banda do verde, R: Banda do vermelho e NIR: banda do infravermelho

Fonte: Elaborado pela autora

Observa-se na Figura 5.7 que o sensor TM do satélite Landsat 5 obteve valores de reflectância média superiores aos sensores OLI do Landsat 8 e 9. Além disso, nota-se que os valores das quatro faixas espectrais representadas dos dois sensores estudados se diferenciam, sendo o Landsat 5 referente a faixas espectrais mais amplas em relação os satélites dos sensores OLI. Ressalva-se que além das quatro faixas espectrais ilustradas no gráfico, o sensor TM conta com mais três bandas espectrais e o sensor OLI com mais cinco bandas.

A resolução espectral descreve a capacidade de um sensor definir intervalos de comprimento de onda, e uma resolução espectral maior resulta em bandas espectrais mais estreitas. Além disso, geralmente a relação sinal-ruído tende a piorar com o estreitamento das bandas, entretanto, o processo de imageamento do sensor OLI, do tipo *pushbroom*, aprimorou a relação sinal-ruído nas imagens Landsat 8 (MISHRA et al., 2016). As bandas dos sensores OLI foram refinadas para evitar a absorção de componentes atmosféricos, e a maior mudança foi em relação a banda do infravermelho que foi reduzida para evitar a absorção do vapor d'água presente na atmosfera (IRONS; DWYER; BARSİ, 2012). Desta forma, uma possível influência nos valores maiores de reflectância no Landsat 5 são os componentes atmosféricos detectados nas faixas espectrais mais largas do sensor TM.

### **5.3 Avaliação dos modelos preditivos para estimativa de clorofila-a**

A partir do conjunto de dados demonstrados na Tabela 5.5, foram realizadas análises de regressões para identificar quais modelos são mais adequados para gerar a estimativa de clorofila-a a partir dos dados de reflectância de superfície e dos dados de campo da CAESB. Foram testadas as regressões nos ajustes linear, exponencial, logarítmico e polinomial, a Tabela 4.2 demonstra quais foram os modelos testados e as Tabelas 5.6, 5.7, 5.8 e 5.9, os resultados dos ajustes nas formas lineares. A demonstração apenas desse ajuste foi escolhida por representar grande parte dos melhores ajustes encontrados para os modelos, como também para simplificar a visualização dos resultados e identificar qual seria a abordagem mais apropriada para o estudo dos reservatórios do DF.

Em relação aos agrupamentos testados, os que relacionavam as concentrações de clorofila-a de campo e os consequentes estados tróficos acarretaram agrupamentos com poucas observações e que não se aplicariam a qualquer situação, visto que impõem uma restrição de

concentração de clorofila-a que pode dificultar sua aplicabilidade como ferramenta global de monitoramento. Posto isso, o agrupamento que melhor se adequou ao que se esperava para uma ferramenta de monitoramento aplicável ao cenário do Distrito Federal foi o referente aos sensores Landsat, um primeiro grupo para o sensor TM do Landsat 5 e outro para os sensores OLI e OLI-2 dos Landsat 8 e 9, respectivamente.

Tabela 5.6 - Resumo dos modelos de única banda aplicados e seus ajustes lineares. Agrupamento por todos os sensores testados, pelo Landsat 5 (TM) e pelos Landsat 8 e 9 (OLI e OLI-2)

	Modelo	Todos		Lago Paranoá		Descoberto		Santa Maria		
		R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	
Landsat 5, 8, 9	<i>Modelos de única banda</i>									
	B	0,0081	23,22	0,2058	23,06	0,0001	1,08	0,0359	3,62	
	G	0,1338	21,47	<b>0,4995</b>	<b>18,14</b>	0,0138	1,07	0,0027	3,60	
	R	0,1600	21,48	0,4821	18,68	0,0045	1,08	0,0030	3,66	
	NIR	<b>0,1847</b>	<b>22,49</b>	0,4622	20,01	0,0080	0,95	0,0487	3,65	
Landsat 5	<i>Modelos de única banda</i>									
	B	0,0622	27,16	0,0302	28,95	0,0716	1,02	0,1311	3,79	
	G	0,0577	27,18	0,4307	22,18	0,1074	1,00	0,0349	3,89	
	R	0,0692	27,13	0,4004	22,76	0,0609	1,03	0,0008	4,02	
	NIR	0,0925	26,67	<b>0,4400</b>	<b>21,99</b>	0,0007	1,06	0,0071	3,94	
Landsat 8 e 9	<i>Modelos de única banda</i>									
	B	4,96*10 <sup>-6</sup>	9,14	0,0099	10,20	0,0420	1,09	0,1431	2,95	
	G	0,0001	8,91	0,0377	9,77	0,0111	1,11	0,3099	2,61	
	R	0,0295	9,08	0,1769	9,41	0,0133	1,11	0,1659	2,91	
	NIR	0,0760	10,82	0,1499	11,56	0,2359	0,37	0,4144	2,28	

Primeiramente sobre os testes com modelos de banda única (Tabela 5.6), foi observada uma melhor performance das reflectâncias na região do vermelho e infravermelho para o agregado de reservatórios e sensores. Quando se observa o desempenho por reservatórios individualmente, a banda do verde também consegue ter uma melhor relação na predição da clorofila-a do Lago Paranoá. Esses valores de reflectância observados na região do vermelho levanta a hipótese de interferência de outros constituintes nas feições espectrais detectadas pelos sensores Landsat, visto que comumente é uma região de absorção dos organismos fitoplanctônicos e por isso, região de baixos valores de reflectância. As bandas do vermelho e infravermelho são comumente utilizadas em modelos de quantificação de sólidos suspensos totais (TSS), por conta do espalhamento nesses comprimentos de onda, em situações em que os SST são dominados por partículas algais, essa situação não é observada (BARBOSA; NOVO; MARTINS, 2019). Quanto a banda do azul, não se espera uma boa correlação por

conta da alta interferência dos sólidos suspensos e da matéria orgânica dissolvida nessa faixa espectral (YU; CAI; WU, 2003).

Machado e Baptista (2016) conseguiram índices de correlação superiores a 0,80 para cenas do Landsat 5 nos anos de 1984, 1994, 1997 e 2001 utilizando as bandas do verde e vermelho, sendo no ano de 1997 a banda do vermelho, aplicada de forma isolada, correspondeu ao índice de correlação de 0,97 com os dados de clorofila-a no Lago Paranoá, demonstrando a aplicabilidade da utilização dos sensores Landsat no estudo histórico do Lago Paranoá. Entretanto, entende-se a fragilidade de estimar a clorofila-a por análise de regressão simples a partir de uma única banda espectral, pois o método estimará qualquer valor ou variação da reflectância da água, sendo causado pela presença de clorofila-a ou por outros constituintes opticamente ativos presentes no ambiente aquático (GROSS, 2019).

Quanto aos resultados dos modelos de índices de razão de bandas, demonstrados nas Tabelas 5.7, 5.8 e 5.9, observa-se tendências semelhantes aos observados por bandas individuais. No agregado de todos os sensores da série Landsat (Tabela 5.7), dentre todos os modelos de índices testados, o modelo BRGI (BOCHAROV et al., 2017), que relaciona as bandas do azul, vermelho e verde, teve o melhor desempenho dentre os modelos testados para o conjunto de todos os sensores da série Landsat estudados.

Tabela 5.7 - Resumo dos modelos de índices e razões de bandas aplicados e seus ajustes lineares. Agrupamento para todos os sensores da série Landsat estudados (Landsat 5, 8 e 9)

	Todos		Lago Paranoá		Descoberto		Santa Maria		Referência	
	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE		
<b>Landsat 5, 8, 9</b>	<i>Modelos de índices</i>									
	GNDVI	0,1271	21,55	0,2136	22,74	0,0373	1,06	0,0006	3,61	(DAUGHTRY et al., 2000)
	NGRDI	0,0107	22,94	0,0105	25,51	0,0085	1,07	0,0008	3,61	(TUCKER, 1979)
	SLOPE	0,0178	22,86	0,1886	23,11	0,0254	1,07	0,0015	3,60	(MISHRA; MISHRA, 2010; WATANABE et al., 2018)
	BRGI	0,2695	19,71	0,2711	21,89	0,0179	1,07	0,0410	3,63	(BOCHAROV et al., 2017)
	TGI	0,2379	20,14	0,4972	18,18	0,0001	1,08	0,0070	3,59	(RAYMOND HUNT et al., 2011)
	SHAPE	0,0481	22,50	0,2841	21,69	0,0382	1,06	0,0402	3,53	(ESCADAFAL; BELGHITH; BEN MOUSSA, 1994)
	NDCI	0,0008	23,06	0,0006	25,64	0,0253	1,06	0,0157	3,58	(MISHRA; MISHRA, 2011)
	<i>Modelos de duas bandas</i>									
	R/G	0,1598	21,48	0,2245	22,86	0,0029	1,08	0,0002	3,66	(LE et al., 2013b)
	G/R	0,0385	22,98	0,0596	25,18	0,0525	1,05	0,0197	3,63	
	NIR/R	0,0042	24,88	0,0081	27,14	0,0471	0,93	0,0729	3,60	(GILERSON et al., 2010)
	R/NIR	0,0263	24,60	0,0434	26,66	0,0055	0,95	0,1857	3,38	
	G/B	0,0021	23,29	0,0046	25,82	0,0265	1,06	0,0203	3,65	(GORDON; MOREL, 1983)
B/G	0,0211	23,07	0,0070	25,79	0,0275	1,06	0,0344	3,62		
G/NIR	0,0031	24,87	0,0060	27,21	5*10 <sup>-5</sup>	0,95	0,1377	3,47	(NGUYEN; HA; PHAM, 2020)	
NIR/G	0,0598	24,15	0,1627	24,97	0,0040	0,95	0,171	3,71		
B/R	0,1154	21,99	0,1533	23,91	0,0212	1,07	0,0239	3,53	(GITELSON et al., 1996)	
R/B	0,2160	20,70	0,2335	22,75	0,0001	1,08	0,0075	3,56		

Outro modelo que teve um melhor desempenho é o TGI, que relaciona as bandas do infravermelho, do vermelho e do verde. Quanto aos demais resultados dos modelos baseados nos índices NDCI, GNDVI, NGRDI, SHAPE e SLOPE não foram satisfatórios. O NDCI, amplamente utilizado em estudos de estimativas de clorofila em reservatórios (AUGUSTO-SILVA et al., 2014; KISLIK et al., 2022; LOBO et al., 2021; WATANABE et al., 2018), apresentou coeficientes R<sup>2</sup> na ordem de 0,01. Os estudos apontam que o mau desempenho dos sensores Landsat em algoritmos que utilizam a relação NIR-R na estimativa de clorofila-a é por conta do posicionamento da banda do infravermelho depois da faixa de absorção de clorofila-a (~670nm) (BUMA; LEE, 2020).

O fato justifica também os piores resultados das razões de duas bandas NIR/R e R/NIR no estudo, visto que a banda do NIR no Landsat 5 é posicionada no comprimento de onda central 830nm no e no 865nm no Landsat 8 e 9. Além disso, a relação NIR-R obteve sucesso em águas turvas e com concentrações maiores de clorofila-a (GURLIN; GITELSON; MOSES, 2011; MISHRA; MISHRA, 2011), o que não é o caso dos reservatórios utilizados para abastecimento urbano no Distrito Federal.

Tabela 5.8 - Resumo dos modelos de índices e razões de bandas aplicados e seus ajustes lineares. Agrupamento para o sensor do Landsat 5.

	Modelo	Todos		Lago Paranoá		Descoberto		Santa Maria		Referência
		R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	
Landsat 5 (TM)	<i>Modelos de índices</i>									
	GNDVI	0,0001	28,00	0,0023	29,36	0,0127	1,05	0,0088	3,94	(DAUGHTRY et al., 2000)
	NGRDI	0,0087	27,88	0,0657	28,41	0,0328	1,04	1,6*10 <sup>-8</sup>	3,96	(TUCKER, 1979)
	SLOPE	0,0148	27,79	0,2200	25,96	0,0763	1,02	0,0348	3,89	(MISHRA; MISHRA, 2010; WATANABE et al., 2018)
	BRGI	0,4485	20,79	0,3840	23,07	0,0613	1,02	0,1347	3,68	(BOCHAROV et al., 2017)
	TGI	0,0872	26,75	0,3331	24,00	0,0013	1,06	0,0052	3,95	(RAYMOND HUNT et al., 2011)
	SHAPE	0,0634	27,09	0,3515	23,01	0,0722	1,02	0,0607	3,83	(ESCADAFAL; BELGHITH; BEN MOUSSA, 1994)
	NDCI	0,0099	27,86	0,0178	29,13	0,0489	1,03	0,0081	3,94	(MISHRA; MISHRA, 2011)
	<i>Modelos de duas bandas</i>									
	R/G	0,0610	27,25	0,0564	28,55	0,0268	1,05	0,0047	4,01	(LE et al., 2013b)
	G/R	0,0758	27,04	0,0795	28,20	0,0457	1,03	8,8*10 <sup>-6</sup>	4,02	
	NIR/R	0,0141	27,92	0,0181	23,13	0,0541	1,03	0,0039	4,01	(GILERSON et al., 2010)
	R/NIR	0,0015	28,10	0,0162	29,15	0,043	1,03	0,0025	4,02	
	G/B	0,1418	25,98	0,3455	23,78	0,0318	1,04	0,1018	3,85	(GORDON; MOREL, 1983)
	B/G	<b>0,4040</b>	<b>21,65</b>	0,4291	22,21	0,0331	1,04	0,1721	3,70	
G/NIR	0,0037	27,95	2*10 <sup>-5</sup>	29,39	0,0090	1,05	0,0160	3,93	(NGUYEN; HA; PHAM, 2020)	
NIR/G	3*10 <sup>-7</sup>	28,00	0,0062	29,60	0,0150	1,05	0,0034	3,95		
B/R	0,4401	21,00	0,4338	22,12	0,0870	1,01	0,0710	3,77		
R/B	0,3967	21,80	0,3022	24,55	0,0453	1,03	0,0732	3,76	(GITELSON et al., 1996)	

Em análise ao agregado do sensor TM do Landsat 5 (Tabela 5.8), o modelo BRGI, assim como no agregado de todos os sensores da série, também apresentou o melhor desempenho. Em

seguida, os modelos de razão de banda azul-verde (B/G) e azul-vermelha (B/R) também apresentaram melhores ajustes comparados aos demais. Como observado nos estudos e na literatura, a reflectância na banda do vermelho é associada a partículas não algais em suspensão (JENSEN, 2009), o que leva a interpretação errônea caso essa reflectância seja associada à biomassa algal, que tem a característica de absorção na região (BARBOSA; NOVO; MARTINS, 2019), e não de reflectância. Neste contexto, o modelo de melhor desempenho escolhido para as estimativas utilizando o Landsat 5 foi o que utilizou a relação azul e verde. Tal relação é reconhecida por apresentar bons ajustes para águas com baixas concentrações do pigmento e ruins para águas com elevada turbidez (KOLLURU et al., 2023; ODERMATT et al., 2012). O coeficiente R<sup>2</sup> para a relação foi de 40%, o maior observado em todos os ajustes lineares apresentados na Tabela 5.7.

Tabela 5.9 - Resumo dos modelos de índices e razões de bandas aplicados e seus ajustes lineares. Agrupamento para os sensores dos Landsat 8 e 9.

	Modelo	Todos		Lago Paranoá		Descoberto		Santa Maria		Referência
		R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	R <sup>2</sup>	RMSE	
Landsat 8 e 9 (OLI e OLI-2)	<i>Modelos de índices</i>									
	GNDVI	0,0939	8,48	0,1144	9,38	0,1929	1,005	0,0616	3,05	(DAUGHTRY et al., 2000)
	NGRDI	0,0058	8,88	0,0062	9,93	0,0939	1,065	0,1224	2,95	(TUCKER, 1979)
	SLOPE	0,1046	8,43	0,1954	8,94	0,0010	1,11	0,1618	2,88	(MISHRA; MISHRA, 2010; WATANABE et al., 2018)
	BRGI	0,1699	8,12	0,2191	8,80	0,0022	1,11	0,0201	3,11	(BOCHAROV et al., 2017)
	TGI	0,2228	7,85	0,3368	8,11	0,0249	1,10	0,0067	3,13	(RAYMOND HUNT et al., 2011)
	SHAPE	0,1462	8,23	0,1974	8,93	0,0110	1,11	0,0304	3,10	(ESCADAFAL; BELGHITH; BEN MOUSSA, 1994)
	NDCI	0,0020	8,90	0,0017	9,96	0,0688	1,07	0,0319	3,09	(MISHRA; MISHRA, 2011)
	<i>Modelos de duas bandas</i>									
	R/G	<b>0,2035</b>	<b>8,23</b>	0,2851	8,76	0,0567	1,08	0,1305	2,97	(LE et al., 2013b)
	G/R	0,0220	9,12	0,0304	10,21	0,2474	0,97	0,1326	2,97	
	NIR/R	0,0120	11,07	0,0154	12,36	0,6196	0,26	0,3488	2,42	(GILERSON et al., 2010)
	R/NIR	0,0050	11,11	0,0072	12,41	0,5942	0,27	0,676	1,71	
	G/B	0,0015	9,13	0,0019	10,24	0,0832	1,07	0,0845	3,05	(GORDON; MOREL, 1983)
B/G	7*10 <sup>-5</sup>	9,14	0,0001	10,25	0,0827	1,07	0,0821	3,05		
G/NIR	0,0033	11,24	0,0045	12,51	0,3011	0,35	0,5996	1,88	(NGUYEN; HA; PHAM, 2020)	
NIR/G	0,1125	8,39	0,1301	11,69	0,5313	0,29	0,4076	2,29		
B/R	0,0548	8,94	0,710	3,03	0,0004	1,11	0,0710	3,03	(GITELSON et al., 1996)	
R/B	0,1941	8,25	0,2889	8,76	0,0051	1,11	0,0006	3,14		

Para o Landsat 8 e 9, o melhor desempenho foi observado na razão do vermelho e verde, com um coeficiente de determinação R<sup>2</sup> 0,20 e um menor RMSE em relação aos observados para o Landsat 5. Apesar da região do vermelho responder a outros componentes, como sólidos suspensos totais, essa relação apresentou uma melhor performance dentre os ajustes testados, o que levanta a necessidade de aprofundar o entendimento quanto a influência das partículas não algais nesse resultado da janela temporal analisada pelo Landsat 8 e 9 (2013 a 2023). Em

acrécimo às questões levantadas, existem estudos que utilizam a razão vermelho e verde para a estimativa de clorofila-a através de sensores que não possuem a banda do infravermelho na faixa de menor absorção de clorofila-a (HA et al., 2017b ). Além disso, a utilização de um único sensor é dificilmente adequado para os estudos de série histórica de estimativa de clorofila-a, por conta das coberturas de nuvens e das limitações de tempo de operação (WANG; CHEN, 2024), o que incumbe um maior desafio em compatibilizar os modelos aos diversos sensores utilizados no estudo.

Baseado no desempenho dos ajustes lineares dos modelos testados, apresentados nas Tabelas 5.7, 5.8 e 5.9, e no comportamento das concentrações de clorofila-a ao longo da série histórica analisada no estudo, adotou-se um modelo para o Landsat 5 e outro para os Landsat 8 e 9. Para o Landsat 5, a razão de banda a ser utilizada no modelo preditivo foi a do azul com o verde (B/G), e para o Landsat 8 e 9, a do vermelho e do verde (R/G). As equações abaixo relacionam as razões de bandas escolhidas para os modelos com os comprimentos de onda central para cada satélite usado.

$$\frac{B}{G} = R_{RS}(485nm) / R_{RS}(560nm) \qquad \frac{R}{G} = R_{RS}(655nm) / R_{RS}(560nm)$$

## 5.4 Modelo preditivo de clorofila-a

### 5.4.1 Landsat 5

Para o Landsat 5, inicialmente, foram considerados 145 pares de dados de campo e reflectância B/G, nestes, foram testados os ajustes de regressão linear, exponencial, polinomial e logaritmo, durante esta investigação, também foram detectadas observações que se encontravam fora do intervalo de confiança. A Tabela 5.8 mostra um resumo com os valores dos coeficientes de determinação para cada ajuste testado nos dados referentes ao Landsat 5.

Tabela 5.10 - Ajustes testados para os dados referentes ao Landsat 5

Ajuste	R <sup>2</sup>
Polinomial	0,65
Exponencial	0,60
Linear	0,51
Logarítmico	0,58

Durante a análise do comportamento dos dados foi possível observar um melhor desempenho do ajuste polinomial, além disso, foi detectado 4 pontos amostrais que apresentavam um comportamento fora do intervalo de confiança do ajuste polinomial. Posto isso, 141 observações referentes ao Landsat 5, compreendendo a janela temporal de 29/05/1986 a 12/09/2011 foram ajustadas em um modelo polinomial. A Figura 5.8 mostra o comportamento do ajuste polinomial realizado para os dados Landsat 5.

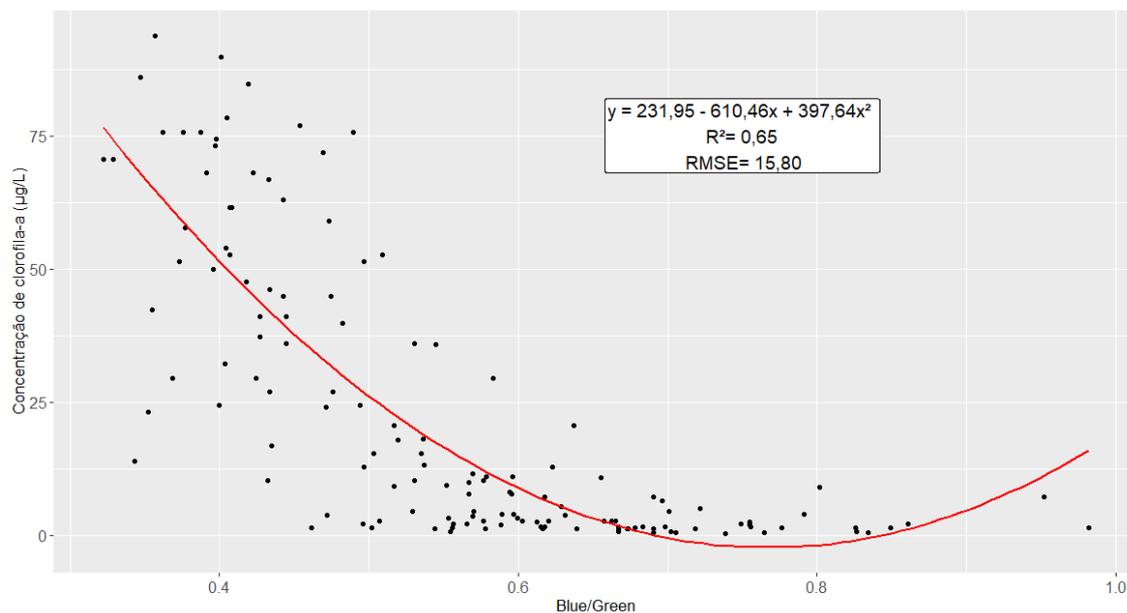


Figura 5.8 - Ajuste polinomial para os dados de clorofila-a com a razão B/G do Landsat 5 para 141 pontos amostrais

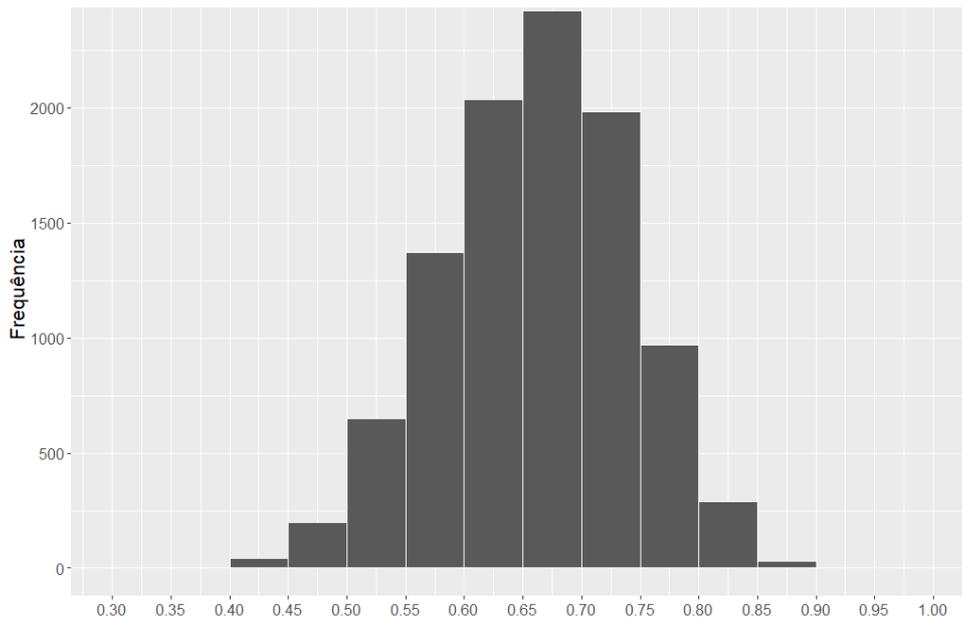


Figura 5.9 - Histograma da distribuição do R<sup>2</sup> nas 10.000 iterações do método Monte Carlo para o modelo azul-verde

Selecionado o ajuste polinomial para a análise do Landsat 5, aplicou-se o método de validação cruzada Monte Carlo para um aperfeiçoamento do modelo preditivo. O método de validação cruzada utilizou 70% das amostras para o treinamento do modelo e 30% para o teste do modelo em 10.000 iterações. A Figura 5.9 ilustra o histograma da distribuição do coeficiente de determinação R<sup>2</sup> para o modelo B/G.

