UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS DA ENGENHARIA AMBIENTAL

TAINÁ THOMASSIM GUIMARÃES

**Utilização de imagens de satélite para predição de clorofila-a e sólidos suspensos em
corpos d'água: estudo de caso da Represa do Lobo/SP**

São Carlos

2019

TAINÁ THOMASSIM GUIMARÃES

**Utilização de imagens de satélite para predição de clorofila-a e sólidos suspensos em
corpos d'água: estudo de caso da Represa do Lobo/SP**

Dissertação apresentada à Escola de Engenharia
de São Carlos, da Universidade de São Paulo,
como parte dos requisitos para obtenção de
título de mestre em Ciências da Engenharia
Ambiental.

Área de Concentração: Planejamento e
Gerenciamento de Recursos Hídricos

Orientador: Prof. Assoc. Frederico Fábio
Mauad

São Carlos

2019

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da
EESC/USP com os dados inseridos pelo(a) autor(a).

G963u Guimarães, Tainá Thomassim
Utilização de imagens de satélite para
predição de clorofila-a e sólidos suspensos em corpos
d'água: estudo de caso da Represa do Lobo/SP / Tainá
Thomassim Guimarães; orientador Frederico Fabio Mauad.
São Carlos, 2019.

Dissertação (Mestrado) - Programa de
Pós-Graduação e Área de Concentração em Ciências da
Engenharia Ambiental -- Escola de Engenharia de São
Carlos da Universidade de São Paulo, 2019.

1. Sensoriamento remoto. 2. Clorofila. 3. Sólidos
suspensos. 4. Sentinel. 5. RNA. I. Título.

Eduardo Graziosi Silva - CRB - 8/8907

FOLHA DE JULGAMENTO

Candidata: Engenheira **TAINÁ THOMASSIM GUIMARÃES**.

Título da dissertação: "Utilização de imagens de satélite para predição de clorofila-a e sólidos suspensos em corpos d'água: estudo de caso da Represa do Lobo/SP".

Data da defesa: 23/05/2019.

Comissão Julgadora:

Resultado:

Prof. Associado **Frederico Fabio Mauad (Orientador)**
(Escola de Engenharia de São Carlos/EESC)

Aprovada

Profa. Associada **Ana Paula Camargo Larocca**
(Escola de Engenharia de São Carlos/EESC)

Aprovada

Prof. Dr. **Maurício Roberto Veronez**
(Universidade do Vale do Rio dos Sinos/UNISINOS)

Aprovada

Coordenador do Programa de Pós-Graduação em Ciências da Engenharia Ambiental:

Prof. Associado **Frederico Fabio Mauad**

Presidente da Comissão de Pós-Graduação:

Prof. Titular **Murilo Araujo Romero**

AGRADECIMENTOS

A concretização deste trabalho seria impossível se eu não contasse com o apoio de diversas pessoas, que de diferentes formas estiveram presentes e influenciaram minha caminhada até aqui.

Agradeço ao professor Frederico Fábio Mauad pela oportunidade, orientação e por garantir toda a infraestrutura necessária para o desenvolvimento deste trabalho. Não poderia também deixar de agradecer o técnico do Núcleo de Hidrometria, Miro, pela paciência e auxílio nas coletas de campo, além das inúmeras histórias e experiências compartilhadas.

Aos meus colegas do Núcleo de Hidrometria, destacando os que ingressaram comigo no programa: Allita, pelo apoio em diversos momentos, sejam eles bons ou ruins; Gabriela e Mariana, pela amizade, abraços e carinho compartilhados; e Phelipe, pela companhia e parceria em diversos momentos. Em especial agradeço à Gabriela Leite Neves por todo o auxílio durante as incansáveis análises realizadas e também pelas conversas e risadas compartilhadas durante este período que com certeza fizeram com que tudo fluísse de uma forma muito mais leve, e ao Carlos Martinez, por ter me apresentado ao Matlab e à ferramenta de redes neurais, o que realmente fez toda a diferença neste trabalho.

Ao professor Maurício Veronez, da UNISINOS/RS, pelo auxílio em diversas etapas do desenvolvimento deste trabalho, sempre me mantendo confiante de que daria tudo certo.

Aos meus amigos do sul, amigos de longa data (Ludmila), da escola (Bruna) e a da faculdade (Gabriela, Tatiana, Rosele e Emilie), por respeitarem minha ausência neste tempo e me incentivarem sempre.

E, por fim, meu agradecimento especial, sincero e eterno a minha família (mãe Leila, pai Renato e irmãs Terena e Naiara) e ao meu namorado (Guilherme) pelo apoio, carinho e amor que sempre me dedicaram, por terem respeitado minha escolha de sair de casa e ir para outro estado fazer mestrado e ainda terem me incentivado a enfrentar todas as dificuldades que surgiram. Se eu cheguei até aqui, com certeza foi porque vocês foram meus pilares, amo vocês!

RESUMO

GUIMARÃES, T. T. **Utilização de imagens de satélite para predição de clorofila-a e sólidos suspensos em corpos d'água: estudo de caso da Represa do Lobo/SP.** 2019. 113f. Dissertação de Mestrado (Mestrado em Ciências da Engenharia Ambiental) – Centro de Recursos Hídricos e Estudos Ambientais, Universidade de São Paulo, São Carlos, 2019.