A partir do histograma da Figura 5.9 é possível observar uma maior ocorrência das iterações do método Monte Carlo no intervalo de R<sup>2</sup> de 0,65 a 0,70. Desta forma, selecionou-se equações dentro desse intervalo com menores RMSE para definir a equação mais adequada para o modelo preditivo de clorofila-a.

A equação do modelo selecionada apresentou um ajuste R<sup>2</sup> de 0,69 e um RMSE de 12,88 µg/L. A Figura 5.10 demonstra o comportamento polinomial dos ajustes utilizados antes da aplicação do método Monte Carlo e depois da aplicação do método. Baseado no melhor desempenho da equação do método, segue a equação do modelo preditivo de clorofila-a nos reservatórios do Distrito Federal selecionada para a série do Landsat 5.

$$Chl - a = 203,61 - 511,22 \times (B/G) + 318,68 \times (B/G)^2$$

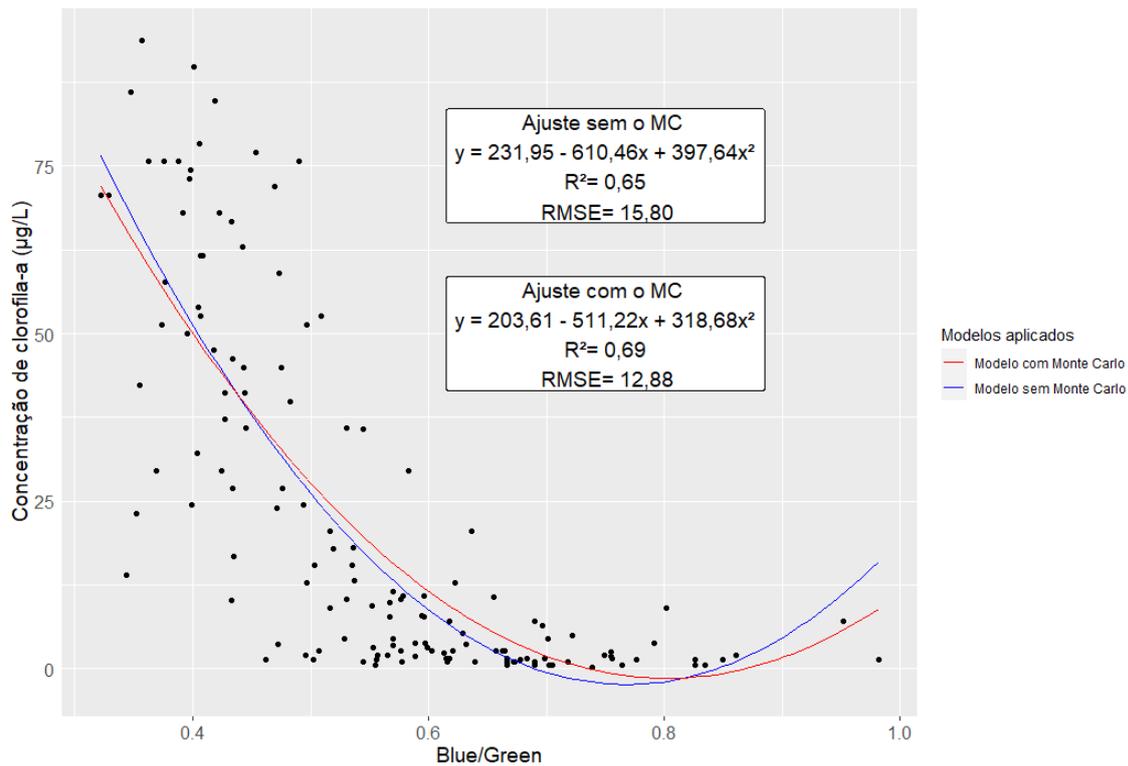


Figura 5.10 - Performance do modelo B/G com e sem o ajuste do método Monte Carlo (MC)

Dentre os estudos descritos na Tabela 5.9 que utilizaram a razão B/G para estimativa de clorofila-a em lagos e reservatórios, este, referente aos reservatórios do Distrito Federal foi o que utilizou um maior número de pontos de observação para a estimativa do modelo. Com ajuste de regressão similar, Witter et al. (2009), aplicou o modelo para águas com baixas concentrações de clorofila-a, reforçando que a razão B/G pode ser aplicada para a estimativa de clorofila-a nos reservatórios do Distrito Federal, onde há a predominância de baixas concentrações. Chu et al. (2021) também aplicou o modelo para baixas concentrações e teve um desempenho satisfatório da razão de bandas do azul e verde em comparação às demais testadas no estudo. Outro estudo que apresentou um bom desempenho com a razão, mas com número de observações inferiores, foi o estudo de Ha et al. (2017a), que apresentou a aplicabilidade do modelo para concentrações superiores de clorofila-a em águas com índices baixos de matéria orgânica.

Para o estudo, a posição das bandas nos comprimentos de ondas centrais do azul no 485 e do verde no 560nm responderam melhor ao primeiro período de análise dos dados de concentração de clorofila-a dos reservatórios. Os estudos mostram que a razão das bandas azul e verde apresenta resultados satisfatórios em concentrações baixas de clorofila-a (ODERMATT et al., 2012), porém, entende-se que a faixa espectral apresenta uma maior

interferência da resposta da matéria orgânica dissolvida, à reflectância de fundo e uma maior vulnerabilidade às interferências atmosféricas, possibilitando uma superestimação da quantidade de clorofila-a medida (CHUSNAH; CHU, 2022; GILERSON et al., 2010; MENON; ADHIKARI, 2018).

Tabela 5.11 - Tabela comparativa dos estudos que utilizaram a razão de bandas B/G para estimativa de clorofila-a

	Local de estudo	Satélite utilizado	Concentrações de chl-a ( $\mu\text{g/L}$ )	Nº de pares	Ajuste	R <sup>2</sup>	RMSE
Este estudo	Reservatórios do Distrito Federal (BR)	Landsat 5 TM	0,3 a 93,7	141	Polinomial	0,69	12,88
Witter et al. (2009)	Lago Erie (EUA)	SeaWiFS	Abaixo de 20	68	Logarítmico	0,69	1,64
Chu et al. (2021)	3 reservatórios em Taiwan	Sentinel-2	Abaixo de 5	14	Linear	-	4,59
Ha et al. (2017)	Lago West (Vietnã)	Landsat 8/OLI	42 - 252	19	Exponencial	0,88	3,89

#### 5.4.2 Landsat 8 e 9

De forma semelhante ao realizado para o Landsat 5, a escolha do modelo para os satélites Landsat 8 e 9 se iniciou com a observação do comportamento dos dados para a escolha do ajuste mais adequado. A Tabela 5.10 mostra os valores dos ajustes testados para os dados dos Landsat 8 e 9 e durante esta investigação, também foram detectadas observações que se encontravam fora do intervalo de confiança. Durante a análise, foram desconsiderados 16 valores de reflectância negativos, restando 116 para o ajuste do modelo R/G dos sensores OLI.

Tabela 5.12 - Ajustes testados para os dados referentes aos Landsat 8 e 9

Ajuste	R <sup>2</sup>
Polinomial	0,58
Exponencial	0,45
Linear	0,27
Logarítmico	0,11

O melhor ajuste observado também foi o polinomial para o período de 11/06/2013 a 05/06/2023, onde obteve-se coeficientes de determinação R<sup>2</sup> de 0,58, superior ao analisado previamente no ajuste linear dos dados. Além disso, o RMSE também apresentou uma

melhora, alcançando o valor de 6,07  $\mu\text{g/L}$ . A Figura 5.11 mostra o comportamento exponencial dos dados ajustados para a razão R/G.

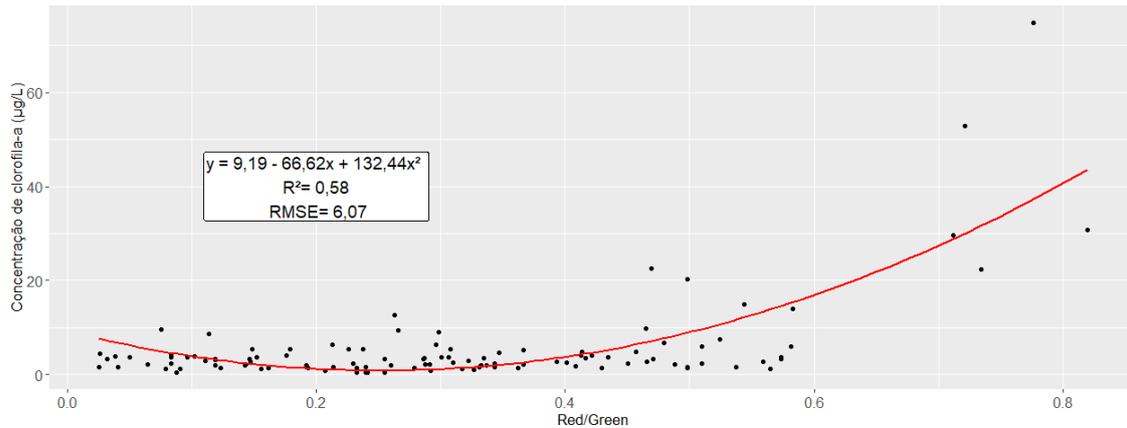


Figura 5.11 - Ajuste polinomial para os dados de clorofila-a com a razão R/G do Landsat 8 e

9

Os resultados do método Monte Carlo para esse segundo cenário do estudo com os dados dos sensores mais recentes, foram menos satisfatórios e apresentaram uma distribuição de  $R^2$  com uma parte considerável dos dados na primeira faixa do histograma, como mostra a Figura 5.12. Ainda assim, a maior ocorrência dos  $R^2$  observados nas 10.000 iterações do Monte Carlo se concentrou na faixa de 0,65 a 0,70. Visto isso, as equações dentro desse intervalo foram testadas da mesma maneira realizada para o Landsat 5.

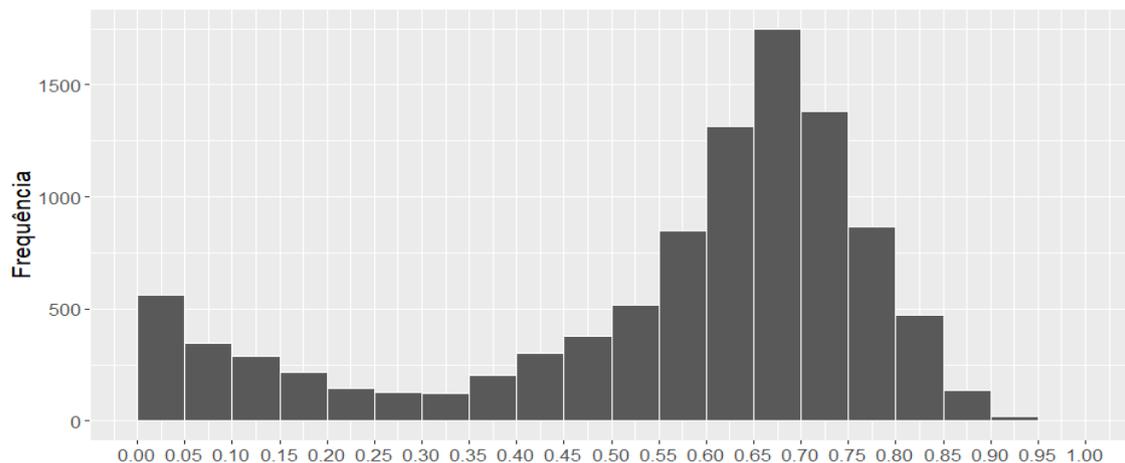


Figura 5.12 - Histograma da distribuição do  $R^2$  nas 10.000 iterações do método Monte Carlo para o modelo preditivos com a razão R/G

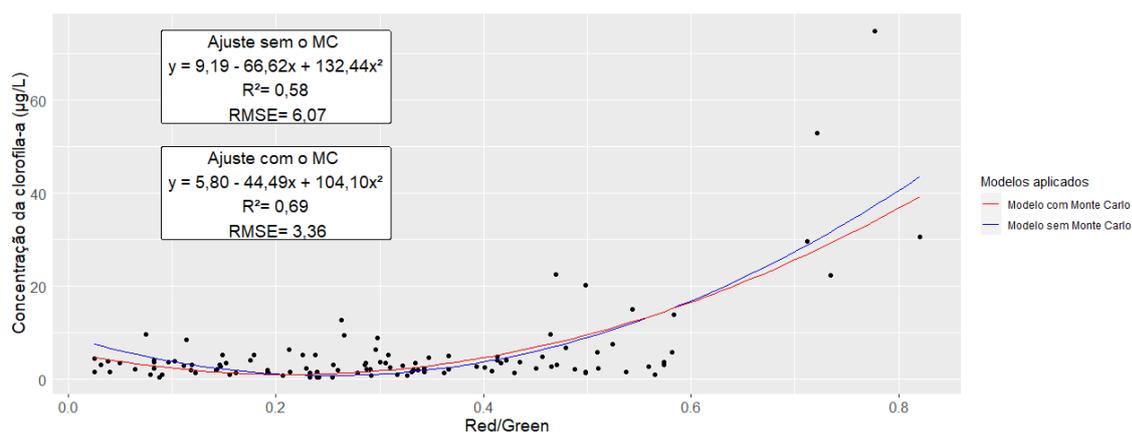


Figura 5.13 - Performance do modelo R/G com e sem o ajuste do método Monte Carlo (MC)

Realizados os testes para a escolha da melhor equação, foi determinada a seguinte equação para o modelo R/G. A equação aplicada aos dados de reflectância apresentou um ajuste  $R^2$  de 0,69 com os dados medidos em campo pela CAESB.

$$Chl - a = 5,80 - 44,49 \times (R/G) + 104,10 \times (R/G)^2$$

Tabela 5.13 - Tabela comparativa dos estudos que utilizaram as bandas vermelho e verde para estimativa de clorofila-a

	Local de estudo	Satélite utilizado	Concentrações de chl-a (µg/L)	Nº de pares	Ajuste	R <sup>2</sup>	RMSE
Este estudo	Reservatórios do Distrito Federal (BR)	Landsat 8 e 9	0,5 a 74,8	116	Polinomial	0,69	3,36
Ha et al. (2017b)	Lago Ba Be (Vietnã)	Sentinel-2A	1,58 - 6	30	Exponencial	0,68	0,14
Le et al. (2013a)	Baía Chesapeake (EUA)	MODIS	7,37 - 54,33	1079	Logarítmica	0,43	
Chu et al. (2021)	6 reservatórios em Taiwan	Sentinel-2	0 - 120	25	Linear	-	12,56
Oliveira et al. (2016)	Baía de Guanabara - RJ (BR)	MERIS	1,0 - 351,5	162	Exponencial	0,71	34,48

Por meio de outros sensores, os estudos de Ha et al. (2017b) e Oliveira et al. (2016) apresentaram coeficientes semelhantes a este estudo. Ha et al. (2017b) utilizou o Sentinel-2A que possui uma resolução espacial maior do que comparada aos sensores Landsat, em

contrapartida, o estudo analisou um menor número de pares, o que pode ter colaborado para ajustes melhores da equação do modelo.

Em estudos de águas costeiras consideradas complexas, Le et al. (2013a) utilizaram um grande número de pares para construir um modelo de predição para a Baía de Chesapeake nos Estados Unidos, de 1997 a 2011, o primeiro modelo inicial que obteve a performance de 0,43 de coeficiente de correlação foi calibrado regionalmente. Oliveira et al. (2016) obtiveram bons resultados com a razão, utilizando um número considerável de observações, em um ambiente submetido à grandes pressões antrópicas, como despejos de efluentes domésticos e industriais, que aumentam a complexidade da predição de clorofila-a. Compreende-se que esses ambientes costeiros apresentam mais características de ambientes lóticos do que lênticos, culminando em tempos menores de residência da água e favorecendo a ocorrência de concentrações baixas de clorofila-a em alguns pontos de amostragem, o que pode ser associada a aplicabilidade da razão de bandas selecionada à ambientes lênticos com a variabilidade de concentrações encontradas nos reservatórios do DF.

A utilização das bandas do vermelho e verde na estimativa de clorofila-a apresenta a vantagem de sofrer menos influência da matéria orgânica dissolvida na resposta espectral (GURLIN; GITELSON; MOSES, 2011). Para baixas concentrações de clorofila-a, em que a feição de espalhamento em 705nm não é pronunciada, é comumente utilizada a feição da banda do verde, em que a absorção pelo pigmento é relativamente menor que na região espectral do azul e vermelho (BARBOSA; NOVO; MARTINS, 2019). E nesse presente estudo, apesar das baixas concentrações de clorofila-a avaliadas, a razão de estimativa empírica foi a que melhor correspondeu às variações de clorofila-a nos anos posteriores a 2013.

Por ser o mais atual e possibilitar a validação com novos dados de campo, o modelo R/G foi validado com novos dados de concentração de clorofila-a fornecidos pela CAESB. Ao total, foram utilizados cinco pares de dados independentes para a validação do modelo da razão vermelha e verde, os dados utilizados estão apresentados na Tabela 5.12. O quantitativo reduzido para validação resultou-se da priorização de mais amostras para o desenvolvimento do modelo, entretanto, ressalva-se que a validação pode ser enriquecida com novos dados da CAESB, coletados em períodos posteriores aos empregados neste estudo.

Em análise aos dados calculados pelo modelo, é possível observar que o modelo preditivo dos últimos sensores da série Landsat superestima as concentrações mais baixas de clorofila-a, enquanto para as maiores que 4 µg/L é observado uma diferença menor entre o real e o

modelado. Ressalta-se que cinco observações para a validação do modelo é uma baixa representatividade da eficácia do modelo, mas ainda assim, consegue-se observar a potencialidade do modelo em estimar as variações de clorofila-a, que mesmo não sendo precisa, consegue identificar pontos de maiores e menores concentrações.

Tabela 5.14 - Dados dos pontos utilizados para a validação dos dados de clorofila-a do modelo R/G para todos os reservatórios

<b>Reservatório</b>	<b>Ponto</b>	<b>Clorofila-a</b> ( $\mu\text{g/L}$ )	<b>Clorofila-a modelo</b> <b>R/G</b> ( $\mu\text{g/L}$ )
Descoberto	A	1,3	2,74
Descoberto	A	0,5	3,36
Lago Paranoá	A4	5,7	4,92
Lago Paranoá	A5	3,4	12,95
Santa Maria	A	4,6	5,52

Como resultado da validação com cinco valores independentes de amostra de clorofila-a referentes ao período de junho a outubro de 2023, obteve-se os seguintes resultados das métricas estatísticas demonstradas na Tabela 5.13.

Tabela 5.15 - Resultados da métricas da validação do modelo R/G para os Landsat 8 e 9

<b>Métrica</b>	<b>Resultado</b>
RMSE ( $\mu\text{g/L}$ )	4,53
NRMSE (%)	87,28
Bias ( $\mu\text{g/L}$ )	-2,80

As métricas estatísticas apresentados na Tabela 5.13 evidenciam a fragilidade do modelo em estimar concentrações baixas de clorofila-a. Uma baixa exatidão resulta de erros sistemáticos que contribuem para desvios ou tendências (bias) nos resultados. Em relação aos outros estudos que estimaram clorofila-a para reservatório com baixas concentrações, o RMSE obtido pelo modelo de melhor desempenho no estudo de Borges et al. (2020) no Lago Paranoá foi de 4.63  $\mu\text{g/L}$ , similar a validação dos dados deste estudo. Em relação a esse valor, os autores reiteraram que foi satisfatório devido a quantidade significativa de concentrações baixas de clorofila-a no estudo.

Com o intuito de integrar os sensores da série Landsat para a estimativa de clorofila-a em reservatórios Bonansea, Rodriguez e Pinotti (2018), elaboraram um modelo multilinear para

a predição de clorofila-a no reservatório Rio Tercero, na Argentina. Os autores utilizaram seis datas de 2006 a 2016 para combinar as imagens e as medições em campo, onde as concentrações variaram de 1,1 a 299,0  $\mu\text{g/L}$ , e como resultado o modelo apresentou um ajuste  $R^2 = 0,89$  e um RMSE = 18.47  $\mu\text{g/L}$ , maior do que os observados para os dois modelos propostos e na validação com dados independentes nesse presente estudo. Entretanto, como resultado, os autores enfatizam a necessidade de um estudo com um maior número de observações utilizando os sensores Landsat mais antigos para entender o comportamento histórico e os sensores OLI para ser utilizado nas predições, com a possibilidade de acréscimo de dados recentes para uma melhor calibração do modelo. O presente estudo empregou ainda observações do recém-lançado Landsat 9, evidenciando a potencialidade de utilização dos últimos sensores da série Landsat para estimativa futuras de clorofila-a.

### **5.5 Mapas de distribuição espacial da clorofila-a**

A partir dos modelos preditivos escolhidos para a série Landsat, foram elaborados mapas que mostram a evolução da distribuição espacial da clorofila-a nos reservatórios entre os anos 1985 e 2023 e para isso, foram consideradas imagens dos meses de julho e agosto com o intuito de produzir imagens com a menor interferência de nuvens possível. As Figuras 5.14, 5.15 e 5.16 mostram a espacialização da concentração de clorofila-a para o Lago Paranoá, Descoberto e Santa Maria, respectivamente.

Através do mapa de distribuição de clorofila-a no Lago Paranoá é possível notar um cenário eutrófico em quase toda a totalidade do manancial antes do ano 1995, e um comportamento de concentrações descendente após 1995. Cavalcanti et al. (1997) mostram a diminuição das cargas de nutrientes do lago no início década de 90 com a implementação do tratamento terciários nas estações de tratamento de esgoto, entretanto, os autores mostram que as concentrações de clorofila-a ainda eram altas no ano de 1994. Angelini, Bini e Starling (2008) observaram através de medições no Lago Paranoá, um comportamento de diminuição da clorofila-a após o ano de 1995, e segundo os autores, o é referente ao período em que as estações de tratamento de esgoto começaram a operar adequadamente, após treinamento da equipe operacional da ETE. Padovesi-Fonseca, Philomeno e Andreoni-Batista (2009) destacam que a manobra operacional do *flushing* no final de 1998 provocou uma significativa melhora na qualidade da água, como a diminuição de clorofila-a e uma mudança nas espécies fitoplanctônicas dominantes.

A partir do ano 2000 observa-se uma tendência de diminuição da clorofila-a no Lago Paranoá. No ano 2015 é possível notar um aumento na quantidade de clorofila-a predita pelo modelo na região do braço do Riacho Fundo, região em que se localiza a Estação de Tratamento de Esgoto Sul de Brasília (ETE-Sul). O ano de 2015 é coincidente ao primeiro ano da crise hídrica enfrentada pelo Distrito Federal (ADASA et al., 2018) e no ano posterior foi noticiada a ocorrência de florações de cianobactérias que implicaram na suspensão de atividades na região do Lago Paranoá (COLLISCHONN; VALTER; DE MELO, 2021). Nos anos subsequentes, 2020 e 2023, observa-se uma maior resposta da concentração de clorofila-a na região do braço do Riacho Fundo.

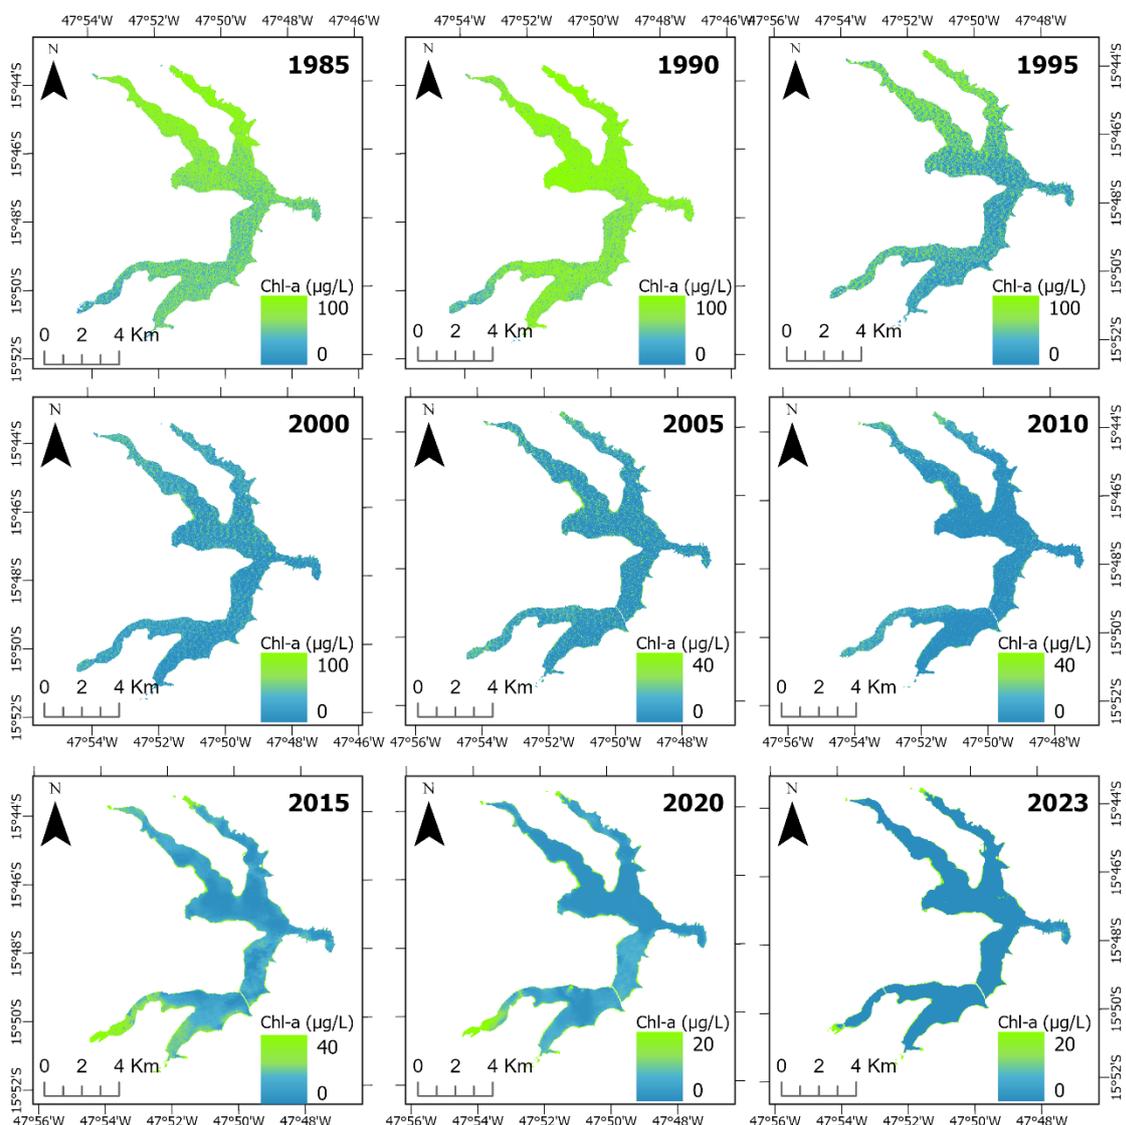


Figura 5.14 - Distribuição espacial de clorofila-a no Lago Paranoá de acordo com os modelos preditivos do estudo

Além disso, nota-se uma maior concentração no braço do Bananal também, representada na parte norte, influenciada pelas obras do Noroeste. O estudo de (MENEZES, 2010) demonstrou que as áreas do braço do Riacho Fundo e do Bananal sofreram com o processo de assoreamento, mesmo possuindo características distintas, onde a primeira sofre mais influência das ações antrópicas de urbanização. O acúmulo de sedimentos na região das bordas do reservatório pode ter contribuído para a resposta espectral observada no modelo que utiliza a banda do vermelho para a predição de clorofila-a, região do espectro visível comumente utilizada para estimativa de sólidos em suspensão (BARBOSA; NOVO; MARTINS, 2019), entretanto, podem alertar para possíveis ocorrências de florações de cianobactérias junto aos processos de acúmulos de sedimentos.