Medidas complementares ao monitoramento in situ da qualidade da água podem ser obtidas por meio de sensoriamento remoto, sendo clorofila-a e sólidos suspensos alguns dos parâmetros que podem ser estimados. Este trabalho teve como objetivo explorar técnicas de processamento de imagens, análises estatísticas e de inteligência artificial com o objetivo de prever e modelar as concentrações de clorofila-a e sólidos suspensos totais na Represa do Lobo/SP. Metodologicamente, foram realizadas coletas em campo, em três diferentes datas, para amostragem de água e posterior análise laboratorial. Os resultados limnológicos foram analisados, modelados e comparados com imagens processadas do satélite Sentinel-2. Análises de regressão e redes neurais artificiais (RNA) foram exploradas para gerar modelos de predição para a área de estudo. Os resultados indicam que métodos de regressão podem não ser adequados para capturar as relações lineares e/ou não-lineares entre os compostos de interesse e as respostas espectrais da água recebidas pelo satélite, indicando a capacidade das redes neurais em modelar relações mais complexas. Através da integração da resposta que o sensor MSI do satélite Sentinel-2 coletou nas regiões do visível ao infravermelho médio e de RNAs foi possível modelar a concentração de clorofila-a, com valores de R^2 superiores a 0,65 e de RMSE inferiores a 2,5 $\mu\text{g/L}$, e gerar mapas que permitam seu monitoramento temporal e análise espacial na área de estudo. Os resultados para SST não foram satisfatórios devido à complexidade óptica do ambiente analisado, bem como as baixas concentrações de SST na represa. Portanto, a integração de dados de sensoriamento remoto no mapeamento de corpos d'água com a aplicação de redes neurais na análise de dados é uma abordagem promissora para prever clorofila-a e sólidos suspensos, bem como suas variações temporais e espaciais.

Palavras-chave: Sensoriamento remoto. Clorofila. Sólidos suspensos. Sentinel. RNA.

ABSTRACT

GUIMARÃES, T. T. **Use of satellite images to predict chlorophyll-a and suspended solids in water bodies: a study case of the Lobo Reservoir/SP**. 2019. 113f. Dissertação de Mestrado (Mestrado em Ciências da Engenharia Ambiental) – Centro de Recursos Hídricos e Estudos Ambientais, Universidade de São Paulo, São Carlos, 2019.

Complementary measures to in situ monitoring of water quality can be obtained through remote sensing, with chlorophyll-a and suspended solids being some of the parameters that can be estimated. The objective of this work was to explore techniques for image processing, statistical analysis and artificial intelligence with the objective of predicting and modeling the concentrations of chlorophyll-a and total suspended solids in the Lobo Reservoir/SP. Methodologically, field samples were collected in three different dates for water sampling and laboratory analysis. The limnological results were analyzed, modeled and compared with processed images of the Sentinel-2 satellite. Regression analysis and artificial neural networks (ANNs) were explored to generate prediction models for the study area. The results indicate that regression methods may not be adequate to capture linear and/or nonlinear relationships between the compounds of interest and the spectral responses of water received by the satellite, indicating the ability of neural networks to model more complex relationships. Through of the integration of response with the MSI sensor of Sentinel satellite collected in the visible and near-infrared regions and of the ANN analysis was possible modeling the chlorophyll-a concentration, with R^2 values higher of 0.65 and RMSE less 2.5, and create predict maps with allow your temporal monitoring and spatial analysis in the study area. The TSS results were unsatisfactory because of the optic complexity of analysed ambient, as well as your small TSS concentrations in the Lobo Reservoir. Therefore, the integration of remote sensing data in the mapping of water bodies with the application of neural networks in the data analysis is a promising approach to predict chlorophyll-a and suspended solids as well as their temporal and spatial variations.

Keywords: Remote Sensing. Chlorophyll. Suspended solids. Sentinel. ANN.

LISTA DE FIGURAS

Figura 1 – Comportamento espectrais de alvos da superfície terrestre	28
Figura 2 - Modelos de referência representando massas de água distintas	37
Figura 3 – Resposta espectral de água clara e de água com algas	38
Figura 4 - Resposta espectral da água contendo sólidos em suspensão	39
Figura 5 - Resposta espectral da água contendo algas e sedimentos em suspensão.....	41
Figura 6 - Resposta espectral da água contendo sólidos suspensos e clorofila-a	41
Figura 7 – Esquema metodológico	50
Figura 8 – Localização da Represa do Lobo	51
Figura 9 – Precipitação mensal de 2017 e 2018 (Estação Climatológica do CRHEA).....	54
Figura 10 - Localização dos pontos amostrais.....	56
Figura 11 – Boxplot dos resultados de clorofila-a e SST	69
Figura 12 – Distribuição espacial da clorofila-a.....	71
Figura 13 – Distribuição espacial dos sólidos suspensos	71
Figura 14 – Imagens Sentinel-2 processadas.....	73
Figura 15 – Gráfico do comportamento espectral médio extraído das imagens Sentinel-2.....	73
Figura 16 – Índices obtidos através das imagens Sentinel-2	76
Figura 17 – Gráfico de clorofila-a observada e predita por regressões	82
Figura 18 – Mapas preditos de clorofila-a por meio de regressões	83
Figura 19 – Gráfico de SST observado e predito por regressões	86
Figura 20 - Gráfico de clorofila-a observada e predita por RNA, separados por coleta	91
Figura 21 - Gráfico de SST observado e predito por RNA, separados por coleta.....	93
Figura 22 - Gráfico de clorofila-a e SST observado e predito por RNA, analisados em conjunto	94
Figura 23 – Mapas preditos de clorofila-a por RNA.....	96
Figura 24 – Mapas preditos de SST por RNA.....	98

LISTA DE TABELAS

Tabela 1 – Características gerais da Represa do Lobo	52
Tabela 2 – Características do satélite Sentinel-2	58
Tabela 3 – Datas das coletas de campo e passagens do satélite	59
Tabela 4 – Dados climáticos dos meses de coleta	66
Tabela 5 – Síntese dos dados coletados com a Sonda Multiparâmetros	67
Tabela 6 – Síntese dos resultados das análises laboratoriais	68
Tabela 7 – Matriz de correlação entre as variáveis de qualidade da água.....	70
Tabela 8 – Valores médios dos COAs e dos índices espectrais por zona da represa e totais...	77
Tabela 9 – Resultados das análises de regressão para clorofila-a	79
Tabela 10 – Resultados das análises de regressão para SST	84
Tabela 11 – Resultados das RNAs para clorofila-a	88
Tabela 12 – Resultados das RNAs para SST.....	88

LISTA DE SIGLAS

AR	Análise de Regressão
BOA	<i>Bottom of Atmosphere</i>
CETESB	Companhia Ambiental do Estado de São Paulo
COA	Composto Opticamente Ativo
CONAMA	Conselho Nacional de Meio Ambiente
CV	Coeficiente de Variação
ESA	<i>European Space Agency</i>
IET	Índice de Estado Trófico
IQA	Índice de Qualidade da Água
MOD	Matéria Orgânica Dissolvida
MERIS	<i>Medium Resolution Imaging Spectrometer</i>
MSI	<i>MultiSpectral Instrument</i>
NIR	<i>Near Infrared</i>
NDCI	<i>Normalized Difference Chlorophyll Index</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NDWI	<i>Normalized Difference Water Index</i>
NRAVI	<i>Normalized Ratio Vegetation Index</i>
NTU	<i>Nephelometric Turbidity Unit</i>
OLI	<i>Operational Land Imager</i>
REM	Radiação Eletromagnética
RMSE	Raiz do erro médio quadrático
RNA	Redes Neurais Artificiais
SWIR	<i>Short-Wave Infrared</i>
SIRGAS	Sistema de Referência Geocêntrico para as Américas
SIS	Sólido inorgânico em suspensão
SST	Sólidos Suspensos Totais
TM	<i>Thematic Mapper</i>
TOA	<i>Top of Atmosphere</i>
USGS	<i>United States Geological Survey</i>
UTM	<i>Universal Transversa de Mercator</i>
VIS	Visível

SUMÁRIO

1 INTRODUÇÃO	19
1.1 HIPÓTESE	21
1.2 OBJETIVOS	21
2 REVISÃO BIBLIOGRÁFICA	22
2.1 MONITORAMENTO DA QUALIDADE DA ÁGUA.....	22
2.1.1 Eutrofização de corpos d'água e clorofila-a.....	22
2.1.2 Assoreamento de reservatórios e sólidos suspensos.....	24
2.1.3 Desafios do monitoramento da qualidade da água.....	26
2.2 SENSORIAMENTO REMOTO	27
2.2.1 Processamento digital de imagens.....	32
2.2.2 Sensoriamento remoto da água	36
2.3 APLICAÇÃO DE SENSORIAMENTO REMOTO NA QUALIDADE DA ÁGUA.....	42
2.3.1 Estudos desenvolvidos	44
2.3.2 Vantagens e desafios.....	47
3 METODOLOGIA.....	49
3.1 ÁREA DE ESTUDO	50
3.2 COLETA DE DADOS LIMNOLÓGICOS	54
3.3 AQUISIÇÃO E PROCESSAMENTO DAS IMAGENS	57
3.4 GERAÇÃO DE MODELOS DE PREDIÇÃO	61
3.4.1 Análises de Regressão.....	61
3.4.2 Redes Neurais Artificiais	63
4 RESULTADOS E DISCUSSÕES.....	66
4.1 DADOS LIMNOLÓGICOS	66
4.2 IMAGENS	71
4.3 MODELOS DE PREDIÇÃO DE CLOROFILA-A E SÓLIDOS SUSPENSOS	77
4.3.1 Regressões	77
4.3.2 Redes Neurais Artificiais	86
5 CONCLUSÕES	98
6 TRABALHOS FUTUROS	100
REFERÊNCIAS	101
APÊNDICE A - DADOS COLETADOS COM A SONDA MULTIPARÂMETROS	111

APÊNDICE B – DADOS ANALISADOS EM LABORATÓRIO	112
APÊNDICE C – RESULTADOS DAS ANÁLISES DE REGRESSÃO	113
APÊNDICE D – RESULTADOS DAS REDES NEURAIS ARTIFICIAIS.....	115

1 INTRODUÇÃO

O monitoramento da qualidade da água atualmente é essencial para a sustentabilidade e para a melhor gestão dos recursos hídricos. Neste sentido, considerando que os sistemas aquáticos estão constantemente sujeitos à degradação devido aos efeitos causados principalmente pela ação antrópica, há uma necessidade cada vez maior de se discutir e executar ferramentas auxiliares ao controle da qualidade da água nestes ambientes.

O monitoramento ambiental de ecossistemas aquáticos se dá principalmente por campanhas amostrais in situ de coleta de dados realizadas periodicamente, e sua eficiência é diretamente relacionada ao número de parâmetros analisados, a frequência dos levantamentos de campo e da distribuição dos pontos amostrais na bacia. Entretanto, os custos relacionados à instalação e manutenção de uma rede de estações amostrais pode inviabilizar a realização do projeto (ROIG et al., 2013). Além disso, a crescente demanda por monitoramento da qualidade de recursos hídricos pode não ser acompanhada pelas metodologias convencionais, sendo necessária a introdução de novas tecnologias de apoio (VILLAR et al., 2011).

Neste contexto, as geotecnologias surgem como alternativa para a fiscalização e análise ambiental de superfícies terrestres e seus recursos. O uso integrado de ferramentas como o sensoriamento remoto e o sistema de informações geográficas (SIG) permite a visualização espacial do fenômeno em estudo através do uso de técnicas tradicionais de interpolação (BENDOR et al., 2009). Além disso, tais ferramentas são importantes no monitoramento e simulação de diferentes componentes de recursos hídricos, auxiliando na tomada de decisões (LEITE; LEITE; CLEMENTE, 2010).