Em relação a sazonalidade, Leite Costa e Koide (2013) concluíram que as cargas de poluição difusa oriundas do sistema de drenagem na Asa Norte nos meses de novembro e janeiro podem ser mais significativas do que a cargas lançadas pelo efluente tratado da ETE que recebe o esgoto doméstico desse bairro e se localiza próxima a região. Da Silva et al. (2021) observou entre os anos de 2016 e 2017, uma maior concentração espacial de clorofila-a no braço do Bananal, na porção norte do Lago Paranoá. Tais fatos chamam a atenção às diferentes pressões que as regiões do Lago Paranoá sofrem, e as como as mudanças de sazonalidade afetam a dinâmica das concentrações de seus constituintes, levantando a necessidade de um maior apoio em termos de ferramentas para o monitoramento dessas áreas.

Quanto a distribuição espacial no reservatório Descoberto (Figura 5.15), responsável por abastecer a maior parte do DF, pode-se notar uma maior concentração de clorofila-a na parte norte do reservatório durante os anos representados nos mapas. A região é próxima a Brazlândia, região conhecida pela produção de hortifrutigranjeiros (CODEPLAN, 2022) que pode impactar a carga de nutrientes incidente no reservatório. O Rio Descoberto é afluente do reservatório no braço norte, região evidenciada nas figuras com maior concentração de clorofila-a, Chelotti et al. (2019) identificaram uma maior variação de sólidos suspensos nessa região do reservatório através de sensoriamento remoto e segundo Relatório (GDF, 2009), a qualidade da água captada pela ETA Descoberto vem caindo continuamente, demonstrando um aumento constante da degradação ambiental com aumento no percentual de lodo e da turbidez da água.

Ainda em relação a distribuição espacial no reservatório Descoberto, é possível observar uma alta concentração da clorofila-a no ano de 2015, primeiro ano da crise hídrica do DF na qual

o reservatório atingiu 5,3% do seu volume útil (ADASA et al., 2018). Monsalve-Herrera (2018) destaca em seu estudo que a região vem sendo impactada pela diminuição da precipitação, o uso desordenado do solo, dentre outras problemáticas que afetam a disponibilidade do recurso hídrico local. Além disso, é possível notar a interferência da borda na resposta espectral ilustrada nos mapas, um problema nos estudos de corpos hídricos rasos (BARBOSA; NOVO; MARTINS, 2019).

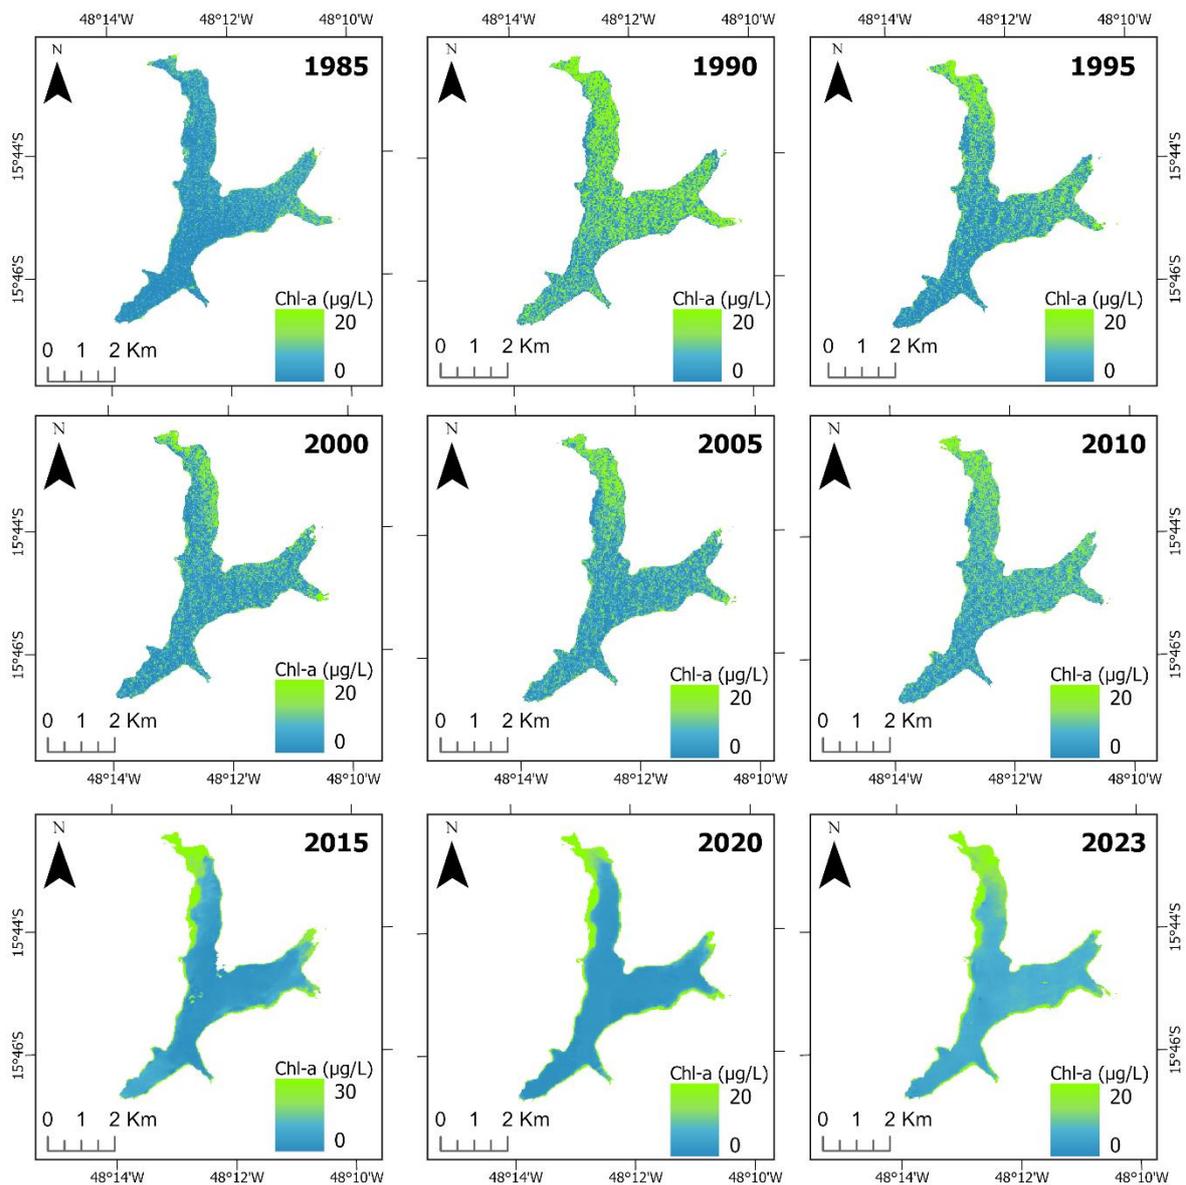


Figura 5.15 - Distribuição espacial de clorofila-a no reservatório Descoberto de acordo com os modelos preditivos do estudo

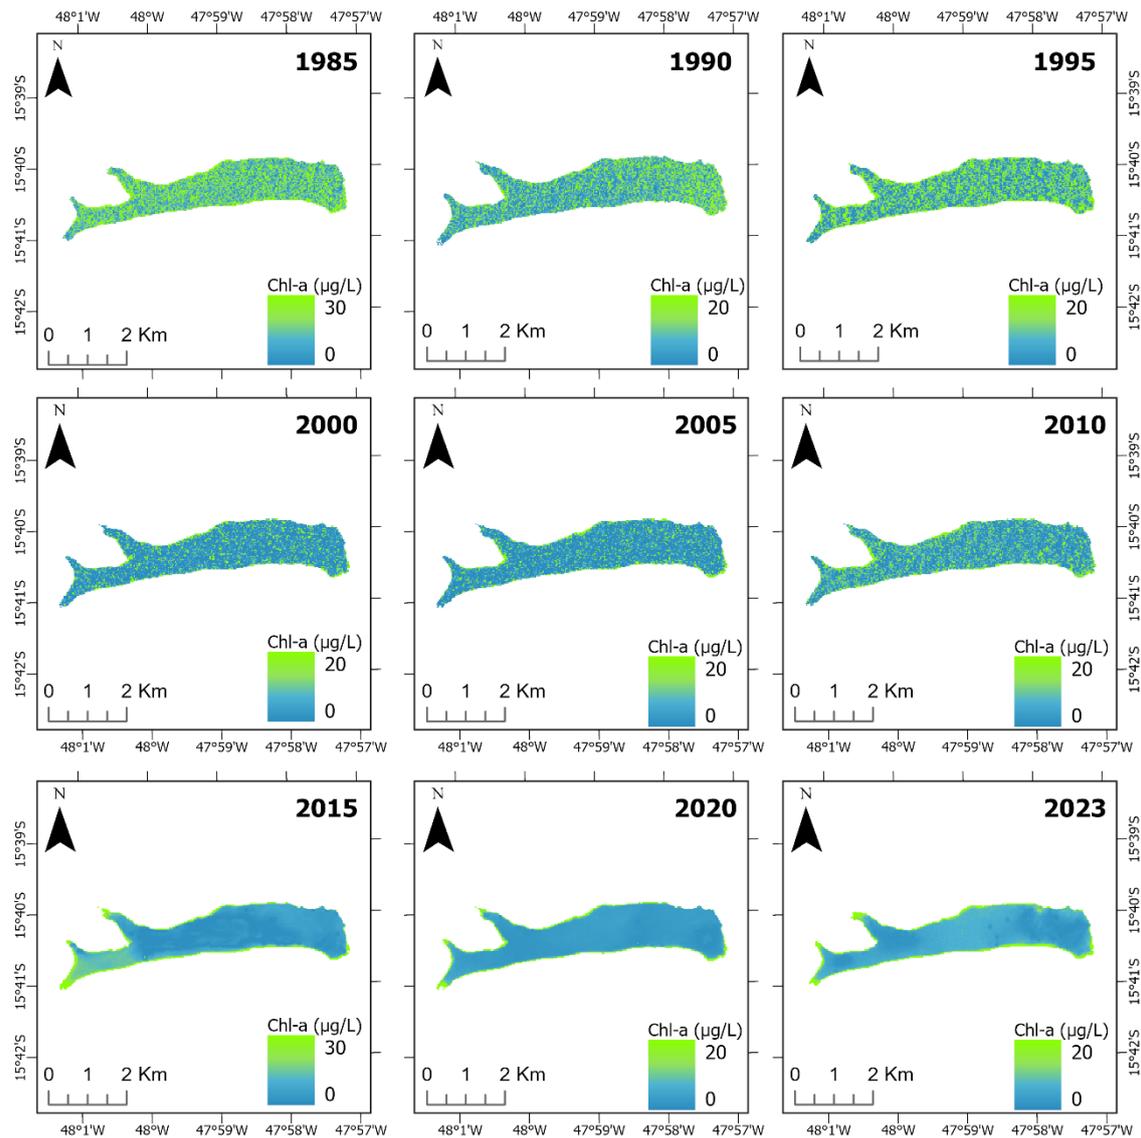


Figura 5.16 - Distribuição espacial de clorofila-a no reservatório Santa Maria de acordo com os modelos preditivos do estudo

Quanto a Figura 5.16, observa-se uma maior concentração de clorofila-a entre os dez primeiros anos da série histórica estudada, em particular no ano de 1985, cerca de 15 anos após o erguimento da barragem Santa Maria. Após esse período, é possível notar uma maior resposta no ano de 2015, ano em que o reservatório atingiu o seu menor volume desde o início de sua operação (ADASA et al., 2018), no entanto, não há registros de ocorrências de florações na época, sugerindo que a resposta seja devida a reflexão de fundo do reservatório. Em geral, como mostrado nos dados descritivos, o reservatório de Santa Maria apresenta uma média baixa de concentração de clorofila-a ( $6,6 \mu\text{g/L}$ ) e por ser inserido no Parque Nacional de Brasília, pode se dizer que dentre os reservatórios estudados, é o que se encontra em uma área mais protegida e controlada.

Apesar da necessidade de monitoramento, entende-se da fragilidade do sensoriamento remoto em quantificar concentrações baixas de clorofila-a. Segundo Tundisi e Tundisi (2008) e Brient et al. (2008), lagos ou represas com concentrações de clorofila menores que 10 µg/L apresentam predominâncias de atenuação vertical da radiação solar por causa do trípton (partículas orgânicas mortas em suspensão), o que dificulta a mensuração de clorofila-a em baixas concentrações por sensoriamento remoto. No entanto, os modelos propostos foram capazes de identificar as variações de clorofila-a em determinadas regiões e períodos, corroborando para a sua aplicabilidade em apoiar rotinas convencionais de monitoramento.

## 6 CONCLUSÃO E RECOMENDAÇÕES

O objetivo do estudo de propor um modelo semiempírico de estimativa espaço temporal de clorofila-a com a série Landsat foi alcançado, mas com ressalvas. Ao final das análises, foram propostos dois modelos de estimativa, no primeiro modelo, para o Landsat 5, as bandas do azul e do verde responderam melhor a essa variabilidade de concentrações de clorofila-a observadas no período histórico de 1984 a 2011. A partir de 2013, ano inicial de análise com as séries dos Landsat 8 e 9, a variabilidade de clorofila-a respondeu melhor nas bandas do verde e do vermelho. Além da diferença na variabilidade das concentrações nos períodos históricos analisados, as diferenças nos comprimentos de ondas centrais das bandas do azul e do verde entre os sensores podem ter influenciado nas respostas diferentes para cada sensor utilizado. Uma outra vertente é a possível interferência de partículas não algais nas respostas espectrais encontradas, especialmente no modelo utilizado para o Landsat 8 e 9, que podem ter aumentado a resposta nos comprimentos de onda da região do vermelho.

Os resultados dos modelos propostos não apresentam a precisão e a acurácia requerida para ser utilizado como uma principal ferramenta de monitoramento de qualidade da água, porém, foi possível notar que a ferramenta pode indicar a tendência de comportamento eutrófico que pode ser utilizada para apoiar os sistemas de monitoramento convencionais. Além disso, o estudo forneceu uma metodologia de estudo histórico da área que pode ser aprimorado posteriormente com utilização de outras técnicas de processamento, análise de dados para relacionar fatores climáticos e de urbanização da área.

Em complemento ao que foi posto em relação aos modelos desenvolvidos separadamente para cada sensor da série, levanta-se a necessidade de investigar os modelos que analisaram conjuntamente os sensores da série Landsat (Tabela 5.7) e que melhor se adequaram às condições dos reservatórios estudados. Em destaque os modelos BRGI (BOCHAROV et al., 2017) e TGI (RAYMOND HUNT et al., 2011), que apresentarem os melhores ajustes no agrupamento dos sensores Landsat 5, 8 e 9.

Quanto aos produtos desenvolvidos, foi possível estabelecer um protocolo para a extração de imagens de boa qualidade radiométrica que juntamente com os dados de qualidade da CAESB, produz um banco de dados limnológicos e de sensoriamento remoto capaz de calibrar e apoiar a estruturação de futuros modelos de estimativa de parâmetros de qualidade da água. Além disso, pretende-se que o estudo seja subsídio para um outro estudo em curso sobre a

modelagem hidrodinâmica e de qualidade da água do Lago Paranoá para um melhor entendimento dos fenômenos ecológicos e hidrodinâmicos do manancial.

Além disso, para os futuros estudos de estimativas de clorofila-a nos corpos hídricos do Distrito Federal, aconselha-se o levantamento dos valores de concentrações de sólidos suspensos na série histórica analisada, com o intuito de investigar a interferência de partículas não algais nas respostas dos modelos propostos, em especial no modelo que utilizou os valores de reflectância das bandas verde e vermelha. Em complemento, propõe-se a utilização de condicionantes aplicadas aos modelos que relacionam as concentrações de outras variáveis limnológicas para o desenvolvimento de um modelo mais robusto de estimativa. Além de se relacionar com outras variáveis limnológicas, poderiam ser aplicados modelos diferentes a cada reservatório, e no caso do Lagoa Paranoá, e às regiões/braços específicos, visto que cada localidade apresenta uma vulnerabilidade quanto às interferências que prejudicam a qualidade da água.

Recomenda-se ainda a avaliação de algoritmos de correção atmosférica aplicados às imagens Landsat e adequados à aplicação no *Google Earth Engine* para estudos de séries históricas, de forma a diminuir as interferências atmosféricas nas respostas espectrais dos pontos analisados nos reservatórios do DF. E com o intuito de explorar as interferências sazonais e antrópicas nas concentrações de clorofila-a, sugere-se a aplicação do modelo atrelado a dados climáticos e de uso e cobertura da terra.

## REFERÊNCIAS BIBLIOGRÁFICAS

ADASA. **Adasa - Nível dos reservatórios**. 2023a. Disponível em: <https://www.adasa.df.gov.br/monitoramento/niveis-dos-reservatorios>. Acesso em: 26 out. 2023.

ADASA. **Bacias do DF**. 2023b. Disponível em: <http://cobranca-rh-df.adasa.df.gov.br/page7.html>. Acesso em: 26 out. 2023.

ADASA; CAESB; NOVACAP; IBRAM. **Proliferação de cianobactérias e mortandade de peixes no Lago Paranoá**. 2016. Disponível em: [http://www.adasa.df.gov.br/images/stories/anexos/7Noticias/22-122016/Proliferacao\\_de\\_cianobacterias\\_no\\_Paranoa-dez\\_2016.pdf](http://www.adasa.df.gov.br/images/stories/anexos/7Noticias/22-122016/Proliferacao_de_cianobacterias_no_Paranoa-dez_2016.pdf). Acesso em: 12 nov. 2023.

ADASA; CAESB; SEAGRI; EMATER. **Gestão da crise hídrica 2016-2018 : experiências do Distrito Federal** (Jorge Enoch Furquim Werneck Lima, Glauco Kimura de Freitas, Marcelo Antônio Teixeira Pinto, Paulo Sérgio Bretas de Almeida Salles, Org.). Brasília, DF.

ADASA; ENGEPLUS. **Plano de Recursos Hídricos dos Afluentes Distritais da Bacia do Paranaíba**. [s.l: s.n.].

ADRIAN, Rita et al. Lakes as sentinels of climate change. **Limnology and Oceanography**, [S. l.], v. 54, n. 6 PART 2, p. 2283–2297, 2009. DOI: 10.4319/LO.2009.54.6\_PART\_2.2283. Acesso em: 26 out. 2023.

ALTMAN, Douglas G.; BLAND, J. Martin. Statistics notes: The normal distribution. **BMJ**, [S. l.], v. 310, n. 6975, p. 298, 1995. DOI: 10.1136/BMJ.310.6975.298. Disponível em: <https://www.bmj.com/content/310/6975/298>. Acesso em: 15 nov. 2023.

AMANI, Meisam et al. Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [S. l.], v. 13, p. 5326–5350, 2020. DOI: 10.1109/JSTARS.2020.3021052.

ANGELINI, Ronaldo; BINI, Luis Mauricio; STARLING, Fernando Luis do Rego Monteiro. **Efeitos de diferentes intervenções no processo de eutrofização do lago Paranoá (Brasília - DF)**. **Oecologia Brasiliensis** Programa de Pós-Graduação em Ecologia da Universidade Federal do Rio de Janeiro, , 2008. Disponível em: <http://repositorio.bc.ufg.br/handle/ri/11815>. Acesso em: 4 nov. 2023.

ARANHA, Thaís R. Benevides; MARTINEZ, Jean-Michel; SOUZA, Enio P.; BARROS, Mário U. G.; MARTINS, Eduardo Sávio P. R. Remote Analysis of the Chlorophyll-a Concentration Using Sentinel-2 MSI Images in a Semiarid Environment in Northeastern Brazil. **Water** 2022, Vol. 14, Page 451, [S. l.], v. 14, n. 3, p. 451, 2022. DOI: 10.3390/W14030451. Disponível em: <https://www.mdpi.com/2073-4441/14/3/451/htm>. Acesso em: 27 out. 2023.

ARAÚJO, Bruno Munhoz; NEGRI, Rogério Galante; MORAES ANANIAS, Pedro Henrique; BRESSANE, Adriano; RODGHER, Suzelei. Remotely sensed-based analysis about climatic and landscape change effects on phytoplankton bloom in Barra Bonita Reservoir (São Paulo

State, Brazil). **JARS**, [S. l.], v. 17, n. 01, p. 014509, 2023. DOI: 10.1117/1.JRS.17.014509. Disponível em: <https://ui.adsabs.harvard.edu/abs/2023JARS...17a4509A/abstract>. Acesso em: 29 out. 2023.

AUGUSTO-SILVA, Pétala B.; OGASHAWARA, Igor; BARBOSA, Cláudio C. F.; DE CARVALHO, Lino A. S.; JORGE, Daniel S. F.; FORNARI, Celso Israel; STECH, José L. Analysis of MERIS Reflectance Algorithms for Estimating Chlorophyll-a Concentration in a Brazilian Reservoir. **Remote Sensing** 2014, Vol. 6, Pages 11689-11707, [S. l.], v. 6, n. 12, p. 11689–11707, 2014. DOI: 10.3390/RS61211689. Disponível em: <https://www.mdpi.com/2072-4292/6/12/11689/htm>. Acesso em: 27 out. 2023.

BARBOSA, Claudio C. F.; NOVO, Evlyn M. L. M.; MARTINS, Vitor S. **Introdução ao sensoriamento remoto de sistemas aquáticos**. 1ª Edição ed. São José dos Campos/SP: Instituto Nacional de Pesquisas Espaciais, 2019. Disponível em: [www.inpe.br](http://www.inpe.br).

BARBOSA, Jackeline do S. B.; BELLOTTO, Valéria R.; DA SILVA, Damiana B.; LIMA, Thiago B. Nitrogen and Phosphorus Budget for a Deep Tropical Reservoir of the Brazilian Savannah. **Water** 2019, Vol. 11, Page 1205, [S. l.], v. 11, n. 6, p. 1205, 2019. DOI: 10.3390/W11061205. Disponível em: <https://www.mdpi.com/2073-4441/11/6/1205/htm>. Acesso em: 26 out. 2023.

BARROS, Lucélia Souza De. **FLUORESCÊNCIA NA ESTIMATIVA DE CLOROFILA-A EM MANANCIAIS DE ABASTECIMENTO PÚBLICO NO CERRADO, BRASIL**. 2021. Dissertação de mestrado - Universidade de Brasília, Brasília, DF, 2021.

BATISTA, Bruno Dias; FONSECA, Bárbara Medeiros. Fitoplâncton da região central do Lago Paranoá (DF): uma abordagem ecológica e sanitária. **Engenharia Sanitaria e Ambiental**, [S. l.], v. 23, n. 2, p. 229–241, 2018. DOI: 10.1590/S1413-41522018169124. Disponível em: <https://www.scielo.br/j/esa/a/jPNgZdv6DgkSGB6KDWjtHDn/>. Acesso em: 26 out. 2023.

BOCHAROV, A. V.; TIKHOMIROV, O. A.; KHIZHNYAK, S. D.; PAKHOMOV, P. M. Monitoring of Chlorophyll in Water Reservoirs Using Satellite Data. **Journal of Applied Spectroscopy**, [S. l.], v. 84, n. 2, p. 291–295, 2017. DOI: 10.1007/S10812-017-0466-7/METRCS. Disponível em: <https://link.springer.com/article/10.1007/s10812-017-0466-7>. Acesso em: 15 jan. 2024.