Medidas alternativas ao monitoramento in situ da qualidade da água em lagos, represas e reservatórios podem ser obtidas por meio de técnicas de sensoriamento remoto. Tal aplicação só é possível devido à presença de componentes opticamente ativos (COAs) na água. Essas substâncias podem ser identificadas por sensores remotos tendo em vista que sua presença em um corpo d'água resulta em diferentes padrões de absorção e retro-espalhamento da luz incidente, os quais são característicos de cada componente. Dentre os parâmetros de qualidade da água, sedimentos inorgânicos em suspensão, clorofila-a orgânica e material orgânico dissolvido são os principais agentes de absorção e espalhamento da radiação eletromagnética (REM) em um corpo d'água (JENSEN, 2011; CAMPBELL et al., 2011).

Destaca-se que estes componentes apresentam relações diretas com a qualidade do ecossistema aquático e seu entorno, sendo: a clorofila-a um importante bioindicador do nível

de trofia da água e, conseqüentemente, do processo de eutrofização de corpos hídricos (CETESB, 2009); e os sedimentos em suspensão podem estar relacionados à poluição da água, pois estes podem servir como agente transportador e armazenador de diversos poluentes, bem como indicar processos erosivos em uma bacia hidrográfica, resultando em assoreamentos dos principais rios e reservatórios (JENSEN, 2011).

Neste contexto, o uso de sensoriamento remoto torna-se uma ferramenta importante para monitorar sistemas aquáticos e suas bacias hidrográficas, pois permite a avaliação de problemas dinâmicos em sistemas aquáticos, tais como a eutrofização de corpos de água e dos sedimentos em suspensão. Esta metodologia também fornece uma visão sinóptica do meio ambiente, permitindo a identificação de áreas críticas de poluição na bacia hidrográfica e de entrada de nutrientes para a superfície de reservatórios (LOPES et al., 2016).

A partir de melhorias na tecnologia e na disponibilidade de dados de sensoriamento remoto, modelos mais precisos e generalizados têm sido desenvolvidos para monitorar a qualidade da água (KONG et al., 2018; PETERSON et al., 2018). Entretanto, como a evolução temporal das variáveis físico-químicas nos ecossistemas aquáticos é complexa e não-linear (SILVA et al., 2018), esta metodologia pode apresentar limitações se as análises entre os compostos e a resposta espectral da água forem regressões simplistas. Assim, observa-se a necessidade de pesquisa e aperfeiçoamento de técnicas de monitoramento de águas interiores integradas às facilidades proporcionadas pelas tecnologias desenvolvidas e disponíveis no mercado.

Neste sentido, abordagens envolvendo inteligência artificial com o uso de redes neurais apresentam-se como promissoras na área de sensoriamento remoto e no desenvolvimento de modelos de qualidade de água, pois podem ser mais sensíveis e robustas do que outras técnicas tradicionais de regressão, com capacidade de modelar ambientes complexos e capturar tanto relações lineares quanto não lineares entre os parâmetros envolvidos (MORIDNEJAD et al., 2015; GUO et al., 2016; KONG et al., 2018; PETERSON et al., 2018).

A realização de estudos e aplicação de ferramentas que sejam capazes de monitorar de forma contínua os ambientes aquáticos apresenta extrema relevância, tendo em vista que desta forma podem ser tomadas medidas preventivas e/ou corretivas e, assim, os danos ambientais e socioeconômicos podem ser minimizados ou evitados.

1.1 HIPÓTESE

O presente trabalho apresenta duas hipóteses principais: de que existe uma relação entre o comportamento espectral da água recebido pelo sensor remoto utilizado (satélite Sentinel-2) e a concentração dos compostos opticamente ativos nela presentes e, consequentemente, de que é possível estabelecer um modelo que permita prever a concentração de clorofila-a e sólidos suspensos através do processamento de imagens multiespectrais coletadas por sensoriamento remoto.

1.2 OBJETIVOS

Para corroborar as hipóteses supracitadas, o presente trabalho teve como objetivo principal estabelecer um modelo para prever os parâmetros sólidos suspensos e clorofila-a em corpos d'água a partir de imagens do satélite Sentinel-2. Para isso foi utilizada como material de estudo a Represa do Lobo/Broa, localizada no município de Itirapina/SP.

Baseando-se no objetivo geral do trabalho e nas hipóteses apresentadas foram estabelecidos cinco objetivos específicos, sendo eles:

- (a) avaliar a qualidade da água e discutir a variação espacial dos parâmetros sólidos suspensos e clorofila-a na Represa do Lobo/Broa;
- (b) avaliar o comportamento espectral da água na área de estudo;
- (c) comparar as imagens geradas dos índices espectrais com a variação espacial de clorofila-a e sólidos suspensos totais na represa;
- (d) verificar o desempenho de análises de regressão e de redes neurais artificiais para modelagem de clorofila-a e sólidos suspensos através de dados espectrais;
- (e) propor um modelo para predição destes compostos utilizando imagens do satélite Sentinel-2.

2 REVISÃO BIBLIOGRÁFICA

2.1 MONITORAMENTO DA QUALIDADE DA ÁGUA

A gestão de recursos hídricos é um tema de amplo interesse ambiental e também está relacionada e impacta, direta ou indiretamente, os meios sócio-econômicos, políticos e tecnológicos. Neste sentido, considerando que os sistemas aquáticos estão constantemente sujeitos à degradação de sua quantidade e qualidade devido aos efeitos causados principalmente pela ação antrópica, há uma necessidade cada vez maior de se discutir e executar o monitoramento da qualidade da água nestes ambientes.

O estudo dos diversos corpos hídricos, bem como de sua qualidade, é denominado limnologia. De acordo com Tundisi e Tundisi (2008, p. 20), limnologia caracteriza-se por ser “o estudo científico do conjunto de águas continentais em todo o Planeta, incluindo lagos, represas, rios, lagoas, costeiras, áreas pantanosas, lagos salinos e também estuários e áreas pantanosas em regiões costeiras”.