BONANSEA, Matias; RODRIGUEZ, Claudia; PINOTTI, Lucio. Assessing the potential of integrating Landsat sensors for estimating chlorophyll-a concentration in a reservoir. **Hydrology Research**, [S. l.], v. 49, n. 5, p. 1608–1617, 2018. DOI: 10.2166/NH.2017.116. Disponível em: <http://glovis>. Acesso em: 23 nov. 2023.

BORGES, Henrique Dantas; CICERELLI, Rejane Ennes; DE ALMEIDA, Tati; ROIG, Henrique L.; OLIVETTI, Diogo. Monitoring cyanobacteria occurrence in freshwater reservoirs using semi-analytical algorithms and orbital remote sensing. **Marine and Freshwater Research**, [S. l.], v. 71, n. 5, p. 569–578, 2020. DOI: 10.1071/MF18377.

BOUCHER, Jonah; WEATHERS, Kathleen C.; NOROUZI, Hamid; STEELE, Bethel. Assessing the effectiveness of Landsat 8 chlorophyll a retrieval algorithms for regional freshwater monitoring. **Ecological Applications**, [S. l.], v. 28, n. 4, p. 1044–1054, 2018. DOI:

- 10.1002/EAP.1708. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1002/eap.1708>. Acesso em: 31 out. 2023.
- BRASIL. **Decreto n.º 241. de 29 de novembro de 1961.** [s.l: s.n.].
- BRASIL. DECRETO Nº 88.940, DE 7 DE NOVEMBRO DE 1983Brasil, 1983.
- BRASIL. LEI Nº 9.433, DE 8 DE JANEIRO DE 1997Brasília, DF, 1997.
- BRICAUD, Annick; ROESLER, Collin; ZANEVELD, J. Ronald V. In situ methods for measuring the inherent optical properties of ocean waters. **Limnology and Oceanography**, [S. l.], v. 40, n. 2, p. 393–410, 1995. DOI: 10.4319/LO.1995.40.2.0393. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.4319/lo.1995.40.2.0393>. Acesso em: 4 nov. 2023.
- BRIENT, Luc et al. A phycocyanin probe as a tool for monitoring cyanobacteria in freshwater bodies. **Journal of environmental monitoring : JEM**, [S. l.], v. 10, n. 2, p. 248–255, 2008. DOI: 10.1039/B714238B. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/18246219/>. Acesso em: 23 jan. 2024.
- BUKATA, R. P.; JEROME, J. H.; BRUTON, J. E.; JAIN, S. C. Determination of inherent optical properties of Lake Ontario coastal waters. **Applied optics**, [S. l.], v. 18, n. 23, p. 3926, 1979. DOI: 10.1364/AO.18.003926. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/20216727/>. Acesso em: 26 out. 2023.
- BUKATA, R. P.; JEROME, J. H.; BRUTON, J. E.; JAIN, S. C.; ZWICK, H. H. Optical water quality model of Lake Ontario. 1: Determination of the optical cross sections of organic and inorganic particulates in Lake Ontario. **Applied optics**, [S. l.], v. 20, n. 9, p. 1696, 1981. DOI: 10.1364/AO.20.001696. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/20309371/>. Acesso em: 26 out. 2023.
- BUMA, Willibroad Gabila; LEE, Sang Il. Evaluation of Sentinel-2 and Landsat 8 Images for Estimating Chlorophyll-a Concentrations in Lake Chad, Africa. **Remote Sensing 2020, Vol. 12, Page 2437**, [S. l.], v. 12, n. 15, p. 2437, 2020. DOI: 10.3390/RS12152437. Disponível em: <https://www.mdpi.com/2072-4292/12/15/2437/htm>. Acesso em: 3 nov. 2023.
- BURNETT, J. A. B.; MATTOS, S. P.; AZZOLIN, N. M. P. Intervenções da Companhia de Saneamento. Em: FONSECA, F. O. (org.). **Olhares sobre o Lago Paranoá**. Brasília: SEMARH, 2001. p. 199–212.
- CAESB. Revista Caesb Inova 2023. n° 3, [S. l.], p. 1–55, 2023. a.
- CAESB. **Relatório da Qualidade da Água Distribuída pela Caesb em 2022.** [s.l: s.n.]. Disponível em: [www.caesb.df.gov.br](http://www.caesb.df.gov.br);
- CAESB. Notícias. **Responsável por abastecer 11% do DF, Barragem de Santa Maria passa por reformas**, [S. l.], 2023. c. Disponível em: <https://www.caesb.df.gov.br/8-noticias/1742-15-05-23-barragem-de-santa-maria-passa-por-reformas.html#:~:text=passa%20por%20reformas-,15%2F05%2F23%20%2D%20Respons%C3%A1vel%20por%20abastecer%2011%25%20do,Santa%20Maria%20passa%20por%20reformas&text=A%20Barragem%20de%20Santa%20Maria,em%202022%2C%20est%C3%A1%20sendo%20reformada>. Acesso em: 25 nov. 2023.

CAIRO, Carolline; BARBOSA, Claudio; LOBO, Felipe; NOVO, Evlyn; CARLOS, Felipe; MACIEL, Daniel; JÚNIOR, Rogério Flores; SILVA, Edson; CURTARELLI, Victor. Hybrid chlorophyll-a algorithm for assessing trophic states of a tropical brazilian reservoir based on msi/sentinel-2 data. **Remote Sensing**, [S. l.], v. 12, n. 1, 2020. DOI: 10.3390/RS12010040.

CARDALL, Anna; TANNER, Kaylee; WILLIAMS, Gustavious. **Google Earth Engine Tools for Long-Term Spatiotemporal Monitoring of Chlorophyll-a Concentrations** *Open Water Journal*. [s.l: s.n.].

CAVALCANTI, Cristine Gobbato B.; PINTO, Marcelo Teixeira; DE FREITAS, Hélio José; MOREIRA, Ricardo Cosme A. Paranoá Lake restoration: impact of tertiary treatment of sewage in the watershed. **SIL Proceedings, 1922-2010**, [S. l.], v. 26, n. 2, p. 689–693, 1997. DOI: 10.1080/03680770.1995.11900803.

CHELOTTI, Giancarlo Brugnara; MARTINEZ, Jean Michel; ROIG, Henrique Llacer; OLIVIETTI, Diogo. Space-Temporal analysis of suspended sediment in low concentration reservoir by remote sensing. **RBRH**, [S. l.], v. 24, p. e17, 2019. DOI: 10.1590/2318-0331.241920180061.

Disponível em: <https://www.scielo.br/j/rbrh/a/rcbdD6j8VZVD5pVBqRtDZgR/?lang=en>. Acesso em: 26 out. 2023.

CHU, Hone Jay; HE, Yu Chen; CHUSNAH, Wachidatin Nisa'Ul; JAELANI, Lalu Muhamad; CHANG, Chih Hua. Multi-Reservoir Water Quality Mapping from Remote Sensing Using Spatial Regression. **Sustainability** **2021**, Vol. 13, Page 6416, [S. l.], v. 13, n. 11, p. 6416, 2021. DOI: 10.3390/SU13116416. Disponível em: <https://www.mdpi.com/2071-1050/13/11/6416/htm>. Acesso em: 28 out. 2023.

CHUSNAH, Wachidatin Nisaul; CHU, Hone Jay. Estimating chlorophyll-a concentrations in tropical reservoirs from band-ratio machine learning models. **Remote Sensing Applications: Society and Environment**, [S. l.], v. 25, p. 100678, 2022. DOI: 10.1016/J.RSASE.2021.100678. Acesso em: 28 out. 2023.

CICERELLI, Rejane E.; GALO, Maria de L. B. T. Multisource remote sensing applied to the detection of phytoplankton in inland waters. **Revista Brasileira de Engenharia Agrícola e Ambiental**, [S. l.], v. 19, n. 3, p. 259–265, 2015. DOI: 10.1590/1807-1929/agriambi.v19n3p259-265.

CODEPLAN. **Pesquisa Distrital por Amostra de Domicílios – PDAD 2021**. [s.l: s.n.].

COLLISCHONN, Bruno; VALTER, José; DE MELO, Simplício. A FLORAÇÃO DE CIANOBACTÉRIAS NO LAGO PARANOÁ EM NOVEMBRO DE 2016: UMA HIPÓTESE EXPLICATIVA. *Em: XXIV SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS 2021*, **Anais [...]**. [s.l: s.n.]

CONAMA. Resolução nº 357, de 17 DE MARÇO DE 2005. Publicada no DOU nº 053, de 18/03/2005, págs. 58-63 • Alterada pela Resolução 410/2009 e pela 430/2011 Dispõe sobre a classificação dos corpos de água e diretrizes ambientais para o seu enquadramento, bem como estabelece as condições e padrões de lançamento de efluentes, e dá outras providências. Brasília, DF, 2005.

CRH-DF. Resolução N° 02, de 17 de DEZEMBRO DE 2014 **Aprova o enquadramento dos corpos de água superficiais do Distrito Federal em classes, segundo os usos preponderantes, e dá encaminhamentos**, 2014.

CURRAN-EVERETT, Douglas; BENOS, Dale J. Guidelines for reporting statistics in journals published by the American Physiological Society. **https://doi.org/10.1152/ajpcell.00250.2004**, [S. l.], v. 287, n. 2, p. C243–C245, 2004. DOI: 10.1152/AJPCCELL.00250.2004. Disponível em: <https://journals.physiology.org/doi/10.1152/ajpcell.00250.2004>. Acesso em: 15 nov. 2023.

DA SILVA, Damiana B.; BELLOTTO, Valéria R.; DO B BARBOSA, Jackeline S.; LIMA, Thiago B.; HUNG, Yung-Tse; ABDUL AZIZ, Hamidi; AL-KHATIB, Issam A.; ABDEL RAHMAN, Rehab O.; IMAI, Tsuyoshi. Spatiotemporal Variation on Water Quality and Trophic State of a Tropical Urban Reservoir: A Case Study of the Lake Paranoá-DF, Brazil. **Water 2021, Vol. 13, Page 3314**, [S. l.], v. 13, n. 22, p. 3314, 2021. a. DOI: 10.3390/W13223314. Disponível em: <https://www.mdpi.com/2073-4441/13/22/3314/htm>. Acesso em: 26 out. 2023.

DA SILVA, Damiana B.; BELLOTTO, Valéria R.; DO B BARBOSA, Jackeline S.; LIMA, Thiago B.; HUNG, Yung-Tse; ABDUL AZIZ, Hamidi; AL-KHATIB, Issam A.; ABDEL RAHMAN, Rehab O.; IMAI, Tsuyoshi. Spatiotemporal Variation on Water Quality and Trophic State of a Tropical Urban Reservoir: A Case Study of the Lake Paranoá-DF, Brazil. **Water 2021, Vol. 13, Page 3314**, [S. l.], v. 13, n. 22, p. 3314, 2021. b. DOI: 10.3390/W13223314. Disponível em: <https://www.mdpi.com/2073-4441/13/22/3314/htm>. Acesso em: 23 nov. 2023.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; DE COLSTOUN, E. Brown; MCMURTREY, J. E. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. **Remote Sensing of Environment**, [S. l.], v. 74, n. 2, p. 229–239, 2000. DOI: 10.1016/S0034-4257(00)00113-9. Acesso em: 28 out. 2023.

DE OLIVEIRA, L. P.; KRAU, L. General and applied hydro-biology, particularly as a vehicle of schistosoma. Hypereutrophy, modern deterioration of water. **Memórias do Instituto Oswaldo Cruz**, [S. l.], v. 68, n. 1, p. 89–118, 1970. DOI: 10.1590/S0074-02761970000100004. Disponível em: <https://www.scielo.br/j/mioc/a/ZWhMSrydzBXnVWfR36NgKsR/abstract/?lang=en>. Acesso em: 29 out. 2023.

DE VITO, Marco. **AVALIAÇÃO DO RISCO DE CONTAMINAÇÃO DE MANANCIAS HÍDRICAS PARA O ABASTECIMENTO: O CASO DA BACIA DA BARRAGEM DO DESCOBERTO**. 2007. Dissertação - Universidade de Brasília, Brasília, 2007.

DRISCOLL, P.; LECKY, F.; CROSBY, M. An introduction to everyday statistics—1. **Journal of Accident & Emergency Medicine**, [S. l.], v. 17, n. 3, p. 205, 2000. DOI: 10.1136/EMJ.17.3.205-A. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1725369/>. Acesso em: 15 nov. 2023.

ESA. **The Sentinel missions.** 2023. Disponível em: [https://www.esa.int/Applications/Observing\\_the\\_Earth/Copernicus/The\\_Sentinel\\_missions](https://www.esa.int/Applications/Observing_the_Earth/Copernicus/The_Sentinel_missions). Acesso em: 26 out. 2023.

ESCADAFAL, R.; BELGHITH, A.; BEN MOUSSA, H. Indices spectraux pour la télédétection de la dégradation des milieux naturels en Tunisie aride. *Em: PROCEEDINGS OF THE 6TH INTERNATIONAL SYMPOSIUM ON PHYSICAL MEASUREMENTS AND SIGNATURES IN REMOTE SENSING 1994*, **Anais [...]**. [s.l: s.n.] p. 17–21.

ESTEVEES, Francisco de Assis. **Fundamentos de Limnologia.** 2ª Edição ed. [s.l: s.n.].

FALKOWSKI, Paul; KIEFER, Dale A. Chlorophyll a fluorescence in phytoplankton: relationship to photosynthesis and biomass. **Journal of Plankton Research**, [S. l.], v. 7, n. 5, p. 715–731, 1985. DOI: 10.1093/PLANKT/7.5.715. Disponível em: <https://dx.doi.org/10.1093/plankt/7.5.715>. Acesso em: 27 out. 2023.

FENG, Lei; YOU, Yu; LIAO, Weiling; PANG, Jiawei; HU, Ronghao; FENG, Li. Multi-scale change monitoring of water environment using cloud computing in optimal resolution remote sensing images. **Energy Reports**, [S. l.], v. 8, p. 13610–13620, 2022. DOI: 10.1016/J.EGYR.2022.09.134. Acesso em: 29 out. 2023.

FONTANA, Luciane; ALBUQUERQUE, Ana Luiza S.; BRENNER, Mark; BONOTTO, Daniel M.; SABARIS, Tatiani P. P.; PIRES, Maria A. F.; COTRIM, Marycel E. B.; BICUDO, Denise C. The eutrophication history of a tropical water supply reservoir in Brazil. **Journal of Paleolimnology**, [S. l.], v. 51, n. 1, p. 29–43, 2014. DOI: 10.1007/S10933-013-9753-3/METRICS. Disponível em: <https://link.springer.com/article/10.1007/s10933-013-9753-3>. Acesso em: 26 out. 2023.

GALLEGOS, Charles L.; CORRELL, David L.; PIERCE, J. W. Modeling spectral diffuse attenuation, absorption, and scattering coefficients in a turbid estuary. **Limnology and Oceanography**, [S. l.], v. 35, n. 7, p. 1486–1502, 1990. DOI: 10.4319/LO.1990.35.7.1486. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.4319/lo.1990.35.7.1486>. Acesso em: 30 out. 2023.

GAO, Bo Cai; MONTES, Marcos J.; DAVIS, Curtiss O.; GOETZ, Alexander F. H. Atmospheric correction algorithms for hyperspectral remote sensing data of land and ocean. **Remote Sensing of Environment**, [S. l.], v. 113, n. SUPPL. 1, p. S17–S24, 2009. DOI: 10.1016/J.RSE.2007.12.015. Acesso em: 27 out. 2023.

GDF. **Adequação Ambiental da Reserva Biológica e das Propriedades Rurais às Margens do Lago Descoberto.** [s.l: s.n.].

GHASEMI, Asghar; ZAHEDIASL, Saleh. Normality Tests for Statistical Analysis: A Guide for Non-Statisticians. **International Journal of Endocrinology and Metabolism**, [S. l.], v. 10, n. 2, p. 486, 2012. DOI: 10.5812/IJEM.3505. Disponível em: [/pmc/articles/PMC3693611/](https://pmc/articles/PMC3693611/). Acesso em: 15 nov. 2023.

GHOLIZADEH, Mohammad Haji; MELESSE, Assefa M.; REDDI, Lakshmi. **A comprehensive review on water quality parameters estimation using remote sensing techniques.** **Sensors (Switzerland)**MDPI AG, , 2016. DOI: 10.3390/s16081298.

GILERSON, Alexander A. et al. Algorithms for remote estimation of chlorophyll-a in coastal and inland waters using red and near infrared bands. **Optics Express**, Vol. 18, Issue 23, pp. 24109-24125, [S. l.], v. 18, n. 23, p. 24109–24125, 2010. DOI: 10.1364/OE.18.024109. Disponível em: <https://opg.optica.org/viewmedia.cfm?uri=oe-18-23-24109&seq=0&html=true>. Acesso em: 29 out. 2023.

GITELSON, A. The peak near 700 nm on radiance spectra of algae and water: Relationships of its magnitude and position with chlorophyll. **International Journal of Remote Sensing**, [S. l.], v. 13, n. 17, p. 3367–3373, 1992. DOI: 10.1080/01431169208904125.

GITELSON, A. A. .; YACOBI, Y. Z.; KARNIELI, A.; KRESS, N. Reflectance spectra of polluted marine waters in Haifa Bay, Southeastern Mediterranean: Features and application for remote estimation of chlorophyll concentration. **Israel Journal of Earth Science**, [S. l.], v. 45, p. 127–136, 1996.

GITELSON, Anatoly A.; DALL’OLMO, Giorgio; MOSES, Wesley; RUNDQUIST, Donald C.; BARROW, Tadd; FISHER, Thomas R.; GURLIN, Daniela; HOLZ, John. A simple semi-analytical model for remote estimation of chlorophyll-a in turbid waters: Validation. **Remote Sensing of Environment**, [S. l.], v. 112, n. 9, p. 3582–3593, 2008. DOI: 10.1016/J.RSE.2008.04.015. Acesso em: 27 out. 2023.

GITELSON, Anatoly A.; GRITZ, Yuri; MERZLYAK, Mark N. **Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves**. **J. Plant Physiol.** [s.l: s.n.]. Disponível em: <http://www.urbanfischer.de/journals/jpp>.

GORDON, Howard R.; MOREL, André Y. Remote Assessment of Ocean Color for Interpretation of Satellite Visible Imagery. Lecture Notes on Coastal and Estuarine Studies. New York, NY, v. 4, Lecture Notes on Coastal and Estuarine Studies, 1983. DOI: 10.1007/978-1-4684-6280-7. Disponível em: <http://link.springer.com/10.1007/978-1-4684-6280-7>. Acesso em: 31 out. 2023.

GORELICK, Noel; HANCHER, Matt; DIXON, Mike; ILYUSHCHENKO, Simon; THAU, David; MOORE, Rebecca. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, [S. l.], v. 202, p. 18–27, 2017. DOI: 10.1016/j.rse.2017.06.031.

GRIFFIN, C. G.; MCCLELLAND, J. W.; FREY, K. E.; FISKE, G.; HOLMES, R. M. Quantifying CDOM and DOC in major Arctic rivers during ice-free conditions using Landsat TM and ETM+ data. **Remote Sensing of Environment**, [S. l.], v. 209, p. 395–409, 2018. DOI: 10.1016/J.RSE.2018.02.060. Acesso em: 27 out. 2023.

GROSS, Joceli Augusto. **EFEITOS DE DIFERENTES COMPONENTES OPTICAMENTE ATIVOS NA REFLECTÂNCIA DA ÁGUA PARA A ESTIMATIVA REMOTA DAS CONCENTRAÇÕES DE CLOROFILA-A FITOPLANCTÔNICA**. 2019. Tese de doutorado - Universidade Federal de Santa Maria (RS), Santa Maria, RS, 2019.

GUANTER, Luis; RUIZ-VERDÚ, Antonio; ODERMATT, Daniel; GIARDINO, Claudia; SIMIS, Stefan; ESTELLÉS, Víctor; HEEGE, Thomas; DOMÍNGUEZ-GÓMEZ, Jose Antonio; MORENO, Jose. Atmospheric correction of ENVISAT/MERIS data over inland

waters: Validation for European lakes. **Remote Sensing of Environment**, [S. l.], v. 114, n. 3, p. 467–480, 2010. DOI: 10.1016/J.RSE.2009.10.004. Acesso em: 4 nov. 2023.

GURLIN, Daniela; GITELSON, Anatoly A.; MOSES, Wesley J. Remote estimation of chl-a concentration in turbid productive waters - Return to a simple two-band NIR-red model? **Remote Sensing of Environment**, [S. l.], v. 115, n. 12, p. 3479–3490, 2011. DOI: 10.1016/j.rse.2011.08.011.

HA, Nguyen Thi Thu; KOIKE, Katsuaki; NHUAN, Mai Trong; CANH, Bui Dinh; THAO, Nguyen Thien Phuong; PARSONS, Michael. Landsat 8/OLI Two bands ratio algorithm for chlorophyll-a concentration mapping in hypertrophic waters: An application to west lake in Hanoi (Vietnam). **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, [S. l.], v. 10, n. 11, p. 4919–4929, 2017. a. DOI: 10.1109/JSTARS.2017.2739184. Acesso em: 2 nov. 2023.

HA, Nguyen Thi Thu; THAO, Nguyen Thien Phuong; KOIKE, Katsuaki; NHUAN, Mai Trong. Selecting the Best Band Ratio to Estimate Chlorophyll-a Concentration in a Tropical Freshwater Lake Using Sentinel 2A Images from a Case Study of Lake Ba Be (Northern Vietnam). **ISPRS International Journal of Geo-Information 2017, Vol. 6, Page 290**, [S. l.], v. 6, n. 9, p. 290, 2017. b. DOI: 10.3390/IJGI6090290. Disponível em: <https://www.mdpi.com/2220-9964/6/9/290/htm>. Acesso em: 1 nov. 2023.

HAN, Luoheng. **Spectral Reflectance with Varying Suspended Sediment Concentrations in Clear and Algae-Laden Waters**. [s.l.: s.n.].

HIRD, Jennifer N.; DELANCEY, Evan R.; MCDERMID, Gregory J.; KARIYEVA, Jahan. Google earth engine, open-access satellite data, and machine learning in support of large-area probabilistic wetland mapping. **Remote Sensing**, [S. l.], v. 9, n. 12, 2017. DOI: 10.3390/rs9121315.

HOFFMAN, Julien I. E. Basic biostatistics for medical and biomedical practitioners. **Biostatistics for Medical and Biomedical Practitioners**, [S. l.], p. 1–734, 2019. DOI: 10.1016/C2018-0-02190-8. Disponível em: <http://www.sciencedirect.com:5070/book/9780128170847/basic-biostatistics-for-medical-and-biomedical-practitioners>. Acesso em: 15 nov. 2023.

IBGE. **Panorama do Censo 2022**. 2022. Disponível em: <https://censo2022.ibge.gov.br/panorama/>. Acesso em: 29 out. 2023.

ICCG, International Ocean-Colour Sensors. **Historical Ocean-Colour Sensors**. 2023. Disponível em: <https://ioccg.org/resources/missions-instruments/historical-ocean-colour-sensors/>. Acesso em: 26 out. 2023.

IOCCG. **Atmospheric Correction for Remotely-Sensed Ocean-Colour**. Dartmouth, Canada: International Ocean Colour Coordinating Group (IOCCG), 2010. DOI: 10.25607/OBP-101. Disponível em: <https://repository.oceanbestpractices.org/handle/11329/521>. Acesso em: 27 out. 2023.

IPEDF. **2.6 – Climate – Federal District Atlas**. 2020. Disponível em: <https://atlas.ipe.df.gov.br/en/?p=999>. Acesso em: 29 out. 2023.

IRONS, James R.; DWYER, John L.; BARSÍ, Julia A. The next Landsat satellite: The Landsat Data Continuity Mission. **Remote Sensing of Environment**, [S. l.], v. 122, p. 11–21, 2012. DOI: 10.1016/J.RSE.2011.08.026. Acesso em: 31 out. 2023.

JENSEN, John R. **Sensoriamento Remoto do Ambiente: Uma perspectiva em Recursos Terrestres**. São José dos Campos.

JEROME, J. H.; BUKATA, R. P.; BRUTON, J. E. Spectral Attenuation and Irradiance in the Laurentian Great Lakes. **Journal of Great Lakes Research**, [S. l.], v. 9, n. 1, p. 60–68, 1983. DOI: 10.1016/S0380-1330(83)71872-1. Acesso em: 26 out. 2023.

KISLIK, Chippie; DRONOVA, Iryna; GRANTHAM, Theodore E.; KELLY, Maggi. Mapping algal bloom dynamics in small reservoirs using Sentinel-2 imagery in Google Earth Engine. **Ecological Indicators**, [S. l.], v. 140, p. 109041, 2022. DOI: 10.1016/J.ECOLIND.2022.109041. Acesso em: 27 out. 2023.

KOLLURU, Srinivas; GEDAM, Shirishkumar S.; CHANDER, Shard; SAHAY, Arvind. Development of chlorophyll-a concentration estimation algorithm for turbid productive inland waters in India. **Geocarto International**, [S. l.], v. 38, n. 1, p. 2171143, 2023. DOI: 10.1080/10106049.2023.2171143. Disponível em: <https://doi.org/10.1080/10106049.2023.2171143>. Acesso em: 6 nov. 2023.

KONDRATYEVA, Anna et al. Urbanization Effects on Biodiversity Revealed by a Two-Scale Analysis of Species Functional Uniqueness vs. Redundancy. **Frontiers in Ecology and Evolution**, [S. l.], v. 8, p. 499897, 2020. DOI: 10.3389/FEVO.2020.00073/BIBTEX. Acesso em: 29 out. 2023.

LE, Chengfeng; HU, Chuanmin; CANNIZZARO, Jennifer; DUAN, Hongtao. Long-term distribution patterns of remotely sensed water quality parameters in Chesapeake Bay. **Estuarine, Coastal and Shelf Science**, [S. l.], v. 128, p. 93–103, 2013. a. DOI: 10.1016/J.ECSS.2013.05.004. Acesso em: 28 out. 2023.

LE, Chengfeng; HU, Chuanmin; ENGLISH, David; CANNIZZARO, Jennifer; CHEN, Zhiqiang; FENG, Lian; BOLER, Richard; KOVACH, Charles. Towards a long-term chlorophyll-a data record in a turbid estuary using MODIS observations. **Progress in Oceanography**, [S. l.], v. 109, p. 90–103, 2013. b. DOI: 10.1016/J.POCEAN.2012.10.002. Acesso em: 31 out. 2023.

LE, Chengfeng; HU, Chuanmin; ENGLISH, David; CANNIZZARO, Jennifer; KOVACH, Charles. Climate-driven chlorophyll-a changes in a turbid estuary: Observations from satellites and implications for management. **Remote Sensing of Environment**, [S. l.], v. 130, p. 11–24, 2013. c. DOI: 10.1016/J.RSE.2012.11.011. Acesso em: 2 nov. 2023.

LEITE COSTA, Maria Elisa; KOIDE, Sergio. O IMPACTO DA POLUIÇÃO DIFUSA ORIUNDA DO SISTEMA DE DRENAGEM URBANO NO LAGO PARANOÁ. Em: XX SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS 2013, **Anais [...]**. [s.l.: s.n.] Disponível em: <https://www.researchgate.net/publication/314313371>.

LI, Leiming; WU, Jun; LU, Jian; LI, Kexin; ZHANG, Xiying; MIN, Xiuyun; GAO, Chunliang; XU, Juan. Water quality evaluation and ecological-health risk assessment on trace elements in surface water of the northeastern Qinghai-Tibet Plateau. **Ecotoxicology and**

**Environmental Safety**, [S. l.], v. 241, p. 113775, 2022. DOI: 10.1016/J.ECOENV.2022.113775. Acesso em: 29 out. 2023.

LI, Linhai; LI, Lin; SONG, Kaishan; LI, Yunmei; TEDESCO, Lenore P.; SHI, Kun; LI, Zuchuan. An inversion model for deriving inherent optical properties of inland waters: Establishment, validation and application. **Remote Sensing of Environment**, [S. l.], v. 135, p. 150–166, 2013. DOI: 10.1016/j.rse.2013.03.031.

LI, Sijia et al. Quantification of chlorophyll-a in typical lakes across China using Sentinel-2 MSI imagery with machine learning algorithm. **Science of The Total Environment**, [S. l.], v. 778, p. 146271, 2021. DOI: 10.1016/J.SCITOTENV.2021.146271. Acesso em: 27 out. 2023.

LILLESAND, T. M.; KIEFER, R. W. **Remote Sensing and Image Interpretation**. 7ª Edição ed. New York: Wiley, 2015.

LIMA, Jorge Enoch Furquim Werneck. Situação e perspectivas sobre as águas do cerrado. **Ciência e Cultura**, [S. l.], v. 63, n. 3, p. 27–29, 2011. DOI: 10.21800/S0009-67252011000300011. Disponível em: [http://cienciaecultura.bvs.br/scielo.php?script=sci\\_arttext&pid=S0009-67252011000300011&lng=en&nrm=iso&tlng=pt](http://cienciaecultura.bvs.br/scielo.php?script=sci_arttext&pid=S0009-67252011000300011&lng=en&nrm=iso&tlng=pt). Acesso em: 29 out. 2023.

LIN, Shengpan; NOVITSKI, Linda N.; QI, Jiaguo; STEVENSON, Robert Jan. Landsat TM/ETM+ and machine-learning algorithms for limnological studies and algal bloom management of inland lakes. **Journal of Applied Remote Sensing**, [S. l.], v. 12, n. 02, p. 1, 2018. DOI: 10.1117/1.jrs.12.026003.

LOBO, Felipe de Lucia; NAGEL, Gustavo Willy; MACIEL, Daniel Andrade; DE CARVALHO, Lino Augusto Sander; MARTINS, Vitor Souza; BARBOSA, Cláudio Clemente Faria; DE MORAES NOVO, Evlyn Márcia Leão. Algaemap: Algae bloom monitoring application for inland waters in Latin America. **Remote Sensing**, [S. l.], v. 13, n. 15, 2021. DOI: 10.3390/rs13152874.

LOBO, Felipe de Lucia; NOVO, Evlyn Márcia Leão de Moraes; BARBOSA, Claudio Clemente Faria; GALVÃO, Lênio Soares. Reference spectra to classify Amazon water types. **International Journal of Remote Sensing**, [S. l.], v. 33, n. 11, p. 3422–3442, 2012. DOI: 10.1080/01431161.2011.627391. Disponível em: <https://www.tandfonline.com/doi/abs/10.1080/01431161.2011.627391>. Acesso em: 31 out. 2023.

LOBO, Felipe L.; COSTA, Maycira P. F.; NOVO, Evlyn M. L. M. Time-series analysis of Landsat-MSS/TM/OLI images over Amazonian waters impacted by gold mining activities. **Remote Sensing of Environment**, [S. l.], v. 157, p. 170–184, 2015. DOI: 10.1016/j.rse.2014.04.030.

LONDE, Luciana de Resende. **COMPORTAMENTO ESPECTRAL DO FITOPLÂNTON DE UM RESERVATÓRIO BRASILEIRO EUTROFIZADO-IBITINGA (SP)**. 2008. Tese de Doutorado - INPE, São José dos Campos, 2008.

LORZ, C. et al. Challenges of an integrated water resource management for the Distrito Federal, Western Central Brazil: Climate, land-use and water resources. **Environmental**

**Earth Sciences**, [S. l.], v. 65, n. 5, p. 1575–1586, 2012. DOI: 10.1007/S12665-011-1219-1/METRICS. Disponível em: <https://link.springer.com/article/10.1007/s12665-011-1219-1>. Acesso em: 26 out. 2023.

MACHADO, Marília Teresinha de Sousa; BAPTISTA, Gustavo Macedo de Mello. Sensoriamento remoto como ferramenta de monitoramento da qualidade da água do Lago Paranoá (DF). **Engenharia Sanitária e Ambiental**, [S. l.], v. 21, n. 2, p. 357–365, 2016. DOI: 10.1590/S1413-41522016141970.

MAGALHÃES, Ivo Augusto Lopes; PEREIRA DE SOUZA, Ana Carolina; MINOTI, Ricardo Tezini; GOMES, Lenora Nunes Ludolf. **Análise de parâmetros da qualidade da água no lago Descoberto no Distrito Federal, por meio de imagens do satélite Sentinel-2B** *Revista Brasileira de Geografia Física* v. [s.l.: s.n.]. Disponível em: <https://periodicos.ufpe.br/revistas/rbgfe>.

MALONE, Chris. **HLA 622: Modeling and Predictive Analytics in Healthcare course. Módulo 2, Parte 3.** 2023. Disponível em: [https://www.statsclass.org/online/dsci622/notes/Module2\\_Part3.php](https://www.statsclass.org/online/dsci622/notes/Module2_Part3.php). Acesso em: 27 out. 2023.

MARQUES, Laís de Almeida. **MODELAGEM BIDIMENSIONAL PARA SIMULAÇÃO DA QUALIDADE DA ÁGUA DO LAGO PARANOÁ-DF**. 2021. Dissertação de Mestrado - Universidade de Brasília, Brasília, 2021.

MENEZES JR., A.; SINOTI, M. L.; SARAIVA, R. C. F. Histórico. *Em*: FONSECA, F. O. (org.). **Olhares sobre o Lago Paranoá**. Brasília: SEMARH, 2001.

MENEZES, Paulo Henrique Bretanha Junker. **Avaliação do efeito das ações antrópicas no processo de escoamento superficial e assoreamento na bacia do Lago Paranoá**. 2010. Dissertação de Mestrado - Universidade de Brasília, [S. l.], 2010.

MENON, Harilal B.; ADHIKARI, Arjun. Remote Sensing of Chlorophyll-A in Case II Waters: A Novel Approach With Improved Accuracy Over Widely Implemented Turbid Water Indices. **Journal of Geophysical Research: Oceans**, [S. l.], v. 123, n. 11, p. 8138–8158, 2018. DOI: 10.1029/2018JC014052. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1029/2018JC014052>. Acesso em: 23 nov. 2023.

MILLER, Richard L.; MCKEE, Brent A. Using MODIS Terra 250 m imagery to map concentrations of total suspended matter in coastal waters. **Remote Sensing of Environment**, [S. l.], v. 93, n. 1–2, p. 259–266, 2004. DOI: 10.1016/J.RSE.2004.07.012. Acesso em: 17 jan. 2024.

MISHRA, Deepak R.; MISHRA, Sachidananda. Plume and bloom: Effect of the mississippi river diversion on the water quality of lake pontchartrain. **Geocarto International**, [S. l.], v. 25, n. 7, p. 555–568, 2010. DOI: 10.1080/10106041003763394.

MISHRA, Nischal; HELDER, Dennis; BARSİ, Julia; MARKHAM, Brian. CONTINUOUS CALIBRATION IMPROVEMENT: LANDSAT 5 THROUGH LANDSAT 8. **Remote sensing of environment**, [S. l.], v. 185, p. 7, 2016. DOI: 10.1016/J.RSE.2016.07.032. Disponível em: [/pmc/articles/PMC5810144/](https://www.sciencedirect.com/journal/remote-sensing-of-environment/article/pii/S0924646016305144). Acesso em: 31 out. 2023.

MISHRA, Sachidananda; MISHRA, Deepak R. Normalized difference chlorophyll index: A novel model for remote estimation of chlorophyll-a concentration in turbid productive waters. **Remote Sensing of Environment**, [S. l.], v. 117, p. 394–406, 2011. DOI: 10.1016/j.rse.2011.10.016.

MISHRA, Sachidananda; MISHRA, Deepak R.; LEE, Zhongping; TUCKER, Craig S. Quantifying cyanobacterial phycocyanin concentration in turbid productive waters: A quasi-analytical approach. **Remote Sensing of Environment**, [S. l.], v. 133, p. 141–151, 2013. DOI: 10.1016/J.RSE.2013.02.004. Acesso em: 15 nov. 2023.

MOBLEY, C. D. **Light and water: radiative transfer in natural waters**. [s.l.] : Academic press, 1994.

MOBLEY, Curtis. **Ocean Optics Web Book**. 2021. Disponível em: <https://www.oceanopticsbook.info/view/inherent-and-apparent-optical-properties/introduction>. Acesso em: 27 out. 2023.

MONSALVE-HERRERA, Diana Jimena. **MODELO COMPORTAMENTAL COM BASE EM AGENTES PARA GESTÃO ADAPTATIVA DE ÁGUA: CASO DE ESTUDO DE CONSUMO DE ÁGUA RESIDENCIAL URBANA EM BRAZLANDIA/DF**. 2018. Tese de Doutorado - Universidade de Brasília, [S. l.], 2018.

MORADI, Masoud; KABIRI, Keivan. Spatio-temporal variability of red-green chlorophyll-a index from MODIS data – Case study: Chabahar Bay, SE of Iran. **Continental Shelf Research**, [S. l.], v. 184, p. 1–9, 2019. DOI: 10.1016/J.CSR.2019.07.002. Acesso em: 2 nov. 2023.

NASA. **Satellites**. 2023. Disponível em: <https://landsat.gsfc.nasa.gov/satellites/>. Acesso em: 26 out. 2023.

NGUYEN, Hao Quang; HA, Nam Thang; PHAM, Thanh Luu. Inland harmful cyanobacterial bloom prediction in the eutrophic Tri An Reservoir using satellite band ratio and machine learning approaches. **Environmental Science and Pollution Research**, [S. l.], v. 27, n. 9, p. 9135–9151, 2020. DOI: 10.1007/S11356-019-07519-3/METRICS. Disponível em: <https://link.springer.com/article/10.1007/s11356-019-07519-3>. Acesso em: 15 jan. 2024.

ODERMATT, Daniel; GITELSON, Anatoly; BRANDO, Vittorio Ernesto; SCHAEPMAN, Michael. Review of constituent retrieval in optically deep and complex waters from satellite imagery. **Remote Sensing of Environment**, [S. l.], v. 118, p. 116–126, 2012. DOI: 10.1016/J.RSE.2011.11.013. Acesso em: 31 out. 2023.

OGASHAWARA, Igor; MISHRA, Deepak; GITELSON, Anatoly. **Remote Sensing of Inland Waters: Background and Current State-of-the-Art Non-invasive monitoring of microalgal culture condition View project Smart Community Centric Urban Heat Monitoring Framework View project**. [s.l.: s.n.]. Disponível em: <http://www.sciencedirect.com:5070/book/9780128046449/bio-optical-modeling-and-remote-sensing-of-inland-waters>. Acesso em: 16 jan. 2024.

OLIVEIRA, Eduardo N. et al. Assessment of remotely sensed chlorophyll-a concentration in Guanabara Bay, Brazil. <https://doi.org/10.1117/1.JRS.10.026003>, [S. l.], v. 10, n. 2, p. 026003, 2016. DOI: 10.1117/1.JRS.10.026003. Disponível em:

<https://www.spiedigitallibrary.org/journals/journal-of-applied-remote-sensing/volume-10/issue-2/026003/Assessment-of-remotely-sensed-chlorophyll-a-concentration-in-Guanabara-Bay/10.1117/1.JRS.10.026003.full>. Acesso em: 1 nov. 2023.

PADOVESI-FONSECA, C.; PHILOMENO, M. G.; ANDREONI-BATISTA. **Limnological features after a flushing event in Paranoá Reservoir, central Brazil**. *Acta Limnol. Bras.* [s.l.: s.n.].

PAHLEVAN, Nima; WEI, Jianwei; SCHAAF, Crystal B.; SCHOTT, John R. Evaluating radiometric sensitivity of Landsat 8 over coastal/inland waters. **International Geoscience and Remote Sensing Symposium (IGARSS)**, [S. l.], p. 1393–1396, 2014. DOI: 10.1109/IGARSS.2014.6946695. Acesso em: 27 out. 2023.

PAINTER, Kristin J.; VENKITESWARAN, Jason J.; BAULCH, Helen M. Blooms and flows: Effects of variable hydrology and management on reservoir water quality. **Ecosphere**, [S. l.], v. 14, n. 3, 2023. DOI: 10.1002/ECS2.4472. Acesso em: 25 out. 2023.

PARK, Jungsu; KIM, Keug Tae; LEE, Woo Hyoung. Recent advances in information and communications technology (ICT) and sensor technology for monitoring water quality. **Water (Switzerland)**, [S. l.], v. 12, n. 2, 2020. DOI: 10.3390/w12020510.

PAXTON, Pamela; CURRAN, Patrick J.; BOLLEN, Kenneth A.; KIRBY, Jim; CHEN, Feinian. Monte Carlo experiments: Design and implementation. **Structural Equation Modeling**, [S. l.], v. 8, n. 2, p. 287–312, 2001. DOI: 10.1207/S15328007SEM0802\_7.

PEKEL, Jean François; COTTAM, Andrew; GORELICK, Noel; BELWARD, Alan S. High-resolution mapping of global surface water and its long-term changes. **Nature**, [S. l.], v. 540, n. 7633, p. 418–422, 2016. DOI: 10.1038/nature20584. Disponível em: <https://www.nature.com/articles/nature20584>. Acesso em: 27 out. 2023.

PIROMAL, Rodrigo Alexandre Sbravatti; OLIVEIRA, Marco Antonio Garrido; MORENO, Fellpe de Negreiros. **Proposta de plano de monitoramento da qualidade de água dos grandes corpos d'água do Distrito Federal e entorno**. [s.l.: s.n.].

POLIS, Gary A.; ANDERSON, Wendy B.; HOLT, Robert D. Toward an Integration of Landscape and Food Web Ecology: The Dynamics of Spatially Subsidized Food Webs. <https://doi.org/10.1146/annurev.ecolsys.28.1.289>, [S. l.], v. 28, p. 289–316, 1997. DOI: 10.1146/ANNUREV.ECOLSYS.28.1.289. Disponível em: <https://www.annualreviews.org/doi/abs/10.1146/annurev.ecolsys.28.1.289>. Acesso em: 26 out. 2023.

RAYMOND HUNT, E.; DAUGHTRY, C. S. T.; EITEL, Jan U. H.; LONG, Dan S. Remote Sensing Leaf Chlorophyll Content Using a Visible Band Index. **Agronomy Journal**, [S. l.], v. 103, n. 4, p. 1090–1099, 2011. DOI: 10.2134/AGRONJ2010.0395. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.2134/agronj2010.0395>. Acesso em: 15 jan. 2024.

REYNOLDS, C. S. **The Ecology of Phytoplankton**. [s.l.] : Cambridge University Press, 2006. DOI: 10.1017/CBO9780511542145.

RIBEIRO, Paulo Eduardo Aragon Marçal; HORA, Mônica de Aquino Galeano Massera Da. PERSPECTIVA DOS 20 ANOS DA LEI N°9.433/97: PERCEPÇÕES DOS COMITÊS DE BACIA HIDROGRÁFICA E DOS ÓRGÃOS GESTORES DE RECURSOS HÍDRICOS

ACERCA DO ENQUADRAMENTO DE CORPOS D'ÁGUA. **Demandas Essenciais para o Avanço da Engenharia Sanitária e Ambiental** 4, [S. l.], p. 228–237, 2020. DOI: 10.22533/AT.ED.52320210117. Acesso em: 26 out. 2023.

RITCHIE, Jerry C.; SCHIEBE, Frank R.; MCHENRY, J. Roger. **Remote Sensing of Suspended Sediments in Surface Waters**. [s.l.: s.n.].

RODRÍGUEZ-LÓPEZ, Lien; DURAN-LLACER, Iongel; GONZÁLEZ-RODRÍGUEZ, Lisdelys; ABARCA-DEL-RIO, Rodrigo; CÁRDENAS, Rolando; PARRA, Oscar; MARTÍNEZ-RETURETA, Rebeca; URRUTIA, Roberto. Spectral analysis using LANDSAT images to monitor the chlorophyll-a concentration in Lake Laja in Chile. **Ecological Informatics**, [S. l.], v. 60, 2020. DOI: 10.1016/j.ecoinf.2020.101183.

ROUSE, J. W. ., Jr. **Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation**. , 1974. . Acesso em: 28 out. 2023.

SHI, Peng; ZHANG, Yan; LI, Zhanbin; LI, Peng; XU, Guoce. Influence of land use and land cover patterns on seasonal water quality at multi-spatial scales. **CATENA**, [S. l.], v. 151, p. 182–190, 2017. DOI: 10.1016/J.CATENA.2016.12.017. Acesso em: 29 out. 2023.

SMITH, Val H. Eutrophication of freshwater and coastal marine ecosystems: A global problem. **Environmental Science and Pollution Research**, [S. l.], v. 10, n. 2, p. 126–139, 2003. DOI: 10.1065/ESPR2002.12.142/METRICS. Disponível em: <https://link.springer.com/article/10.1065/espr2002.12.142>. Acesso em: 26 out. 2023.

SOMLYODY, L.; ALTAFIN, I. Management of Water Resources and Eutrophication in the Federal District of Brazil. **Water Science and Technology**, [S. l.], v. 26, n. 7–8, p. 1813–1822, 1992. DOI: 10.2166/WST.1992.0625. Acesso em: 26 out. 2023.

SOUZA, Ana Carolina Pereira De. **ESTUDO DA QUALIDADE DA ÁGUA DO LAGO DESCOBERTO: ANÁLISE DE PARÂMETROS LIMNOLÓGICOS PARA AVALIAÇÃO DA INTEGRIDADE DO AMBIENTE**. 2018. Monografia de Projeto Final em Engenharia Ambiental - Universidade de Brasília, Brasília, 2018.

STEINKE, Valdir Adilson; MARTINS PALHARES DE MELO, Luis Alberto; MELO, Mamedes Luiz; FRANCA, Rafael Rodrigues Da; LUCENA, Rebecca Luna; STEINKE, Ercilia Torres. Trend Analysis of Air Temperature in the Federal District of Brazil: 1980–2010. **Climate** 2020, Vol. 8, Page 89, [S. l.], v. 8, n. 8, p. 89, 2020. DOI: 10.3390/CLI8080089. Disponível em: <https://www.mdpi.com/2225-1154/8/8/89/htm>. Acesso em: 29 out. 2023.

STRASSBURG, Bernardo B. N. et al. Moment of truth for the Cerrado hotspot. **Nature Ecology & Evolution** 2017 1:4, [S. l.], v. 1, n. 4, p. 1–3, 2017. DOI: 10.1038/s41559-017-0099. Disponível em: <https://www.nature.com/articles/s41559-017-0099>. Acesso em: 29 out. 2023.

TAMIMINIA, Haifa; SALEHI, Bahram; MAHDIANPARI, Masoud; QUACKENBUSH, Lindi; ADELI, Sarina; BRISCO, Brian. **Google Earth Engine for geo-big data applications: A meta-analysis and systematic review**. **ISPRS Journal of Photogrammetry and Remote Sensing** Elsevier B.V., , 2020. DOI: 10.1016/j.isprsjprs.2020.04.001.

TIAN, Chang; HAO, Daping; PEI, Haiyan; DOBLIN, Martina A.; REN, Ying; WEI, Jieli; FENG, Yawei. Phytoplankton Functional Groups Variation and Influencing Factors in a Shallow Temperate Lake. **Water environment research : a research publication of the Water Environment Federation**, [S. l.], v. 90, n. 6, p. 510–519, 2018. DOI: 10.2175/106143017X15131012153059. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/29789042/>. Acesso em: 27 out. 2023.

TÖRÖK, Liliana; TÖRÖK, Zsolt; CARSTEADT, Elfrida M.; SAVASTRU, Dan. Seasonal Variation of Eutrophication in Some Lakes of Danube Delta Biosphere Reserve. **Water Environment Research**, [S. l.], v. 89, n. 1, p. 86–94, 2017. DOI: 10.2175/106143016X14733681696248. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.2175/106143016X14733681696248>. Acesso em: 27 out. 2023.

TUCKER, Compton J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, [S. l.], v. 8, n. 2, p. 127–150, 1979. DOI: 10.1016/0034-4257(79)90013-0. Acesso em: 28 out. 2023.

TUNDISI, Jose Galizia. **Água no século XXI: enfrentando a escassez**. São Carlos: RiMa/IEE, 2003.

TUNDISI, José Galizia. Recursos hídricos no futuro: problemas e soluções. **Estudos Avançados**, [S. l.], v. 22, n. 63, p. 7–16, 2008. DOI: 10.1590/S0103-40142008000200002. Disponível em: <https://www.scielo.br/j/ea/a/7gyMPtTzfkYfWWsMHqVLTqm/>. Acesso em: 29 out. 2023.

TUNDISI, José Galizia.; TUNDISI, Takako Matsumura. **Limnologia**. 1ª Edição ed. São Paulo: Oficina de Textos, 2008.

USGS. **How do I use a scale factor with Landsat Level-2 science products?** 2023. Disponível em: <https://www.usgs.gov/faqs/how-do-i-use-a-scale-factor-landsat-level-2-science-products>. Acesso em: 14 nov. 2023.

VERMOTE, Eric; JUSTICE, Chris; CLAVERIE, Martin; FRANCH, Belen. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, [S. l.], v. 185, p. 46–56, 2016. DOI: 10.1016/j.rse.2016.04.008.

VINCENT, Robert K.; QIN, Xiaoming; MCKAY, R. Michael L.; MINER, Jeffrey; CZAJKOWSKI, Kevin; SAVINO, Jeffrey; BRIDGEMAN, Thomas. Phycocyanin detection from LANDSAT TM data for mapping cyanobacterial blooms in Lake Erie. **Remote Sensing of Environment**, [S. l.], v. 89, n. 3, p. 381–392, 2004. DOI: 10.1016/j.rse.2003.10.014.

WANG, Jialin; CHEN, Xiaoling. A new approach to quantify chlorophyll-a over inland water targets based on multi-source remote sensing data. **Science of The Total Environment**, [S. l.], v. 906, p. 167631, 2024. DOI: 10.1016/J.SCITOTENV.2023.167631. Acesso em: 14 jan. 2024.

WANG, Menghua et al. The NIR-SWIR combined atmospheric correction approach for MODIS ocean color data processing. **Optics Express**, Vol. 15, Issue 24, pp. 15722–15733, [S. l.], v. 15, n. 24, p. 15722–15733, 2007. DOI: 10.1364/OE.15.015722. Disponível em:

<https://opg.optica.org/viewmedia.cfm?uri=oe-15-24-15722&seq=0&html=true>. Acesso em: 26 out. 2023.

WATANABE, Fernanda; ALCÂNTARA, Enner; RODRIGUES, Thanan; ROTTA, Luiz; BERNARDO, Nariane; IMAI, Nilton. Remote sensing of the chlorophyll-a based on OLI/Landsat-8 and MSI/Sentinel-2a (Barra Bonita Reservoir, Brazil). **Anais da Academia Brasileira de Ciências**, [S. l.], v. 90, n. 2, p. 1987–2000, 2018. DOI: 10.1590/0001-3765201720170125.

WATANABE, Fernanda; MISHRA, Deepak R.; ASTUTI, Ike; RODRIGUES, Thanan; ALCÂNTARA, Enner; IMAI, Nilton N.; BARBOSA, Cláudio. Parametrization and calibration of a quasi-analytical algorithm for tropical eutrophic waters. **ISPRS Journal of Photogrammetry and Remote Sensing**, [S. l.], v. 121, p. 28–47, 2016. DOI: 10.1016/J.ISPRSJPRS.2016.08.009. Acesso em: 15 nov. 2023.