Sobre o monitoramento da qualidade da água em ambientes aquáticos, Breunig et al. (2017) destacam que à medida que as barragens em rios causam alterações nas características da água nas correntes superiores e inferiores dos reservatórios, é de extrema necessidade a avaliação da qualidade da água destes ambientes ao longo do tempo. Sperling (2005) aponta que a qualidade da água em recursos hídricos é resultante de fenômenos naturais (escoamento superficial e infiltração no solo, resultantes da precipitação atmosférica) e do uso e ocupação do solo na bacia hidrográfica, causados por interferências antrópicas.

Entre os impactos ambientais mais decorrentes nos sistemas aquáticos lênticos, como lagos e reservatórios, estão a eutrofização e o assoreamento dos mesmos. Este trabalho apresenta o enfoque no monitoramento da qualidade da água com objetivo de auxiliar a gestão dos recursos hídricos focado nestas duas problemáticas. Desta forma, os dois parâmetros que foram avaliados são a clorofila-a (considerada como indicadora do processo de eutrofização) e os sólidos suspensos (relacionados principalmente ao assoreamento de reservatórios).

2.1.1 Eutrofização de corpos d'água e clorofila-a

Um dos impactos qualitativos e quantitativos mais importantes em ambientes aquáticos lênticos (como lagos e represas) é a eutrofização. O aporte excessivo de nutrientes como fósforo e nitrogênio acelera o crescimento de algas, as quais inibem o processo fotossintético das

camadas inferiores por agirem como uma barreira para a penetração de luz, além da alta produção de detritos e acúmulo de sedimentos. Como consequência, ocorre a deterioração da qualidade da água devido à baixa disponibilidade de oxigênio dissolvido. Este processo pode ser desencadeado por eutrofização natural, que é um processo lento e contínuo, resultante dos efeitos do vento, erosão por chuvas, adição de material biológico, ou artificial, quando é induzida pelo homem podendo ter origens como fertilizantes orgânicos e inorgânicos, efluentes e poluição térmica (ESTEVES, 1988; TUNDISI; TUNDISI, 2008).

A eutrofização de massas naturais e artificiais de águas interiores no Brasil é um processo contínuo que está afetando economias regionais e nacionais. Isso se explica já que nos reservatórios que possuem usos múltiplos, como a geração de energia hidrelétrica, recreação, turismo, navegação, irrigação, pesca e aquicultura, os seus principais usos dependem de alguma forma da qualidade da água e do controle da eutrofização (TUNDISI; MATSUMURA-TUNDISI, 2013). Watanabe et al. (2015) apontam que ambientes artificiais como os reservatórios estão mais propícios a sofrerem com o aumento do nível trófico devido ao tempo de retenção da água e a alta disponibilidade de nutrientes nos mesmos.

Como forma de caracterização do estágio de eutrofização em que se encontra um corpo d'água, possibilitando a tomada de medidas corretivas e/ou preventivas, é adotado um sistema classificatório em que usualmente utilizam-se três principais níveis de trofia: oligotrófico (lagos claros e com baixa produtividade), mesotrófico (lagos com produtividade intermediária) e eutróficos (lagos com elevada produtividade em comparação ao nível natural) (ESTEVES, 1988; SPERLING, 2005). Alguns autores ainda apresentam classificações intermediárias como forma de se caracterizar estes ambientes de forma mais detalhada, tais como: ultra-oligotrófico, oligotrófico, mesotrófico, eutrófico e hipereutrófico (listados da menor para a maior produtividade) (SPERLING, 2005; TUNDISI; TUNDISI, 2008).

Embora diversos sejam os fatores qualitativos que atualmente caracterizam e diferenciam os lagos de acordo com os níveis de trofia, destacam-se alguns parâmetros qualitativos utilizados para esta classificação, sendo eles a transparência do corpo d'água, a concentração de fósforo e a de clorofila presentes no mesmo.

Relacionadas à presença de clorofila nestes meios, Vilela (2010) destaca que a presença de algas fitoplânctônicas pode alterar as características da água e a dinâmica biológica do ecossistema, sendo um importante fator a ser considerado na avaliação da condição ambiental do ambiente aquático. Neste sentido, o fitoplâncton apresenta-se como um dos parâmetros de qualidade da água mais importantes de ser monitorado, principalmente por ser um dos

constituintes que respondem mais rapidamente a mudanças ocorridas no meio (GONS; AUER; EFFLER, 2008).

O termo fitoplâncton se refere à comunidade de vegetais microscópicos que vivem em suspensão em corpos hídricos e que são constituídos principalmente por algas: clorofíceas, diatomáceas, euglenofíceas, crisofíceas, dinofíceas, xantofíceas e cianobactérias. Estas comunidades são a base da cadeia alimentar e, portanto, a produtividade de organismos superiores depende da sua biomassa (CETESB, 2009).

Embora o fitoplâncton tenha um papel importante no meio ambiente, Watanabe et al. (2015) destacam que altas concentrações de algumas espécies podem acarretar problemas de saúde pública tendo em vista que espécies de cianobactérias podem produzir toxinas que, em determinadas concentrações, podem causar doenças graves no fígado e no sistema nervoso, o que em situações mais graves pode levar à morte.

Os fitoplânctons, por serem organismos fotossintetizantes, utilizam-se da absorção da REM para fixar carbono e produzir oxigênio. A presença de pigmentos fotossinteticamente ativos, os quais absorvem energia eletromagnética entre o intervalo de 400 a 700 nm, são fundamentais para que este mecanismo fisiológico ocorra. Dentre os pigmentos – clorofilas, carotenóides e ficobilinas – a clorofila é a principal responsável pela absorção da REM, sendo a clorofila-a a mais comum entre as clorofilas (a, b, c e d) e o único pigmento a estar presente em todos os organismos fotossintetizantes (KIRK, 2011).

Sendo assim, a clorofila-a, por ser um pigmento espectralmente ativo, é comumente utilizada como indicador de biomassa e da produtividade de ecossistemas aquáticos e terrestres (KUDELA et al., 2015). A detecção de clorofila-a possibilita, principalmente, inferir o nível de trofia de ambientes aquáticos, sendo um importante bioindicador da qualidade da água (LONDE, 2008; CETESB, 2009; VILELA, 2010).

2.1.2 Assoreamento de reservatórios e sólidos suspensos

Além dos impactos decorrentes da eutrofização, outro importante impacto ambiental que ocorre principalmente em ambientes lânticos como reservatórios é o assoreamento. Vilela (2010) aponta que este processo de assoreamento pode interferir de forma negativa na qualidade da água e, ainda, indicar processos que estão ocorrendo neste ambiente e em toda sua bacia de captação. Neste sentido, a quantificação de material em suspensão é de extrema importância para o controle da qualidade da água nestes meios.

A presença de sedimentos em suspensão em águas interiores é proveniente de diversas fontes, incluindo a erosão de áreas agrícolas, intemperismo de rochas e minerais, entre outros (JENSEN, 2011). Vilela (2010) destaca que os sólidos presentes na água, dissolvidos ou suspensos, geralmente são carregados do leito dos rios e depositados principalmente em lagos e reservatórios. Desta forma, o volume de material em suspensão transportado pelos rios é influenciado diretamente pelos usos do solo na bacia hidrográfica, pelo desmatamento e pelo grau de cobertura vegetal (TUNDISI; TUNDISI, 2008). Destaca-se que, assim como referente à eutrofização, as atividades humanas também aceleram estes processos de geração, transporte e deposição de sedimentos.

Jensen (2011) afirma que monitorar o tipo, a quantidade e a distribuição espacial de sedimentos em suspensão em corpos d'água interiores e costeiros é muito importante. Por exemplo, a erosão do solo em uma bacia hidrográfica lança uma carga de sedimentos nos corpos d'água que resulta em assoreamentos mais rápidos dos principais rios, lagos e reservatórios. Isso pode diminuir a vida útil de reservatórios e ainda resultar na necessidade de dragagem de rios e lagos.

Neste sentido, realizar estimativas da presença de sólidos suspensos considerando sua variação espacial é de extrema importância para entender os processos de erosão, transporte de sedimentos e deposição (BREUNING et al., 2017).

Os sedimentos também afetam a qualidade da água e a sua adequação para consumo humano, recreação e uso industrial, tendo em vista que podem servir de agente transportador e armazenador de pesticidas, fósforo e nitrogênio adsorvidos, e compostos orgânicos que podem ser um indicador de poluição (JENSEN, 2011). Arantes et al. (2011) confirmam este impacto tendo em vista que observaram nos ambientes estudados uma relação entre o transporte de sedimentos e a concentração de fósforo e nitrogênio.

Além disso, a presença de sedimentos (ou sólidos) suspensos confere turbidez à água, podendo afetar comunidades biológicas e aquáticas ao interferir nos processos fotossintetizantes de algas e vegetação submersa, reduzindo, consequentemente, a disponibilidade de oxigênio dissolvido na água. Os usos doméstico, industrial e recreacional da água também ficam limitados à variação de turbidez (CETESB, 2009).

A parcela dos componentes da água denominada sólidos suspensos totais (SST), entre os constituintes de um corpo d'água, é o componente de maior peso no comportamento óptico da água. O SST consiste da matéria orgânica viva (principalmente algas), da matéria orgânica morta (detritos) e da matéria inorgânica (BARBOSA, 2005).

Segundo Vilela (2010), o material inorgânico particulado, composto principalmente por minerais provenientes de rochas e solos lixiviados, juntamente com a matéria orgânica dissolvida, forma uma composição de sólidos dissolvidos e suspensos presentes na água que alteram sua coloração e constituição.

A concentração de SST está frequentemente relacionada à produção primária total, fluxos de metais pesados e micro-poluentes e em muitas regiões turvas, está diretamente ligada a problemas de transporte sedimentar e à luz disponível para a produção primária (SONG et al. 2012).

2.1.3 Desafios do monitoramento da qualidade da água

Ferreira, Ennes e Galo (2010, p. 01) apontam que “um dos desafios relacionados com o manejo sustentável dos recursos hídricos reside no conhecimento da distribuição espacial e temporal da qualidade da água, mas esse conhecimento é, ainda, de difícil acesso”.

Neste contexto, segundo Prado (2004), não existe um monitoramento único aplicável a todos os reservatórios ou qualquer outro corpo hídrico, tendo em vista que cada sistema apresenta suas características próprias, como localização geográfica, hidrológicas, climáticas, utilização antrópica da água, dentre outras. Apesar deste desafio, o monitoramento efetivo da qualidade da água é importante para a tomada de decisões pelos gestores ambientais, pois fornece informações sobre as intervenções de gerenciamento que devem ser implementadas (MASOCHA et al., 2017). Sobre este assunto, Tundisi e Matsumura-Tundisi (2013) ainda ressaltam que a associação de pesquisa, planejamento e gestão de recursos naturais é uma estratégia poderosa para combater e superar as mudanças ambientais que o crescimento da população, industrialização e urbanização causaram.

A determinação da qualidade da água envolve medidas de variáveis físicas, químicas e biológicas, sendo que sua metodologia convencional de monitoramento implica em coletas realizadas *in situ* e posterior análise em laboratório. Entretanto, o monitoramento *in situ* de ecossistemas aquáticos nem sempre condiz com a frequência e abrangência necessárias (LONDE, 2008). Gholizadeh, Melesse e Reddi (2016) apontam que embora estas medidas *in situ* ofereçam alta precisão, as coletas de dados em campo são capazes de representar apenas estimativas pontuais da qualidade da água no tempo e no espaço, sendo a obtenção de variações espaciais e temporais quase impossíveis.