WITTER, Donna L.; ORTIZ, Joseph D.; PALM, Sarah; HEATH, Robert T.; BUDD, Judith W. Assessing the application of SeaWiFS ocean color algorithms to Lake Erie. **Journal of Great Lakes Research**, [S. l.], v. 35, n. 3, p. 361–370, 2009. DOI: 10.1016/J.JGLR.2009.03.002. Acesso em: 1 nov. 2023.

XIA, Yinglin. Correlation and association analyses in microbiome study integrating multiomics in health and disease. **Progress in Molecular Biology and Translational Science**, [S. l.], v. 171, p. 309–491, 2020. DOI: 10.1016/BS.PMBTS.2020.04.003. Acesso em: 15 nov. 2023.

XU, Qing-Song; LIANG, Yi-Zeng. **Monte Carlo cross validation Chemometrics and Intelligent Laboratory Systems**. [s.l.: s.n.]. Disponível em: [www.elsevier.com/locate/chemometrics](http://www.elsevier.com/locate/chemometrics).

YU, Hong; CAI, Qi-ming; WU, Jing-Iu. Study on characteristic of the absorption and scattering coefficients of Taihu Lake waters. **Advances in Water Science**, [S. l.], p. 46–49, 2003.

ZANGO, Baba-Serges; SEIDOU, Ousmane; SARTAJ, Majid; NAKHAEI, Nader; STILES, Kelly. Impacts of urbanization and climate change on water quantity and quality in the Carp River watershed. **Journal of Water and Climate Change**, [S. l.], v. 13, n. 2, p. 786–816, 2022. DOI: 10.2166/WCC.2021.158. Disponível em: <http://iwaponline.com/jwcc/article-pdf/13/2/786/1013698/jwc0130786.pdf>. Acesso em: 29 out. 2023.

ZHAO, Qiang; YU, Le; LI, Xuecao; PENG, Dailiang; ZHANG, Yongguang; GONG, Peng. Progress and trends in the application of google earth and google earth engine. **Remote Sensing**, [S. l.], v. 13, n. 18, p. 3778, 2021. DOI: 10.3390/RS13183778/S1. Disponível em: <https://www.mdpi.com/2072-4292/13/18/3778/htm>. Acesso em: 27 out. 2023.

ZIMBA, Paul V.; GITELSON, Anatoly. Remote estimation of chlorophyll concentration in hyper-eutrophic aquatic systems: Model tuning and accuracy optimization. **Aquaculture**, [S. l.], v. 256, n. 1–4, p. 272–286, 2006. DOI: 10.1016/J.AQUACULTURE.2006.02.038. Acesso em: 16 jan. 2024.

## APÊNDICE

### 1. Script do Google Earth Engine

O script a seguir foi utilizado para a extração das informações de reflectância de toda a série histórica das imagens Landsat no estudo. O acesso ao script na plataforma do *Google Earth Engine* também está disponível no link: <https://code.earthengine.google.com/7562c1a4c9f94f2808d90baf434190d6>.

```
////Script de extração da reflectância de superfície dos pontos de coleta dos reservatórios
```

```
// Funções
```

```
//1- Buffer
```

```
function bufferPoints(radius, bounds) {  
  return function(pt) {  
    pt = ee.Feature(pt);  
    return bounds ? pt.buffer(radius).bounds() : pt.buffer(radius);  
  };  
}
```

```
function zonalStats(ic, fc, params) {  
  var _params = {  
    reducer: ee.Reducer.mean(),  
    scale: null,  
    crs: null,  
    bands: null,  
    bandsRename: null,  
    imgProps: null,  
    imgPropsRename: null,  
    datetimeName: 'datetime',  
    datetimeFormat: 'YYYY-MM-dd HH:mm:ss'  
  };  
  if (params) {
```

```

for (var param in params) {
  _params[param] = params[param] || _params[param];
}
}

var imgRep = ic.mean();
var nonSystemImgProps = ee.Feature(null)
  .copyProperties(imgRep).propertyNames();
if (!_params.bands) _params.bands = imgRep.bandNames();
if (!_params.bandsRename) _params.bandsRename = _params.bands;
if (!_params.imgProps) _params.imgProps = nonSystemImgProps;
if (!_params.imgPropsRename) _params.imgPropsRename = _params.imgProps;

// Mapear a função para as coleções
var results = ic.map(function(img) {
  img = ee.Image(img.select(_params.bands, _params.bandsRename))
    .set(_params.datetimeName, img.date().format(_params.datetimeFormat))
    .set('timestamp', img.get('system:time_start'));
  var propsFrom = ee.List(_params.imgProps)
    .cat(ee.List([_params.datetimeName, 'timestamp']));
  var propsTo = ee.List(_params.imgPropsRename)
    .cat(ee.List([_params.datetimeName, 'timestamp']));
  var imgProps = img.toDictionary(propsFrom).rename(propsFrom, propsTo);
  var fcSub = fc.filterBounds(img.geometry());
  return img.reduceRegions({
    collection: fcSub,
    reducer: _params.reducer,
    scale: _params.scale,
    crs: _params.crs
  })
});

```

```

.map(function(f) {
  return f.set(imgProps);
});
}).flatten().filter(ee.Filter.notNull(_params.bandsRename));
return results;
}
/////Inserir os pontos de coleta
var pts = ee.FeatureCollection("users/iararesendedafonseca/pontos_sirgas_desloc");
/////Definição do buffer de 45m para criação da janela 3x3
var ptsLandsat = pts.map(bufferPoints(45, true));
/////Máscara de nuvens para as coleções Landsat 457
function fmask457(img) {
  // Bit 0 - Fill
  // Bit 1 - Dilated Cloud
  // Bit 2 - Unused
  // Bit 3 - Cloud
  // Bit 4 - Cloud Shadow
  var qaMask = img.select('QA_PIXEL').bitwiseAnd(parseInt('11111', 2)).eq(0);
  var saturationMask = img.select('QA_RADSAT').eq(0);

  // Aplicação do fator de escala segundo orientações da USGS para as imagens nível 2
  var opticalBands = img.select('SR_B.').multiply(0.0000275).add(-0.2);
  var thermalBand = img.select('ST_B6').multiply(0.00341802).add(149.0);

  return img.addBands(opticalBands, null, true)
    .addBands(thermalBand, null, true)
    .updateMask(qaMask)
    .updateMask(saturationMask);
}
/////Máscara de nuvens para as coleções Landsat 89

```

```

function fmask89(img) {
  // Bit 0 - Fill
  // Bit 1 - Dilated Cloud
  // Bit 2 - Cirrus
  // Bit 3 - Cloud
  // Bit 4 - Cloud Shadow
  var qaMask = img.select('QA_PIXEL').bitwiseAnd(parseInt('11111', 2)).eq(0);
  var saturationMask = img.select('QA_RADSAT').eq(0);

  // Aplicação do fator de escala segundo orientações da USGS para as imagens nível 2
  var opticalBands = img.select('SR_B.').multiply(0.0000275).add(-0.2);
  var thermalBands = img.select('ST_B.*').multiply(0.00341802).add(149.0);
  return img.addBands(opticalBands, null, true)
    .addBands(thermalBands, null, true)
    .updateMask(qaMask)
    .updateMask(saturationMask);
}

// Compatibilização do sensores Landsat para a produção dos valores das bandas de acordo
// com o nome
function renameOli(img) {
  return img.select(
    ['SR_B2', 'SR_B3', 'SR_B4', 'SR_B5', 'SR_B6', 'SR_B7'],
    ['Blue', 'Green', 'Red', 'NIR', 'SWIR1', 'SWIR2']);
}

function renameEtm(img) {
  return img.select(
    ['SR_B1', 'SR_B2', 'SR_B3', 'SR_B4', 'SR_B5', 'SR_B7'],
    ['Blue', 'Green', 'Red', 'NIR', 'SWIR1', 'SWIR2']);
}

////Aplicação das funções de ma
function prepOli(img) {
  img = fmask89(img);
}

```

```

img = renameOli(img);
return img;
function prepEtm(img) {
img = fmask457(img);
img = renameEtm(img);
return img;
}
////Seleção das coleções
var oliCol2 = ee.ImageCollection('LANDSAT/LC09/C02/T1_L2')
.filterBounds(ptsLandsat)
.map(prepareOli);
var oliCol = ee.ImageCollection('LANDSAT/LC08/C02/T1_L2')
.filterBounds(ptsLandsat)
.map(prepareOli);
//var etmCol = ee.ImageCollection('LANDSAT/LE07/C02/T1_L2')
// .filterBounds(ptsLandsat)
// .map(prepareEtm);
var tmCol = ee.ImageCollection('LANDSAT/LT05/C02/T1_L2')
.filterBounds(ptsLandsat)
.map(prepareEtm);

//var landsatCol = oliCol.merge(oliCol2).merge(etmCol).merge(tmCol);

var landsatCol = oliCol.merge(oliCol2).merge(tmCol);

// Parâmetros Landsat para a aplicação da função que calcula o buffer
var params = {
reducer: ee.Reducer.mean(),
scale: 30, //scale means pixel resolution
crs: 'EPSG:31983', //Coordinate Reference System SIRGAS 2000 / UTM zone 23S

```

```
bands: ['Blue', 'Green', 'Red', 'NIR', 'SWIR1', 'SWIR2'],
bandsRename: ['ls_blue', 'ls_green', 'ls_red', 'ls_nir', 'ls_swir1', 'ls_swir2'],
imgProps: ['SPACECRAFT_ID', 'SENSOR_ID'],
imgPropsRename: ['img_id', 'satellite'],
datetimeName: 'DATE_ACQUIRED',
datetimeFormat: 'YYYY-MM-dd'
};
```

```
// Extrair os valores da média dos pixels do buffer por imagem
var ptsLandsatStats = zonalStats(landsatCol, ptsLandsat, params);
print(ptsLandsatStats.limit(100));
```

```
///Exportar para o Google Drive o arquivo csv
```

```
Export.table.toDrive({
  collection: ptsLandsatStats
})
```

```
Export.table.toDrive({
  collection:ptsLandsatStats,
  description:'table_feat',
  fileFormat:'shp'
})
```

## 2. Artigo da dissertação

O artigo da dissertação foi submetido para a revista Engenharia Sanitária e Ambiental (ISSN: 1809-4457) no dia 04/12/2023 para a apreciação dos revisores. Segue uma cópia da submissão realizada, em cumprimento ao Artigo 32 § 2º do Regulamento do Programa de Pós-Graduação em Tecnologia Ambiental e Recursos Hídricos da Universidade De Brasília.

### **Comportamento espaço temporal da concentração de clorofila-a nos corpos hídricos do Distrito Federal por meio do sensoriamento remoto**

#### **Resumo**

Os mananciais de abastecimento urbano são sistemas lacustres complexos e que exigem um monitoramento contínuo para a detecção de interferências pontuais e difusas que prejudiquem a qualidade da água e coloquem a saúde da população em risco. O sensoriamento remoto se destaca como uma ferramenta que pode permitir uma ação rápida dos gestores perante situações adversas à qualidade em função de seu alto potencial temporal e espacial. Nesse sentido, o presente estudo tem como objetivo propor um método de estimativa espaço temporal de clorofila-a preciso e acurado para os reservatórios do Distrito Federal, por meio de um modelo semiempírico baseado na série histórica de imagens Landsat. O estudo se empenhou em encontrar um modelo semiempírico para a predição das concentrações de clorofila-a para todos os reservatórios do Distrito Federal: Lago Paranoá, Descoberto e Santa Maria. Como resultado, foi encontrado um modelo referente à série histórica dos dados do Landsat 5, de 1984 a 2011, utilizando a razão de banda azul e verde em um ajuste polinomial satisfatório ( $R^2 = 0,69$  e  $RMSE = 12,88 \mu\text{g/L}$ ). E um modelo para os dados dos sensores OLI, de 2013 a 2023, referente aos satélites Landsat 8 e 9, com a utilização da razão das bandas espectrais vermelho e verde e um ajuste exponencial dos dados ( $R^2 = 0,69$  e  $RMSE = 3,36 \mu\text{g/L}$ ).

**Palavras-chave:** Clorofila-a. Landsat. Reservatórios de abastecimento urbano. Google Earth Engine.

#### **Abstract**

Urban water supply sources are complex lacustrine systems that require continuous monitoring to detect point and diffuse interferences that could compromise water quality and put public health at risk. Remote sensing stands out as a tool that can enable quick action by managers in adverse quality situations due to its high temporal and spatial potential. In this sense, the present study aims to propose a precise and accurate spatiotemporal estimation method for chlorophyll-a in the reservoirs of the Federal District, using a semi-empirical

model based on the historical series of Landsat images. The study sought to find a semi-empirical model for predicting chlorophyll-a concentrations for all reservoirs in the Federal District: Paranoá Lake, Descoberto, and Santa Maria. As a result, a model was found for the historical data series of Landsat 5, from 1984 to 2011, using the ratio of blue and green bands in a satisfactory polynomial fit ( $R^2 = 0.69$  and  $RMSE = 12.88 \mu\text{g/L}$ ). Another model was developed for the OLI sensor data, from 2013 to 2023, corresponding to Landsat 8 and 9 satellites, using the ratio of red and green spectral bands and an exponential fit of the data ( $R^2 = 0.69$  and  $RMSE = 3.36 \mu\text{g/L}$ ).

**Keywords:** Chlorophyll-a. Landsat. Urban water supply reservoirs. Google Earth Engine.

## 1 INTRODUÇÃO

Diversos ecossistemas aquáticos foram transformados no intuito de suprir as crescentes demandas da urbanização. Dentre estes ecossistemas, os reservatórios urbanos se destacam pela complexidade e importância na segurança da saúde pública (LI et al., 2022; SHI et al., 2017). Abastecimento urbano, irrigação, geração de energia elétrica, navegação, recreação são usos conhecidos de um reservatório e, para integrar todos esses usos, rotinas de monitoramento e acompanhamento da qualidade da água devem ser desenvolvidos (TUNDISI, 2008).

As mudanças demográficas, de uso e cobertura da terra e as mudanças climáticas ameaçam os ambientes aquáticos, causando perdas de habitats, prejuízos à saúde pública, aumento da demanda hídrica e desafios nos sistemas de monitoramento (KONDRATYEVA et al., 2020; PAINTER; VENKITESWARAN; BAULCH, 2023; ZANGO et al., 2022). Complementarmente, tais impactos ocasionam o aumento do aporte de nutrientes, o aumento da temperatura e o aumento da estratificação térmica promovendo também a expansão das florações de cianobactérias (CAREY et al., 2012; HAYES et al., 2020). Cerca de 75% dessas florações são tóxicas (CHORUS, 2001) e mais de 80 espécies de cianobactérias são associadas a produção de cianotoxinas, prejudiciais à saúde humana (AGUILERA et al., 2023).

Segundo Tundisi e Tundisi (2008), uma base de dados consolidada e transformada em instrumento de gestão pode ser uma das formas mais eficazes de enfrentar o problema de escassez de água, estresse de água e deterioração da qualidade. Para o monitoramento, são utilizados métodos tradicionais de medição da qualidade de água realizados em campo ou em laboratórios, o que conduz a respostas mais lentas sobre as mudanças do ambiente. Sendo assim, faz-se necessário apoiar o monitoramento tradicional com tecnologias que forneça respostas mais ágeis quanto às mudanças do ambiente, espacializem os fatores influentes,

permitindo a identificação de poluições difusas e atuações rápidas contra agentes causadores da degradação de um corpo hídrico.

Nos últimos anos, com o rápido desenvolvimento das tecnologias de sensoriamento remoto, em escalas globais e regionais, a obtenção de informações multitemporais através sensores de imageamento e modelos matemáticos, tornou possível o acompanhamento das alterações nos ambientes aquáticos (FENG et al., 2022). Apesar da evolução, o sensoriamento remoto em ambientes aquáticos ainda encontra dificuldades e limitações. As limitações estão ligadas às características do sistema satélite-sensor, uma vez que o monitoramento de ambientes aquáticos continentais demanda um conjunto fundamental de bandas espectrais na região visível, além de uma resolução espacial suficiente para observação de ambientes de diferentes formas e dimensões (BARBOSA; NOVO; MARTINS, 2019).

O desafio é encontrar tecnologias gratuitas e de livre acesso para atender as elevadas exigências tecnológicas que requerem o estudo de um corpo d'água pela técnica de sensoriamento remoto. Dentre as ferramentas utilizadas para os estudos de sensoriamento remoto, o Google Earth Engine se destaca por ser uma plataforma em nuvem com alta capacidade de processamento de grandes bancos de dados geoespaciais e de livre acesso (GORELICK et al., 2017).

Além disso, os estudos para quantificação e monitoramento de clorofila-a evoluem na aplicação de imagens de satélite gratuitas e sem restrições de licenças ou outros mecanismos de controle. Na década de 90, Gitelson (1992) identificou que o pico de reflectância próximo ao comprimento de onda de 700nm era diretamente relacionado com a concentração de clorofila-a na água, e sua constatação impulsionou diversos progressos na área. Os modelos de estimativa de clorofila-a relacionam a primeira e a segunda faixa de absorção nos comprimentos de onda de 442nm e 665nm, respectivamente (BRICAUD; ROESLER; ZANEVELD, 1995), e aliado com o pico de reflectância em 700nm (GITELSON, 1992). Entretanto, a quantificação dessas feições são um desafio em ambientes oligotróficos (GUANTER et al., 2010).

No Distrito Federal os reservatórios de abastecimento urbano são classificados como oligotróficos, ou seja, de baixa produtividade primária e concentrações baixas de clorofila-a (MACHADO; BAPTISTA, 2016; SOUZA, 2018). Entretanto, faz-se necessário apoiar o monitoramento desses corpos hídricos para permitir respostas rápidas e identificação das possíveis interferências na qualidade de água desses mananciais, e o sensoriamento remoto se mostrou como uma tecnologia aplicável no monitoramento da região (BORGES et al., 2020; MACHADO; BAPTISTA, 2016; MAGALHÃES et al., 2022).

No Brasil, Araújo et al. (2023) analisou a incidência de florações de cianobactérias em São Paulo a partir da série histórica Landsat processada no Google Earth Engine e relacionou com as mudanças de uso e ocupação da terra e com fatores climáticos. Lobo et al. (2021), criou um algoritmo para monitoramento de clorofila-a na bacia do Rio Tietê e implementou, no GEE, um aplicativo para monitorar temporalmente as concentrações do pigmento.

Diante do exposto, o presente estudo tem como objetivo apoiar na elaboração de um sistema de monitoramento de clorofila-a para os reservatórios do Distrito Federal, através de um modelo semiempírico baseado na série histórica de imagens Landsat. Para isso, serão utilizados dados de campo coletados pela Companhia de Saneamento Ambiental do Distrito Federal (CAESB) e dados de reflectância de superfície dos sensores da série Landsat processados na plataforma Google Earth Engine.

## **2. METODOLOGIA**

### **2.1 Área de estudo**

A área do estudo são três reservatórios de abastecimento urbano do Distrito Federal (DF), Lago Paranoá, Descoberto e Santa Maria, localizados na macrorregião centro-oeste do Brasil (Figura 1). A região do DF possui uma área territorial de 5,7 milhões de km<sup>2</sup> e possui uma população residente de 2,8 milhões de habitantes, configurando a maior densidade demográfica dentre as 27 unidades da federação do país (IBGE, 2022).

De acordo com a classificação Köppen, o clima no Distrito Federal é de savana tropical, com inverno seco e os maiores índices de precipitação durante o verão (IPEDF, 2020). Os sistemas de circulação atmosférica associados à posição geográfica do Distrito Federal definem dois períodos: um período seco e frio que vai do final de abril a setembro, e um período quente e chuvoso que vai do final de outubro ao final de março (STEINKE et al., 2020).

A qualidade da água dos três reservatórios objetos deste estudo, são monitorados pela Companhia de Saneamento Ambiental do Distrito Federal nos pontos indicados em vermelho no mapa da Figura 1. São seis pontos de amostragem no Lago Paranoá (A4, A5, B, C, D e E), um ponto no reservatório Descoberto (A) e um no Santa Maria (A).

O Lago Paranoá foi criado em 1959 com objetivos paisagísticos, recreativos, de geração de energia elétrica e para a diluição de efluentes (MARQUES, 2021; MENEZES JR.; SINOTI; SARAIVA, 2001). Na década de 70, os braços do Bananal (Ponto E – Figura 4.2) e do Riacho Fundo (Pontos A4 e A5, Figura 4.2) eram considerados eutróficos devido ao lançamento de esgotos sem tratamento (DE OLIVEIRA; KRAU, 1970). Em 2017, devido à

escassez hídrica enfrentada no DF, o Lago Paranoá passou a ser utilizado como reservatório para abastecimento urbano (ADASA et al., 2018).

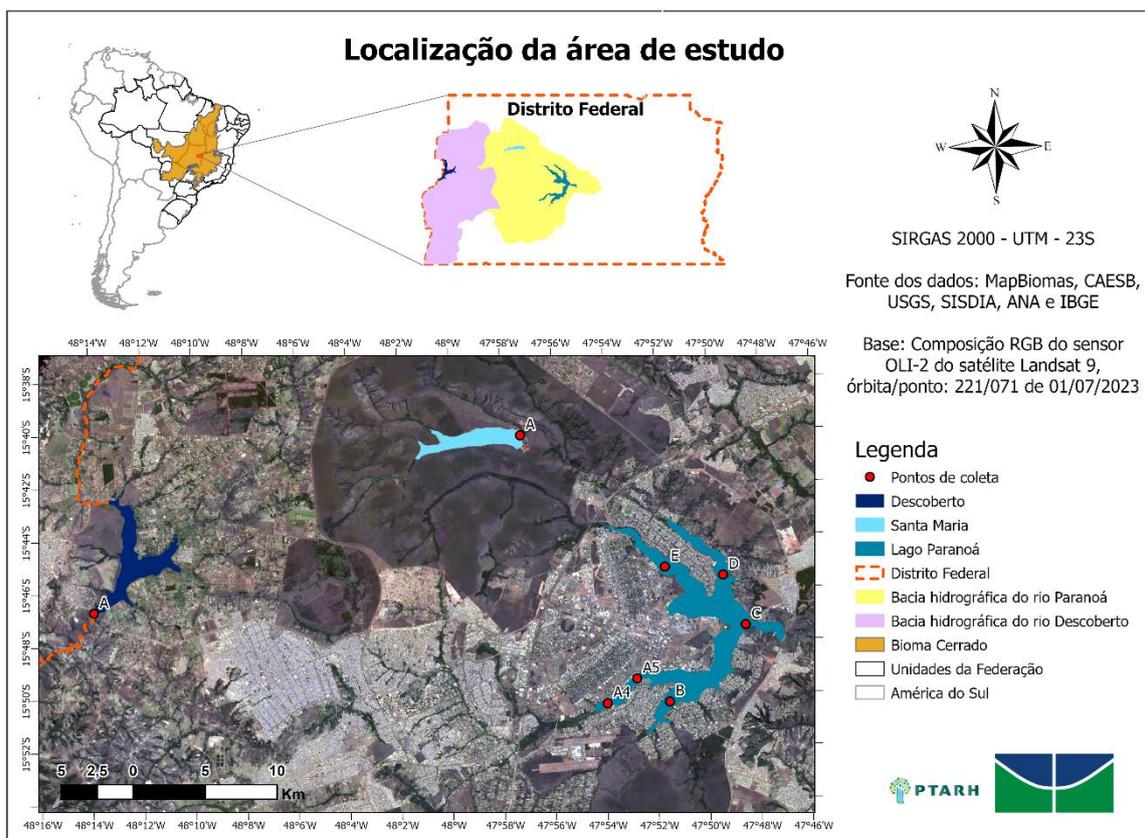


Figura 1 – Área de estudo

O reservatório Santa Maria se insere Parque Nacional de Brasília (BRASIL, 1961), e em 2022, foi responsável pelo abastecimento de 11% do Distrito Federal (CAESB, 2023c). O reservatório Descoberto é responsável pelo abastecimento de cerca de 60% da população do DF (ADASA et al., 2018) e está inserido em uma Área de Proteção Ambiental (BRASIL, 1983), porém apesar de serem proibidas atividades que gerem fontes pontuais de contaminantes, a área vem sofrendo constante degradação ambiental principalmente pela poluição difusa advinda da água de escoamento (DE VITO, 2007).

## 2.2 Aquisição dos dados e estatística descritiva

A primeira fase do escopo metodológico do estudo é referente ao levantamento e compatibilização dos dados iniciais de concentração de clorofila-a coletadas em campo e das imagens de reflectância de superfície do Landsat. Após a compatibilização, foram realizadas estatísticas descritivas com o intuito de entender o comportamento dos dados de clorofila-a que serão aplicados nos modelos preditivos.

Os dados de concentração de clorofila-a coletados em campo foram fornecidos pela Companhia de Saneamento Ambiental do Distrito Federal (CAESB) e compreenderam o

período de janeiro de 1984 a outubro de 2023, totalizando um banco de dados de quase 40 anos de registros do acompanhamento deste parâmetro limnológico. Para estes dados, foram realizados testes de normalidade (Shapiro-Wilk e Kolmogorov-Smirnov) e o teste não paramétrico de Kruskal-Wallis.