Além disso, técnicas convencionais de coleta e análise de água são normalmente custosas e demoradas, não sendo viáveis para fornecer um banco de dados simultâneo de qualidade da água em uma escala regional, o que poderia inviabilizar projetos de monitoramento da qualidade da água nesta escala. A isso, soma-se o fato de que muitos corpos d'água podem estar localizados em locais de difícil ou perigoso acesso, não sendo possível realizar o monitoramento *in situ* (ROIG et al., 2013; GHOLIZADEH; MELESSE; REDDI, 2016).

Sendo assim, Gholizadeh, Melesse e Reddi (2016) destacam que essas dificuldades de amostragens sucessivas e integradas tornam-se um obstáculo significativo para o monitoramento e gerenciamento da qualidade da água.

Considerando a importância da preservação dos recursos hídricos e que os problemas de qualidade da água ganham cada vez mais escala global, cria-se a necessidade de um monitoramento constante e dinâmico destes ambientes, sendo necessária a utilização de tecnologias mais baratas para este monitoramento mais eficaz e para subsidiar o gerenciamento destes recursos (MASOCHA et al., 2017).

Neste contexto, o sensoriamento remoto surge como uma ferramenta complementar no monitoramento de recursos hídricos, tendo em vista que a dedução de variáveis relacionadas à qualidade da água pode ser realizada através da análise das feições espectrais da radiação solar refletida pela superfície da água, onde elementos encontrados nesta água, como algas, material inorgânico suspenso e a matéria orgânica dissolvida, modificam o seu comportamento espectral (FLORENZANO, 2002).

2.2 SENSORIAMENTO REMOTO

Em linhas gerais, sensoriamento remoto é definido como a aquisição de dados em diversas faixas do espectro eletromagnético obtidas a partir de sensores acoplados em aeronaves ou satélites, sendo que a análise dessa informação pode ser realizada visualmente ou via processamento digital de imagens (JENSEN, 2011).

O sensoriamento remoto explora a relação entre as características do objeto alvo e a energia eletromagnética refletida, emitida ou espalhada por ele. Através da identificação do comportamento espectral de superfícies como o solo, água e vegetação, é possível relacionar informações qualitativas e quantitativas destes alvos (JENSEN, 2011). Assim, cada tipo de material ou superfície apresenta características únicas de comportamento espectral, ou seja, cada alvo é caracterizado pela sua assinatura espectral, a qual está diretamente ligada às suas

propriedades físicas, químicas, biológicas ou geométrica (NOVO, 2010). A Figura 1 exemplifica o exposto, apresentando os diferentes comportamentos espectrais de alvos da superfície terrestre.

Figura 1 – Comportamento espectrais de alvos da superfície terrestre

Fonte: Florenzano (2002).

Nota-se a diferença entre os comportamentos espectrais de cada alvo, destacando para a assinatura espectral da água, com baixa reflectância na região do visível até parte do infravermelho próximo e absorção total da energia a partir de 0,9 μm , e da vegetação, com alta reflectância na região do infravermelho próximo e picos de absorção característicos da presença de clorofila na região do visível e infravermelho médio.

Como já observado na Figura 1, dentre as regiões do espectro eletromagnético, o sensoriamento remoto da superfície terrestre se utiliza principalmente da região do visível, infravermelho próximo e infravermelho médio, pois correspondem à região de energia refletida pela superfície em resposta à energia solar incidente (NOVO, 2010).

A aquisição de dados de sensoriamento remoto é feita por sistemas sensores, os quais são responsáveis pela conversão da REM em um registro na forma de imagem ou gráfico que permita a interpretação do comportamento espectral do material de estudo (NOVO, 2010).

Os sensores remotos podem ser caracterizados de acordo com diferentes resoluções, sendo estas: temporal, radiométrica, espectral e espacial.

Segundo Novo (2010), a resolução temporal de um sensor consiste no intervalo de tempo entre dois imageamentos sucessivos ou duas aquisições dos dados. Este parâmetro é essencial para estudos de processos cíclicos e de monitoramento ambiental, pois a análise de

dados temporais auxilia no entendimento de como o elemento ou fenômeno se comporta ou está mudando com o passar do tempo (JENSEN, 2011).

A resolução radiométrica está relacionada à sensibilidade do sensor de detectar, registrar e reproduzir as variações nos níveis de energia (REM) refletida, emitida ou retroespalhada pelo objeto alvo (JENSEN, 2011; NOVO, 2010). Crósta (1992) e Meneses (2012) também afirmam que a resolução radiométrica é dada pela medida do número de níveis digitais (quantização), representando níveis de cinza usados para expressar os dados coletados pelo sensor, expressos em números binários (bits). Desta forma, altas resoluções radiométricas aumentam a probabilidade de se obter informações mais precisas acerca do fenômeno em estudo (JENSEN, 2011).

A resolução espectral de uma imagem é definida pelo número de bandas espectrais de um sistema sensor e pela largura do comprimento de onda coberto por cada banda (CRÓSTA, 1992). Meneses (2012) aponta que além do número e largura das bandas, a posição das bandas ao longo do espectro eletromagnético também é um importante aspecto a ser considerado quanto a resolução espectral para instrumentos de sensoriamento remoto. Logo, quanto maior o número de bandas situadas em diferentes regiões do espectro eletromagnético e com faixas mais estreitas de comprimento de onda, maior será a resolução espectral do sistema sensor (MENESES, 2012).

Em relação a sua resolução espectral, os sensores podem ser categorizados de acordo com a quantidade de bandas que é capaz de detectar. Sensores multiespectrais podem detectar até quatro regiões espectrais de uma mesma cena, compreendendo bandas da região do visível (VIS), infravermelho próximo (NIR, sigla em inglês de *Near Infrared*), infravermelho de ondas curtas (SWIR, sigla em inglês de *Short-Wave Infrared*) e infravermelho termal (NOVO, 2010). Entre essas bandas podem haver lacunas (faixas de comprimentos de onda não identificáveis pelo sensor), e a largura das regiões do espectro são tipicamente maiores. Já os sensores hiperespectrais e ultraespectrais possuem maior refinamento das faixas de comprimento de onda e maior sensibilidade a um maior número de bandas, podendo registrar espectros contínuos (mais de 100 bandas) para cada pixel da imagem (JENSEN, 2011; NOVO, 2010).