Quanto aos dados de sensoriamento remoto, foram utilizadas as coleções 2 das imagens das séries Landsat 5, 8 e 9, referentes às imagens de reflectância de superfície produzidas pela United States Geological Survey (USGS) a partir de algoritmos específicos para cada sensor. No GEE foram realizadas as inserções de pontos de amostragens, a aplicação de uma máscara de nuvens e da correção do fator de escala da imagem e o cálculo da média da reflectância da janela 3x3 pixels para obtenção dos valores de reflectância de superfície. Os dois conjuntos de dados das séries temporais foram trabalhadas no RStudio e as janelas de defasagem foram avaliadas. Após a avaliação optou-se por utilizar a janela de 3 dias de defasagem para considerar mais pares de dados para performar os modelos.

Na etapa de seleção dos modelos preditivos, os dados das razões de bandas e das bandas individuais avaliadas foram produzidos no RStudio. Para a produção desses dados foram feitas algumas considerações para garantir a qualidade radiométrica do valor de reflectância a ser utilizado nos modelos.

Primeiramente foram selecionados os dias sem ocorrência de chuva de acordo com os dados do INMET (INMET, 2023). E com os dados sem ocorrência de chuva, foram realizadas análises individuais das imagens selecionadas para verificação da qualidade radiométrica e possíveis erros de geometria ou incidência de nuvens nos reservatórios a serem estudados.

Após a filtragem das imagens com boa qualidade geométrica e radiométrica para utilização no modelo, foi aplicada a correção sunglint. Na aplicação da correção, os valores de reflectância das bandas da região do visível (azul, verde, vermelho e infravermelho próximo) foram subtraídas do valor da banda do infravermelho de ondas curtas (SWIR).

A partir dos dados corrigidos e verificados, foi possível realizar a etapa de desenvolvimento do modelo preditivo de concentração de clorofila-a nos reservatórios. A Tabela 1 mostra os modelos preditivos testados, bem como as razões de bandas utilizadas para o desenvolvimento de um modelo preditivo a ser aplicado em todos os reservatórios do Distrito Federal.

Tabela 1 - Modelos preditivos testados no estudo

<b>Equação</b>	<b>Referência</b>
<b>Modelos de banda única</b>	
Chl-a = B	

Chl-a = G	
Chl-a = R	
Chl-a = NIR	
<b>Modelos de duas bandas</b>	
Chl-a = R/NIR	(GILERSON et al., 2010)
Chl-a = B/G	(GORDON; MOREL, 1983)
Chl-a = G/R	(LE et al., 2013b)
<b>Modelos de índices</b>	
NDVI Chl-a = [NIR-R]/ [NIR+R]	(ROUSE, 1974)
GNDVI Chl-a = [NIR-G]/ [NIR+G]	(DAUGHTRY et al., 2000)
NGRDI Chl-a = [G-R]/ [G+R]	(TUCKER, 1979)
NDCI Chl-a = [R <sub>RS</sub> (708) - R <sub>RS</sub> (665)]/ [R <sub>RS</sub> (708) + R <sub>RS</sub> (665)]	(MISHRA; MISHRA, 2010)

### 2.3 Validação

Após a seleção dos modelos preditivos para cada satélite, os pares de valores de concentração de clorofila-a de campo e os valores das razões de bandas dos modelos preditivos escolhidos foram calibrados utilizando a técnica de validação Monte Carlo, com 10.000 iterações. A cada iteração, 70% das amostras foram utilizadas para calibração e os 30% restantes foram para a validação.

A partir da equação definida no Monte Carlo para os sensores OLI (Landsat 8 e 9), foi feita uma validação com dados independentes. A validação modelo foi realizada com dados de concentração de clorofila-a da CAESB, de junho de 2023 a outubro de 2023. Para essa última validação, foram calculados os parâmetros estatísticos: erro sistemático (Bias), Raiz do Erro Quadrático Médio (RMSE) e Raiz do Erro Quadrático Normalizada (NRMSE).

Após a aplicação dos modelos preditivos listados na Tabela 1, foi selecionado o modelo que apresentou um melhor desempenho na predição de clorofila-a para a elaboração de mapas da distribuição espacial do pigmento ao longo da série histórica. Para os mapas, foi utilizada a plataforma do Google Earth Engine para aplicação do modelo preditivo, a partir da máscara de água calculada pelo índice NDWI, e em seguida, os rasters, que seriam as imagens com as concentrações de clorofila-a preditas pelos modelos, foram inseridas no ArcGis Pro para a produção dos layouts de mapas de distribuição espacial.

## 3 RESULTADOS E DISCUSSÃO

### 3.1 Modelo preditivo de clorofila-a

Para o Landsat 5, inicialmente, foram considerados 145 pares de dados de campo e reflectância B/G, nestes, foram testados os ajustes de regressão linear, exponencial,

polinomial e logaritmo, durante esta investigação, também foram detectadas observações que se encontravam fora do intervalo de confiança.

Durante a análise do comportamento dos dados foi possível observar um melhor desempenho do ajuste polinomial, além disso, foi detectado 4 pontos amostrais que apresentavam um comportamento fora do intervalo de confiança do ajuste polinomial. Posto isso, 141 observações referentes ao Landsat 5, compreendendo a janela temporal de 29/05/1986 a 12/09/2011 foram ajustadas em um modelo polinomial.

Selecionado o ajuste polinomial para a análise do Landsat 5, aplicou-se o método de validação cruzada Monte Carlo para um aperfeiçoamento do modelo preditivo. O método de validação cruzada utilizou 70% das amostras para o treinamento do modelo e 30% para o teste do modelo em 10.000 iterações. A Figura 2 ilustra o histograma da distribuição do coeficiente de determinação  $R^2$  para o modelo B/G.

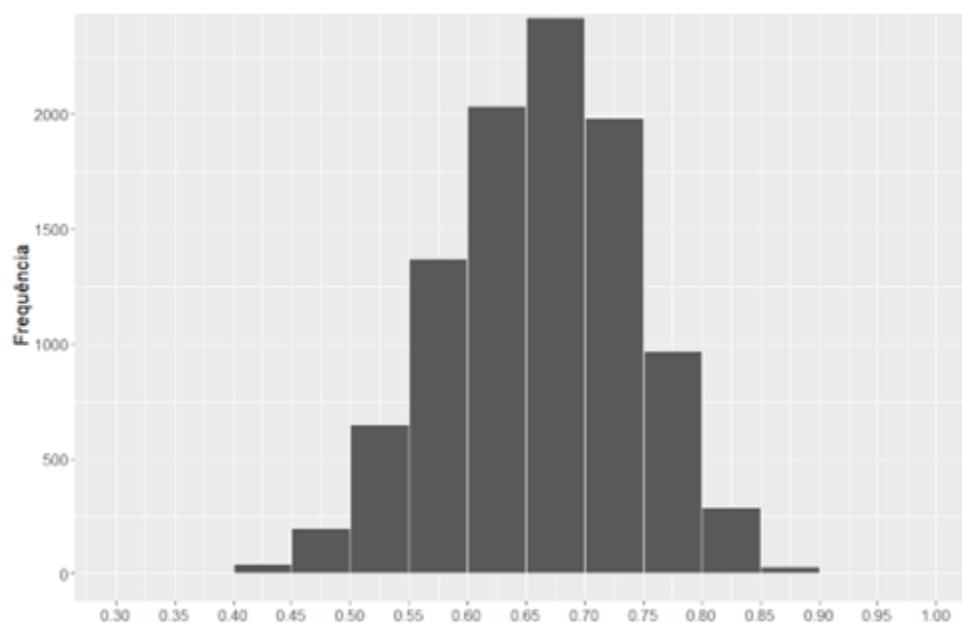


Figura 2 – Histograma da distribuição do  $R^2$  nas 10.000 iterações do método Monte Carlo para o modelo azul-verde

A partir do histograma possível observar uma maior ocorrência das iterações do método Monte Carlo no intervalo de  $R^2$  de 0,65 a 0,70. Desta forma, selecionou-se equações dentro desse intervalo com menores RMSE para definir a equação mais adequada para o modelo preditivo de clorofila-a.

A equação do modelo selecionada apresentou um ajuste  $R^2$  de 0,69 e um RMSE de 12,88  $\mu\text{g/L}$ . A Figura 3 demonstra o comportamento polinomial dos ajustes utilizados antes da aplicação do método Monte Carlo e depois da aplicação do método. Baseado no melhor

desempenho da equação do método, segue a Equação 1 referente ao modelo preditivo de clorofila-a nos reservatórios do Distrito Federal selecionada para a série do Landsat 5.

$$\text{Chl-a} = 203,61 - 511,22 \times (\text{B/G}) + 318,68 \times (\text{B/G})^2 \quad (1)$$

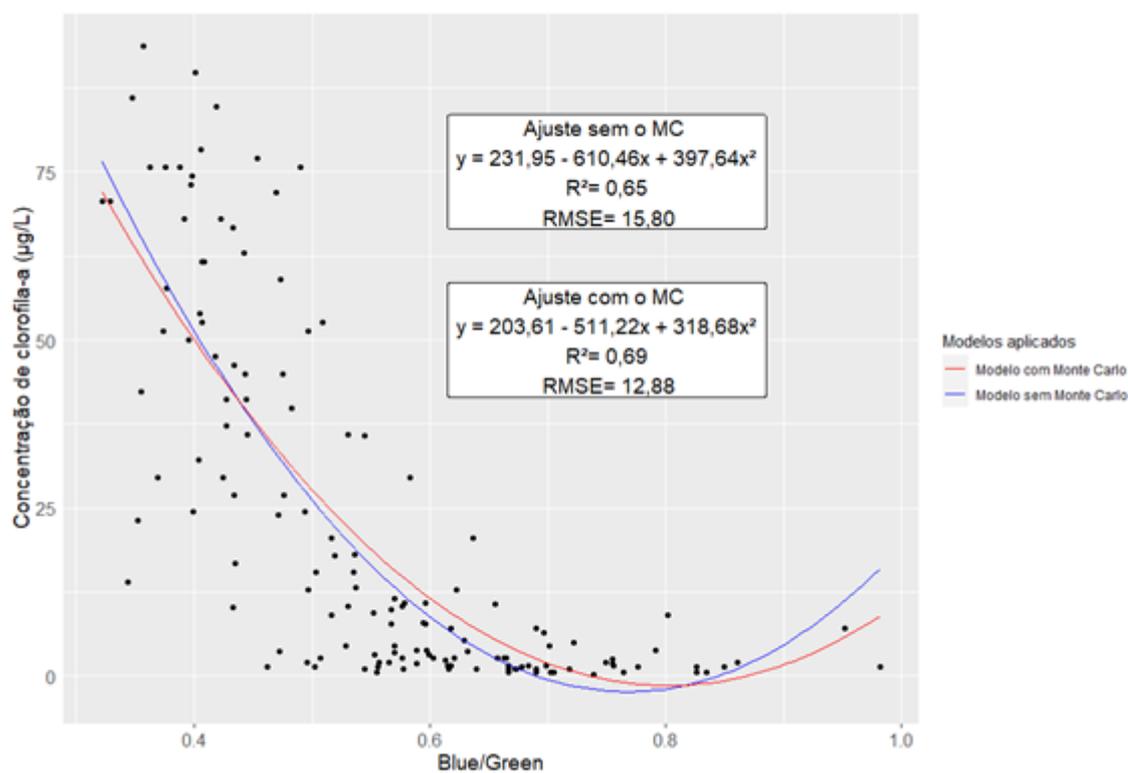


Figura 3 – Comportamento polinomial do Landsat 5

Dentre os estudos que utilizaram a razão B/G para estimativa de clorofila-a em lagos e reservatórios, este, referente aos reservatórios do Distrito Federal foi o que utilizou um maior número de pontos de observação para a estimativa do modelo. Com ajuste de regressão similar, Witter et al. (2009), aplicou o modelo para águas com baixas concentrações de clorofila-a, reforçando que a razão B/G pode ser aplicada para a estimativa de clorofila-a nos reservatórios do Distrito Federal, onde há a predominância de baixas concentrações. Chu et al. (2021) também aplicou o modelo para baixas concentrações e teve um desempenho satisfatório da razão de bandas do azul e verde em comparação às demais testadas no estudo. Outro estudo que apresentou um bom desempenho com a razão, mas com número de observações inferiores, foi o estudo de Ha et al. (2017a), que apresentou a aplicabilidade do modelo para concentrações superiores de clorofila-a em águas com índices baixos de matérias orgânica.

Para o estudo, a posição das bandas nos comprimentos de ondas centrais do azul no 485 e do verde no 560nm responderam melhor ao primeiro período de análise dos dados de

concentração de clorofila-a dos reservatórios. Os estudos mostram que a razão das bandas azul e verde apresenta resultados satisfatórios em concentrações baixas de clorofila-a (ODERMATT et al., 2012), porém, entende-se que a faixa espectral apresenta uma maior interferência da resposta da matéria orgânica dissolvida, à reflectância de fundo e uma maior vulnerabilidade às interferências atmosféricas, possibilitando uma superestimação da quantidade de clorofila-a medida (CHUSNAH; CHU, 2022; GILERSON et al., 2010; MENON; ADHIKARI, 2018).

De forma semelhante ao realizado para o Landsat 5, a escolha do modelo para os satélites Landsat 8 e 9 se iniciou com a observação do comportamento dos dados para a escolha do ajuste mais adequado. Os valores dos ajustes testados para os dados dos Landsat 8 e 9 e durante esta investigação, também foram detectadas observações que se encontravam fora do intervalo de confiança. Durante a análise, foram desconsiderados 16 valores de reflectância negativos, restando 116 para o ajuste do modelo R/G dos sensores OLI.

O melhor ajuste observado também foi o polinomial para o período de 11/06/2013 a 05/06/2023, onde obteve-se coeficientes de determinação  $R^2$  de 0,58, superior ao analisado previamente no ajuste linear dos dados. Além disso, o RMSE também apresentou uma melhora, alcançando o valor de 6,07  $\mu\text{g/L}$ .

Os resultados do método Monte Carlo para esse segundo cenário do estudo com os dados dos sensores mais recentes, foram menos satisfatórios e apresentaram uma distribuição de  $R^2$  com uma parte considerável dos dados na primeira faixa do histograma. Ainda assim, a maior ocorrência dos  $R^2$  observados nas 10.000 iterações do Monte Carlo se concentrou na faixa de 0,65 a 0,70. Visto isso, as equações dentro desse intervalo foram testadas da mesma maneira realizada para o Landsat 5.

Realizados os testes para a escolha da melhor equação, foi determinada a seguinte equação para o modelo R/G (Equação 2). A equação aplicada aos dados de reflectância apresentou um ajuste  $R^2$  de 0,69 com os dados medidos em campo pela CAESB.

$$\text{Chl-a} = 5,80 - 44,49 \times (\text{R/G}) + 104,10 \times (\text{R/G})^2 \quad (2)$$

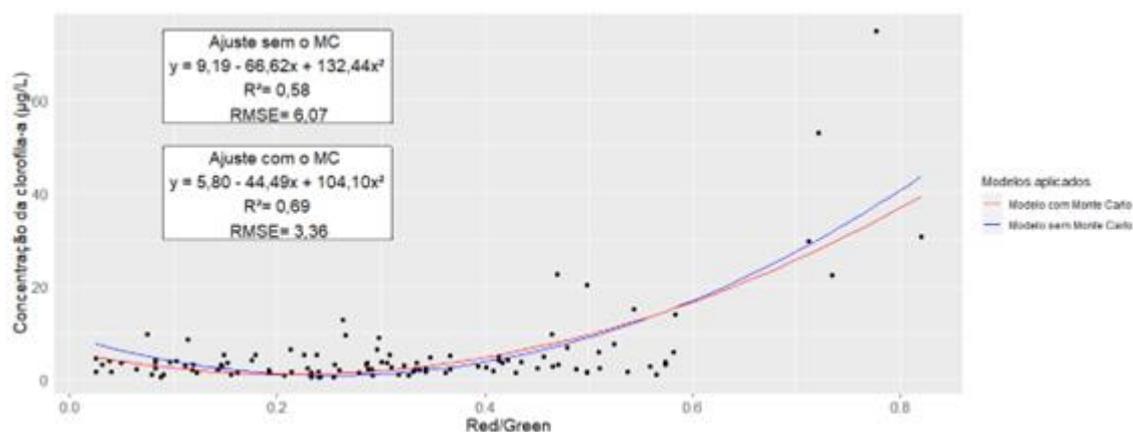


Figura 4 – Ajuste polinomial para os Landsat 8 e 9

Por meio de outros sensores, os estudos de Ha et al. (2017b) e Oliveira et al. (2016) apresentaram coeficientes semelhantes a este estudo. Ha et al. (2017b) utilizou o Sentinel-2A que possui uma resolução espacial maior do que comparada aos sensores Landsat, em contrapartida, o estudo analisou um menor número de pares e com uma distribuição menor de concentrações de clorofila-a, o que pode ter colaborado para ajustes melhores da equação do modelo.

Em estudos de águas costeiras consideradas complexas, Le et al. (2013a) utilizaram um grande número de pares para construir um modelo de previsão para a Baía de Chesapeake nos Estados Unidos, de 1997 a 2011, o primeiro modelo inicial que obteve a performance de 0,43 de coeficiente de correlação foi calibrado regionalmente. Oliveira et al. (2016) obtiveram bons resultados com a razão, utilizando um número considerável de observações, em um ambiente submetido à grandes pressões antrópicas, como despejos de efluentes domésticos e industriais, que aumentam a complexidade da previsão de clorofila-a. Compreende-se que esses ambientes costeiros apresentam mais características de ambientes lóticos do que lânticos, culminando em tempos menores de residência da água e favorecendo a ocorrência de concentrações baixas de clorofila-a, o que pode ser associada a aplicabilidade da razão de bandas selecionada à ambientes lânticos com baixas concentrações de clorofila-a.

A utilização das bandas do vermelho e verde na estimativa de clorofila-a apresenta a vantagem de sofrer menos influência da matéria orgânica dissolvida na resposta espectral (GURLIN; GITELSON; MOSES, 2011). Para baixas concentrações de clorofila-a, em que a feição de espalhamento em 705 nm não é pronunciada, é comumente utilizada a feição da banda do verde, em que a absorção pelo pigmento é relativamente menor que na região espectral do azul e vermelho (BARBOSA; NOVO; MARTINS, 2019). E nesse presente

estudo, apesar das baixas concentrações de clorofila-a avaliadas, a razão de estimativa empírica foi a que melhor correspondeu às variações de clorofila-a nos anos posteriores a 2013.

Por ser o mais atual e possibilitar a validação com novos dados de campo, o modelo R/G foi validado com novos dados de concentração de clorofila-a fornecidos pela CAESB. Ao total, foram utilizados cinco pares de dados independentes para a validação do modelo da razão vermelha e verde, os dados utilizados estão apresentados na Tabela 2.

Tabela 2 - Dados dos pontos utilizados para a validação dos dados de clorofila-a do modelo R/G para todos os reservatórios

<b>Reservatório</b>	<b>Ponto</b>	<b>Clorofila-a</b> ( $\mu\text{g/L}$ )	<b>Clorofila-a modelo R/G</b> ( $\mu\text{g/L}$ )
Descoberto	A	1,3	2,74
Descoberto	A	0,5	3,36
Lago Paranoá	A4	5,7	4,92
Lago Paranoá	A5	3,4	12,95
Santa Maria	A	4,6	5,52

Em análise aos dados calculados pelo modelo, é possível observar que o modelo preditivo dos últimos sensores da série Landsat superestima as concentrações mais baixas de clorofila-a, enquanto para as maiores que  $4 \mu\text{g/L}$  é observado uma diferença menor entre o real e o modelado. Ressalta-se que cinco observações para a validação do modelo é uma baixa representatividade da eficácia do modelo, mas ainda assim, consegue-se observar a potencialidade do modelo em estimar as variações de clorofila-a, que mesmo não sendo precisa, consegue identificar pontos de maiores e menores concentrações.

Como resultado da validação com cinco valores independentes de amostra de clorofila-a referentes ao período de junho a outubro de 2023, obteve-se os seguintes resultados das métricas estatísticas demonstradas na Tabela 3.

Tabela 3 - Resultados da métricas da validação do modelo R/G para os Landsat 8 e 9

<b>Métrica</b>	<b>Resultado</b>
RMSE ( $\mu\text{g/L}$ )	4,53
NRMSE (%)	87,28
Bias ( $\mu\text{g/L}$ )	-2,80

As métricas estatísticas apresentados na Tabela 3 evidenciam a fragilidade do modelo em estimar concentrações baixas de clorofila-a. Uma baixa exatidão resulta de erros sistemáticos que contribuem para desvios ou tendências (bias) nos resultados. Em relação aos outros estudos que estimaram clorofila-a para reservatório com baixas concentrações, o RMSE obtido pelo modelo de melhor desempenho no estudo de Borges et al. (2020) no Lago Paranoá foi de 4.63  $\mu\text{g/L}$ , similar a validação dos dados deste estudo. Em relação a esse valor, os autores reiteraram que foi satisfatório devido a quantidade significativa de concentrações baixas de clorofila-a no estudo.

Com o intuito de integrar os sensores da série Landsat para a estimativa de clorofila-a em reservatórios Bonansea, Rodriguez e Pinotti (2018), elaboraram um modelo multilinear para a predição de clorofila-a no reservatório Rio Tercero, na Argentina. Os autores utilizaram seis datas de 2006 a 2016 para combinar as imagens e as medições em campo, onde as concentrações variaram de 1,1 a 299,0  $\mu\text{g/L}$ , e como resultado o modelo apresentou um ajuste  $R^2 = 0,89$  e um  $\text{RMSE} = 18.47 \mu\text{g/L}$ , maior do que os observados para os dois modelos propostos e na validação com dados independentes nesse presente estudo. Entretanto, como resultado, os autores enfatizam a necessidade de um estudo com um maior número de observações utilizando os sensores Landsat mais antigos para entender o comportamento histórico e os sensores OLI para ser utilizado nas predições, com a possibilidade de acréscimo de dados recentes para uma melhor calibração do modelo. O presente estudo empregou ainda observações do recém-lançado Landsat 9, evidenciando a potencialidade de utilização dos últimos sensores da série Landsat para estimativa futuras de clorofila-a.

#### **4 CONCLUSÕES**

No presente artigo foram propostos dois modelos semiempíricos de estimativa espaço temporal de clorofila-a nos reservatórios do Distrito Federal. No primeiro modelo, para o Landsat 5, as bandas do azul e do verde responderam melhor a essa variabilidade de concentrações de clorofila-a observadas no período histórico de 1984 a 2011. A partir de 2013, ano inicial de análise com as séries dos Landsat 8 e 9, a variabilidade de clorofila-a respondeu melhor nas bandas do verde e do vermelho.

Os resultados dos modelos propostos não apresentam a precisão e a acurácia requerida para ser utilizado como uma principal ferramenta de monitoramento de qualidade da água, porém, foi possível notar que a ferramenta pode indicar a tendência de comportamento eutrófico que pode ser utilizada para apoiar os sistemas de monitoramento convencionais.

Recomenda-se a avaliação de algoritmos de correção atmosférica aplicados às imagens Landsat e adequados à aplicação no Google Earth Engine para estudos de séries históricas, de forma a aprimorar a resposta espectral dos reservatórios do DF para a elaboração de modelos de estimativas de constituintes opticamente ativos. E com o intuito de explorar as interferências sazonais e antrópicas nas concentrações de clorofila-a, sugere-se a aplicação do modelo atrelado a dados climáticos e de uso e cobertura da terra.

## **5 REFERÊNCIAS**

ADASA; CAESB; SEAGRI; EMATER. Gestão da crise hídrica 2016-2018 : experiências do Distrito Federal (Jorge Enoch Furquim Werneck Lima, Glauco Kimura de Freitas, Marcelo Antônio Teixeira Pinto, Paulo Sérgio Bretas de Almeida Salles, Org.). Brasília, DF.

AGUILERA, Anabella et al. Cyanobacterial bloom monitoring and assessment in Latin America. *Harmful Algae*, v. 125, p. 102429, 2023. DOI: 10.1016/J.HAL.2023.102429. Acesso em: 29 out. 2023.

ANGELINI, Ronaldo; BINI, Luis Mauricio; STARLING, Fernando Luis do Rego Monteiro. Efeitos de diferentes intervenções no processo de eutrofização do lago Paranoá (Brasília - DF). *Oecologia Brasiliensis* Programa de Pós-Graduação em Ecologia da Universidade Federal do Rio de Janeiro, 2008. Disponível em: <http://repositorio.bc.ufg.br/handle/ri/11815>. Acesso em: 4 nov. 2023.

ARAÚJO, Bruno Munhoz; NEGRI, Rogério Galante; MORAES ANANIAS, Pedro Henrique; BRESSANE, Adriano; RODGHER, Suzelei. Remotely sensed-based analysis about climatic and landscape change effects on phytoplankton bloom in Barra Bonita Reservoir (São Paulo State, Brazil). *JARS*, v. 17, n. 01, p. 014509, 2023. DOI: 10.1117/1.JRS.17.014509. Disponível em: <https://ui.adsabs.harvard.edu/abs/2023JARS...17a4509A/abstract>. Acesso em: 29 out. 2023.

AUGUSTO-SILVA, Pétala B.; OGASHAWARA, Igor; BARBOSA, Cláudio C. F.; DE CARVALHO, Lino A. S.; JORGE, Daniel S. F.; FORNARI, Celso Israel; STECH, José L. Analysis of MERIS Reflectance Algorithms for Estimating Chlorophyll-a Concentration in a Brazilian Reservoir. *Remote Sensing* 2014, Vol. 6, Pages 11689-11707, v. 6, n. 12, p. 11689–

11707, 2014. DOI: 10.3390/RS61211689. Disponível em: <https://www.mdpi.com/2072-4292/6/12/11689/htm>. Acesso em: 27 out. 2023.

BARBOSA, Claudio C. F.; NOVO, Evlyn M. L. M.; MARTINS, Vitor S. Introdução ao sensoriamento remoto de sistemas aquáticos. 1ª Edição ed. São José dos Campos/SP: Instituto Nacional de Pesquisas Espaciais, 2019. Disponível em: [www.inpe.br](http://www.inpe.br).

BONANSEA, Matias; RODRIGUEZ, Claudia; PINOTTI, Lucio. Assessing the potential of integrating Landsat sensors for estimating chlorophyll-a concentration in a reservoir. *Hydrology Research*, v. 49, n. 5, p. 1608–1617, 2018. DOI: 10.2166/NH.2017.116. Disponível em: <http://glovis>. Acesso em: 23 nov. 2023.

BORGES, Henrique Dantas; CICERELLI, Rejane Ennes; DE ALMEIDA, Tati; ROIG, Henrique L.; OLIVETTI, Diogo. Monitoring cyanobacteria occurrence in freshwater reservoirs using semi-analytical algorithms and orbital remote sensing. *Marine and Freshwater Research*, v. 71, n. 5, p. 569–578, 2020. DOI: 10.1071/MF18377.

BRASIL. Decreto n.o 241. de 29 de novembro de 1961. [s.l: s.n.].

BRASIL. DECRETO No 88.940, DE 7 DE NOVEMBRO DE 1983Brasil, 1983.

BRICAUD, Annick; ROESLER, Collin; ZANEVELD, J. Ronald V. In situ methods for measuring the inherent optical properties of ocean waters. *Limnology and Oceanography*, v. 40, n. 2, p. 393–410, 1995. DOI: 10.4319/LO.1995.40.2.0393. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.4319/lo.1995.40.2.0393>. Acesso em: 4 nov. 2023.

BUMA, Willibroad Gabila; LEE, Sang Il. Evaluation of Sentinel-2 and Landsat 8 Images for Estimating Chlorophyll-a Concentrations in Lake Chad, Africa. *Remote Sensing 2020*, Vol. 12, Page 2437, v. 12, n. 15, p. 2437, 2020. DOI: 10.3390/RS12152437. Disponível em: <https://www.mdpi.com/2072-4292/12/15/2437/htm>. Acesso em: 3 nov. 2023.

BURNETT, J. A. B.; MATTOS, S. P.; AZZOLIN, N. M. P. Intervenções da Companhia de Saneamento. Em: FONSECA, F. O. (org.). *Olhares sobre o Lago Paranoá*. Brasília: SEMARH, 2001. p. 199–212.

CAESB. Notícias. Responsável por abastecer 11% do DF, Barragem de Santa Maria passa por reformas, 2023. Disponível em: <https://www.caesb.df.gov.br/8-noticias/1742-15-05-23-barragem-de-santa-maria-passa-por-reformas.html#:~:text=passa%20por%20reformas-15%2F05%2F23%20%2D%20Respons%C3%A1vel%20por%20abastecer%2011%25%20do,Santa%20Maria%20passa%20por%20reformas&text=A%20Barragem%20de%20Santa%20Maria,em%202022%2C%20est%C3%A1%20sendo%20reformada>. Acesso em: 25 nov. 2023.

CAREY, Cayelan C.; IBELINGS, Bas W.; HOFFMANN, Emily P.; HAMILTON, David P.; BROOKES, Justin D. Eco-physiological adaptations that favour freshwater cyanobacteria in a changing climate. *Water Research*, v. 46, n. 5, p. 1394–1407, 2012. DOI: 10.1016/J.WATRES.2011.12.016. Acesso em: 29 out. 2023.

CAVALCANTI, Cristine Gobbato B.; PINTO, Marcelo Teixeira; DE FREITAS, Hélio José; MOREIRA, Ricardo Cosme A. Paranoá Lake restoration: impact of tertiary treatment of sewage in the watershed. *SIL Proceedings, 1922-2010*, v. 26, n. 2, p. 689–693, 1997. DOI: 10.1080/03680770.1995.11900803.

CHELOTTI, Giancarlo Brugnara; MARTINEZ, Jean Michel; ROIG, Henrique Llacer; OLIVIETTI, Diogo. Space-Temporal analysis of suspended sediment in low concentration reservoir by remote sensing. *RBRH*, v. 24, p. e17, 2019. DOI: 10.1590/2318-0331.241920180061. Disponível em: <https://www.scielo.br/j/rbrh/a/rcbdD6j8VZVD5pVBqRtDZgR/?lang=en>. Acesso em: 26 out. 2023.

CHORUS, Ingrid. Cyanotoxin Occurrence in Freshwaters. *Cyanotoxins*, p. 5–101, 2001. DOI: 10.1007/978-3-642-59514-1\_2. Acesso em: 29 out. 2023.

CHU, Hone Jay; HE, Yu Chen; CHUSNAH, Wachidatin Nisa'Ul; JAELANI, Lalu Muhamad; CHANG, Chih Hua. Multi-Reservoir Water Quality Mapping from Remote Sensing Using Spatial Regression. *Sustainability 2021, Vol. 13, Page 6416*, v. 13, n. 11, p. 6416, 2021. DOI: 10.3390/SU13116416. Disponível em: <https://www.mdpi.com/2071-1050/13/11/6416/htm>. Acesso em: 28 out. 2023.

CHUSNAH, Wachidatin Nisaul; CHU, Hone Jay. Estimating chlorophyll-a concentrations in tropical reservoirs from band-ratio machine learning models. *Remote Sensing Applications: Society and Environment*, v. 25, p. 100678, 2022. DOI: 10.1016/J.RSASE.2021.100678. Acesso em: 28 out. 2023.

CODEPLAN. Pesquisa Distrital por Amostra de Domicílios – PDAD 2021. [s.l: s.n.].

COLLISCHONN, Bruno; VALTER, José; DE MELO, Simplício. A FLORAÇÃO DE CIANOBACTÉRIAS NO LAGO PARANOÁ EM NOVEMBRO DE 2016: UMA HIPÓTESE EXPLICATIVA. Em: XXIV SIMPÓSIO BRASILEIRO DE RECURSOS HIDRÍCOS 2021, Anais [...]. [s.l: s.n.]

DA SILVA, Damiana B.; BELLOTTO, Valéria R.; DO B BARBOSA, Jackeline S.; LIMA, Thiago B.; HUNG, Yung-Tse; ABDUL AZIZ, Hamidi; AL-KHATIB, Issam A.; ABDEL RAHMAN, Rehab O.; IMAI, Tsuyoshi. Spatiotemporal Variation on Water Quality and Trophic State of a Tropical Urban Reservoir: A Case Study of the Lake Paranoá-DF, Brazil. *Water* 2021, Vol. 13, Page 3314, v. 13, n. 22, p. 3314, 2021. DOI: 10.3390/W13223314. Disponível em: <https://www.mdpi.com/2073-4441/13/22/3314/htm>. Acesso em: 23 nov. 2023.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; DE COLSTOUN, E. Brown; MCMURTREY, J. E. Estimating Corn Leaf Chlorophyll Concentration from Leaf and Canopy Reflectance. *Remote Sensing of Environment*, v. 74, n. 2, p. 229–239, 2000. DOI: 10.1016/S0034-4257(00)00113-9. Acesso em: 28 out. 2023.

DE OLIVEIRA, L. P.; KRAU, L. General and applied hydro-biology, particularly as a vehicle of schistosoma. Hypereutrophy, modern deterioration of water. *Memórias do Instituto Oswaldo Cruz*, v. 68, n. 1, p. 89–118, 1970. DOI: 10.1590/S0074-02761970000100004. Disponível em: <https://www.scielo.br/j/mioc/a/ZWhMSrydzBXnVWfR36NgKsR/abstract/?lang=en>. Acesso em: 29 out. 2023.

DE VITO, Marco. AVALIAÇÃO DO RISCO DE CONTAMINAÇÃO DE MANANCIAIS HÍDRICOS PARA O ABASTECIMENTO: O CASO DA BACIA DA BARRAGEM DO DESCOBERTO. 2007. Dissertação - Universidade de Brasília, Brasília, 2007.

FENG, Lei; YOU, Yu; LIAO, Weiling; PANG, Jiawei; HU, Ronghao; FENG, Li. Multi-scale change monitoring of water environment using cloud computing in optimal resolution remote sensing images. *Energy Reports*, v. 8, p. 13610–13620, 2022. DOI: 10.1016/J.EGYR.2022.09.134. Acesso em: 29 out. 2023.

GDF. Adequação Ambiental da Reserva Biológica e das Propriedades Rurais às Margens do Lago Descoberto. [s.l.: s.n.].

GILERSON, Alexander A. et al. Algorithms for remote estimation of chlorophyll-a in coastal and inland waters using red and near infrared bands. *Optics Express*, Vol. 18, Issue 23, pp. 24109-24125, v. 18, n. 23, p. 24109–24125, 2010. DOI: 10.1364/OE.18.024109. Disponível em: <https://opg.optica.org/viewmedia.cfm?uri=oe-18-23-24109&seq=0&html=true>. Acesso em: 29 out. 2023.

GITELSON, A. The peak near 700 nm on radiance spectra of algae and water: Relationships of its magnitude and position with chlorophyll. *International Journal of Remote Sensing*, v. 13, n. 17, p. 3367–3373, 1992. DOI: 10.1080/01431169208904125.

GORDON, Howard R.; MOREL, André Y. Remote Assessment of Ocean Color for Interpretation of Satellite Visible Imagery. *Lecture Notes on Coastal and Estuarine Studies*. New York, NY, v. 4, *Lecture Notes on Coastal and Estuarine Studies*, 1983. DOI: 10.1007/978-1-4684-6280-7. Disponível em: <http://link.springer.com/10.1007/978-1-4684-6280-7>. Acesso em: 31 out. 2023.

GORELICK, Noel; HANCHER, Matt; DIXON, Mike; ILYUSHCHENKO, Simon; THAU, David; MOORE, Rebecca. Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, v. 202, p. 18–27, 2017. DOI: 10.1016/j.rse.2017.06.031.

GROSS, Joceli Augusto. EFEITOS DE DIFERENTES COMPONENTES OPTICAMENTE ATIVOS NA REFLECTÂNCIA DA ÁGUA PARA A ESTIMATIVA REMOTA DAS

CONCENTRAÇÕES DE CLOROFILA-A FITOPLANCTÔNICA. 2019. Tese de doutorado - Universidade Federal de Santa Maria (RS), Santa Maria, RS, 2019.

GUANTER, Luis; RUIZ-VERDÚ, Antonio; ODERMATT, Daniel; GIARDINO, Claudia; SIMIS, Stefan; ESTELLÉS, Víctor; HEEGE, Thomas; DOMÍNGUEZ-GÓMEZ, Jose Antonio; MORENO, Jose. Atmospheric correction of ENVISAT/MERIS data over inland waters: Validation for European lakes. *Remote Sensing of Environment*, v. 114, n. 3, p. 467–480, 2010. DOI: 10.1016/J.RSE.2009.10.004. Acesso em: 4 nov. 2023.

GURLIN, Daniela; GITELSON, Anatoly A.; MOSES, Wesley J. Remote estimation of chl-a concentration in turbid productive waters - Return to a simple two-band NIR-red model? *Remote Sensing of Environment*, v. 115, n. 12, p. 3479–3490, 2011. DOI: 10.1016/j.rse.2011.08.011.

HA, Nguyen Thi Thu; KOIKE, Katsuaki; NHUAN, Mai Trong; CANH, Bui Dinh; THAO, Nguyen Thien Phuong; PARSONS, Michael. Landsat 8/OLI Two bands ratio algorithm for chlorophyll-a concentration mapping in hypertrophic waters: An application to west lake in Hanoi (Vietnam). *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 10, n. 11, p. 4919–4929, 2017. a. DOI: 10.1109/JSTARS.2017.2739184. Acesso em: 2 nov. 2023.

HA, Nguyen Thi Thu; THAO, Nguyen Thien Phuong; KOIKE, Katsuaki; NHUAN, Mai Trong. Selecting the Best Band Ratio to Estimate Chlorophyll-a Concentration in a Tropical Freshwater Lake Using Sentinel 2A Images from a Case Study of Lake Ba Be (Northern Vietnam). *ISPRS International Journal of Geo-Information* 2017, Vol. 6, Page 290, v. 6, n. 9, p. 290, 2017. b. DOI: 10.3390/IJGI6090290. Disponível em: <https://www.mdpi.com/2220-9964/6/9/290/htm>. Acesso em: 1 nov. 2023.

HAYES, Nicole M.; HAIG, Heather A.; SIMPSON, Gavin L.; LEAVITT, Peter R. Effects of lake warming on the seasonal risk of toxic cyanobacteria exposure. *Limnology and Oceanography Letters*, v. 5, n. 6, p. 393–402, 2020. DOI: 10.1002/LOL2.10164. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1002/lo12.10164>. Acesso em: 29 out. 2023.

IBGE. Panorama do Censo 2022. 2022. Disponível em: <https://censo2022.ibge.gov.br/panorama/>. Acesso em: 29 out. 2023.

INMET. Banco de Dados Meteorológicos do INMET. 2023. Disponível em: <https://bdmep.inmet.gov.br/>. Acesso em: 4 nov. 2023.

IPEDF. 2.6 – Climate – Federal District Atlas. 2020. Disponível em: <https://atlas.ipe.df.gov.br/en/?p=999>. Acesso em: 29 out. 2023.

KISLIK, Chippie; DRONOVA, Iryna; GRANTHAM, Theodore E.; KELLY, Maggi. Mapping algal bloom dynamics in small reservoirs using Sentinel-2 image

Engine. Ecological Indicators, v. 140, p. 109041, 2022. DOI: 10.1016/J.ECOLIND.2022.109041. Acesso em: 27 out. 2023.

KOLLURU, Srinivas; GEDAM, Shirishkumar S.; CHANDER, Shard; SAHAY, Arvind. Development of chlorophyll-a concentration estimation algorithm for turbid productive inland waters in India. Geocarto International, v. 38, n. 1, p. 2171143, 2023. DOI: 10.1080/10106049.2023.2171143. Disponível em: <https://doi.org/10.1080/10106049.2023.2171143>. Acesso em: 6 nov. 2023.

KONDRATYEVA, Anna et al. Urbanization Effects on Biodiversity Revealed by a Two-Scale Analysis of Species Functional Uniqueness vs. Redundancy. *Frontiers in Ecology and Evolution*, v. 8, p. 499897, 2020. DOI: 10.3389/FEVO.2020.00073/BIBTEX. Acesso em: 29 out. 2023.

LE, Chengfeng; HU, Chuanmin; CANNIZZARO, Jennifer; DUAN, Hongtao. Long-term distribution patterns of remotely sensed water quality parameters in Chesapeake Bay. *Estuarine, Coastal and Shelf Science*, v. 128, p. 93–103, 2013. a. DOI: 10.1016/J.ECSS.2013.05.004. Acesso em: 28 out. 2023.

LE, Chengfeng; HU, Chuanmin; ENGLISH, David; CANNIZZARO, Jennifer; CHEN, Zhiqiang; FENG, Lian; BOLER, Richard; KOVACH, Charles. Towards a long-term chlorophyll-a data record in a turbid estuary using MODIS observations. *Progress in*

Oceanography, v. 109, p. 90–103, 2013. b. DOI: 10.1016/J.POCEAN.2012.10.002. Acesso em: 31 out. 2023.

LEITE COSTA, Maria Elisa; KOIDE, Sergio. O IMPACTO DA POLUIÇÃO DIFUSA ORIUNDA DO SISTEMA DE DRENAGEM URBANO NO LAGO PARANOÁ. Em: XX SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS 2013, Anais [...]. [s.l: s.n.] Disponível em: <https://www.researchgate.net/publication/314313371>.

LI, Leiming; WU, Jun; LU, Jian; LI, Kexin; ZHANG, Xiying; MIN, Xiuyun; GAO, Chunliang; XU, Juan. Water quality evaluation and ecological-health risk assessment on trace elements in surface water of the northeastern Qinghai-Tibet Plateau. *Ecotoxicology and Environmental Safety*, v. 241, p. 113775, 2022. DOI: 10.1016/J.ECOENV.2022.113775. Acesso em: 29 out. 2023.

LIMA, Jorge Enoch Furquim Werneck. Situação e perspectivas sobre as águas do cerrado. *Ciência e Cultura*, v. 63, n. 3, p. 27–29, 2011. DOI: 10.21800/S0009-67252011000300011. Disponível em: [http://cienciaecultura.bvs.br/scielo.php?script=sci\\_arttext&pid=S0009-67252011000300011&lng=en&nrm=iso&tlng=pt](http://cienciaecultura.bvs.br/scielo.php?script=sci_arttext&pid=S0009-67252011000300011&lng=en&nrm=iso&tlng=pt). Acesso em: 29 out. 2023.

LOBO, Felipe de Lucia; NAGEL, Gustavo Willy; MACIEL, Daniel Andrade; DE CARVALHO, Lino Augusto Sander; MARTINS, Vitor Souza; BARBOSA, Cláudio Clemente Faria; DE MORAES NOVO, Evlyn Márcia Leão. Algaemap: Algae bloom monitoring application for inland waters in Latin America. *Remote Sensing*, v. 13, n. 15, 2021. DOI: 10.3390/rs13152874.

MACHADO, Marília Teresinha de Sousa; BAPTISTA, Gustavo Macedo de Mello. Sensoriamento remoto como ferramenta de monitoramento da qualidade da água do Lago

Paranoá (DF). *Engenharia Sanitaria e Ambiental*, v. 21, n. 2, p. 357–365, 2016. DOI: 10.1590/S1413-41522016141970.

MAGALHÃES, Ivo Augusto Lopes; PEREIRA DE SOUZA, Ana Carolina; MINOTI, Ricardo Tezini; GOMES, Lenora Nunes Ludolf. Análise de parâmetros da qualidade da água no lago Descoberto no Distrito Federal, por meio de imagens do satélite Sentinel-2B *Revista*

Brasileira de Geografia Física v. [s.l: s.n.]. Disponível em: <https://periodicos.ufpe.br/revistas/rbgfe>.

MARQUES, Laís de Almeida. MODELAGEM BIDIMENSIONAL PARA SIMULAÇÃO DA QUALIDADE DA ÁGUA DO LAGO PARANOÁ-DF. 2021. Dissertação de Mestrado - Universidade de Brasília, Brasília, 2021.

MENEZES JR., A.; SINOTI, M. L.; SARAIVA, R. C. F. Histórico. Em: FONSECA, F. O. (org.). Olhares sobre o Lago Paranoá. Brasília: SEMARH, 2001.

MENEZES, Paulo Henrique Bretanha Junker. Avaliação do efeito das ações antrópicas no processo de escoamento superficial e assoreamento na bacia do Lago Paranoá. 2010. Dissertação de Mestrado - Universidade de Brasília, 2010.

MENON, Harilal B.; ADHIKARI, Arjun. Remote Sensing of Chlorophyll-A in Case II Waters: A Novel Approach With Improved Accuracy Over Widely Implemented Turbid Water Indices. *Journal of Geophysical Research: Oceans*, v. 123, n. 11, p. 8138–8158, 2018. DOI: 10.1029/2018JC014052. Disponível em: <https://onlinelibrary.wiley.com/doi/full/10.1029/2018JC014052>. Acesso em: 23 nov. 2023.

MISHRA, Deepak R.; MISHRA, Sachidananda. Plume and bloom: Effect of the mississippi river diversion on the water quality of lake pontchartrain. *Geocarto International*, v. 25, n. 7, p. 555–568, 2010. DOI: 10.1080/10106041003763394.

MISHRA, Sachidananda; MISHRA, Deepak 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, 2011. DOI: 10.1016/j.rse.2011.10.016.

MONSALVE-HERRERA, Diana Jimena. MODELO COMPORTAMENTAL COM BASE EM AGENTES PARA GESTÃO ADAPTATIVA DE ÁGUA: CASO DE ESTUDO DE CONSUMO DE ÁGUA RESIDENCIAL URBANA EM BRAZLANDIA/DF. 2018. Tese de Doutorado - Universidade de Brasília, 2018.

ODERMATT, Daniel; GITELSON, Anatoly; BRANDO, Vittorio Ernesto; SCHAEPMAN, Michael. Review of constituent retrieval in optically deep and complex waters from satellite imagery. *Remote Sensing of Environment*, v. 118, p. 116–126, 2012. DOI: 10.1016/J.RSE.2011.11.013. Acesso em: 31 out. 2023.

OLIVEIRA, Eduardo N. et al. Assessment of remotely sensed chlorophyll-a concentration in Guanabara Bay, Brazil. <https://doi.org/10.1117/1.JRS.10.026003>, v. 10, n. 2, p. 026003, 2016. DOI: 10.1117/1.JRS.10.026003. Disponível em: <https://www.spiedigitallibrary.org/journals/journal-of-applied-remote-sensing/volume-10/issue-2/026003/Assessment-of-remotely-sensed-chlorophyll-a-concentration-in-Guanabara-Bay/10.1117/1.JRS.10.026003.full>. Acesso em: 1 nov. 2023.

PADOVESI-FONSECA, C.; PHILOMENO, M. G.; ANDREONI-BATISTA. Limnological features after a flushing event in Paranoá Reservoir, central Brazil Características limnológicas após um “flushing” no Reservatório Paranoá, Brasil centralC. *Acta Limnol. Bras.* [s.l: s.n.].

PAINTER, Kristin J.; VENKITESWARAN, Jason J.; BAULCH, Helen M. Blooms and flows: Effects of variable hydrology and management on reservoir water quality. *Ecosphere*, v. 14, n. 3, 2023. DOI: 10.1002/ECS2.4472. Acesso em: 25 out. 2023.

PEREIRA, Alice Rocha. Modelagem hidrodinâmica e de qualidade da água do Lago Paranoá -DF. 2024. Tese de doutorado - Universidade de Brasília, Brasília, 2024.

ROUSE, J. W. ., Jr. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation. , 1974. . Acesso em: 28 out. 2023.

SHI, Peng; ZHANG, Yan; LI, Zhanbin; LI, Peng; XU, Guoce. Influence of land use and land cover patterns on seasonal water quality at multi-spatial scales. *CATENA*, v. 151, p. 182–190, 2017. DOI: 10.1016/J.CATENA.2016.12.017. Acesso em: 29 out. 2023.

SOUZA, Ana Carolina Pereira De. ESTUDO DA QUALIDADE DA ÁGUA DO LAGO DESCOBERTO: ANÁLISE DE PARÂMETROS LIMNOLÓGICOS PARA AVALIAÇÃO

DA INTEGRIDADE DO AMBIENTE. 2018. Monografia de Projeto Final em Engenharia Ambiental - Universidade de Brasília, Brasília, 2018.

STEINKE, Valdir Adilson; MARTINS PALHARES DE MELO, Luis Alberto; MELO, Mamedes Luiz; FRANCA, Rafael Rodrigues Da; LUCENA, Rebecca Luna; STEINKE, Ercilia Torres. Trend Analysis of Air Temperature in the Federal District of Brazil: 1980–2010. *Climate 2020*, Vol. 8, Page 89, v. 8, n. 8, p. 89, 2020. DOI: 10.3390/CLI8080089. Disponível em: <https://www.mdpi.com/2225-1154/8/8/89/htm>. Acesso em: 29 out. 2023.

STRASSBURG, Bernardo B. N. et al. Moment of truth for the Cerrado hotspot. *Nature Ecology & Evolution* 2017 1:4, v. 1, n. 4, p. 1–3, 2017. DOI: 10.1038/s41559-017-0099. Disponível em: <https://www.nature.com/articles/s41559-017-0099>. Acesso em: 29 out. 2023.

TUCKER, Compton J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, v. 8, n. 2, p. 127–150, 1979. DOI: 10.1016/0034-4257(79)90013-0. Acesso em: 28 out. 2023.

TUNDISI, José Galizia. Recursos hídricos no futuro: problemas e soluções. *Estudos Avançados*, v. 22, n. 63, p. 7–16, 2008. DOI: 10.1590/S0103-40142008000200002. Disponível em: <https://www.scielo.br/j/ea/a/7gyMPtTzfkYfWWsMHqVLTqm/>. Acesso em: 29 out. 2023.

TUNDISI, José Galizia.; TUNDISI, Takako Matsumura. *Limnologia*. 1a Edição ed. São Paulo: Oficina de Textos, 2008.

WATANABE, Fernanda; ALCÂNTARA, Enner; RODRIGUES, Thanan; ROTTA, Luiz; BERNARDO, Nariane; IMAI, Nilton. Remote sensing of the chlorophyll-a based on OLI/Landsat-8 and MSI/Sentinel-2a (Barra Bonita Reservoir, Brazil). *Anais da Academia Brasileira de Ciências*, v. 90, n. 2, p. 1987–2000, 2018. DOI: 10.1590/0001-3765201720170125.

WITTER, Donna L.; ORTIZ, Joseph D.; PALM, Sarah; HEATH, Robert T.; BUDD, Judith W. Assessing the application of SeaWiFS ocean color algorithms to Lake Erie. *Journal of*

Great Lakes Research, v. 35, n. 3, p. 361–370, 2009. DOI: 10.1016/J.JGLR.2009.03.002.  
Acesso em: 1 nov. 2023.

YU, Hong; CAI, Qi-ming; WU, Jing-Iu. Study on characteristic of the absorption and scattering coefficients of Taihu Lake waters. *Advances in Water Science*, p. 46–49, 2003.

ZANGO, Baba-Serges; SEIDOU, Ousmane; SARTAJ, Majid; NAKHAEI, Nader; STILES, Kelly. Impacts of urbanization and climate change on water quantity and quality in the Carp River watershed. *Journal of Water and Climate Change*, v. 13, n. 2, p. 786–816, 2022. DOI: 10.2166/WCC.2021.158. Disponível em: <http://iwaponline.com/jwcc/article-pdf/13/2/786/1013698/jwc0130786.pdf>. Acesso em: 29 out. 2023.