Por fim, a resolução espacial de uma imagem é definida pela capacidade do sensor remoto em “enxergar” objetos na superfície terrestre. Segundo Jensen (2011), há uma relação geral entre o tamanho de um objeto ou área a ser identificada e a resolução espacial de um sistema de sensoriamento remoto. Crósta (1992) destaca que quanto menor for o objeto possível de ser visto, maior deverá ser a resolução espacial da imagem.

Percebe-se, então, que a resolução espacial de uma imagem está diretamente relacionada ao nível de aquisição desta imagem. A altura do sensor remoto utilizado em relação ao alvo define o que se convencionou chamar de nível de aquisição de dados. Estes níveis dependem do veículo ou sistema de suporte (genericamente denominado de plataforma) para a operação de um sistema sensor (NOVO, 2010).

Existem basicamente três níveis de coleta de dados por sensoriamento remoto, que se diferenciam principalmente em relação a altitude da plataforma utilizada, sendo estes: nível de campo/laboratório, nível de aeronave e nível orbital (FLORENZANO, 2002; NOVO, 2010).

As plataformas terrestres, que coletam dados em nível de campo, muito utilizadas em espectroscopia de campo, também podem ser utilizadas em nível de laboratório com uso de dispositivos espectrorradiométricos manuais (MILTON et al., 2009). Importante destacar que medições de reflectância realizadas *in situ* são muito utilizadas para calibrar medidas de reflectância espectral obtidas por um sistema de sensoriamento remoto (JENSEN, 2011).

Os dados coletados ao nível de aeronave são mais adequados para aplicações com requisitos de alta resolução espacial, podendo ser adquiridos por sistemas sensores de varredura óptico-eletrônico, sistemas fotográficos ou radar, e a resolução espacial destes dados dependerá da altura do voo no momento do aerolevanteamento (MORAES, 2002). Segundo Novo (2010), as aquisições de dados ao nível de aeronave podem ser utilizadas para: identificar alvos presentes em classes espectrais discernidas em imagens orbitais; validação de dados orbitais; ou, ainda, para levantamento de informações específicas, principalmente quando não existe a necessidade de monitoramento frequente.

Já a obtenção de dados no nível orbital é realizada através de sistemas sensores a bordo de plataformas em órbitas da Terra (NOVO, 2010). Moraes (2002, p. 22) destaca que “o sensoriamento remoto neste nível permite a repetitividade das informações, bem como um melhor monitoramento dos recursos naturais para grandes áreas da superfície terrestre”.

É importante ressaltar que, quando trabalhamos com dados ao nível de aeronave e principalmente orbital, a energia registrada pelo sensor não se refere necessariamente a um determinado objeto, mas, dependendo da resolução espacial, a um arranjo de objetos da cena que podem possuir características diferentes, fazendo com que a imagem captada não represente com veracidade as características dos objetos nela presentes. Neste sentido, Florenzano (2002) destaca que a seleção do nível de aquisição de dados depende do objetivo para o qual os dados são adquiridos, pois a esta escolha pode interferir no comportamento espectral dos objetos de estudo.

Logo, as características espaciais, temporais, espectrais e radiométricas dos produtos imageados dependem, principalmente, da configuração do sistema sensor e da plataforma utilizadas durante a aquisição de dados.

Em estudos conduzidos com as mais diversas aplicações do sensoriamento remoto existem uma grande variedade de plataformas e dados de satélite que podem ser utilizados, como por exemplo, dados de: *Thematic Mapper* (TM) como os dos satélites Landsat; *Système Probatoire d'Observation de la Terre-High Resolution Visible* (SPOT- HRV); *National Oceanic and Atmospheric Administration/The Advanced Very High Resolution Radiometer* (NOAA/AVHRR); *Airborne Visible Infrared Imaging Spectrometer* (AVIRIS); *Moderate Resolution Imaging Spectroradiometer* (MODIS); *Medium Resolution Imaging Spectrometer* (MERIS); Hyperion e *China-Brazil Earth Resources Satellite* (CBERS) (GUO et al., 2016).

Com a disponibilidade de imagens multiespectrais de alta resolução espacial, espera-se que o desempenho dos classificadores possa ser melhorado, mesmo que para muitas aplicações, principalmente em estudos de água, um considerável aumento na resolução espacial não se configure em um também aumento na separabilidade entre as classes que representam os fenômenos de interesse. No entanto, independente da aplicação, é importante avaliar o nível de detalhamento necessário para detectar o fenômeno de interesse, uma vez que o custo da aquisição de imagens de alta resolução é elevado (CRUZ; GALO, 2005).

O novo sensor OLI (*Operational Land Imager*), a bordo do satélite Landsat-8 (lançado em 2013), apresenta alta qualidade de dados (relação sinal-ruído) e quantificação radiométrica (12 bits), o que pode melhorar os resultados obtidos através das análises destas imagens (AMANOLLAHI; KABOODVANDPOUR; MAJIDI, 2017). Lobo, Costa e Novo (2015) ainda destacam que, por apresentar características semelhantes de um TM, o sensor OLI permite a utilização de séries temporais com base em imagens Landsat para avaliação de mudanças temporais e fins de monitoramento terrestre e ambiental de 40 anos atrás até hoje.

Projetado para dar continuidade ao Landsat, o Sentinel-2 possui um tempo de revisitação de cinco dias e 13 bandas espectrais do visível ao infravermelho próximo, além de ser disponível em diversas plataformas da internet (KUHN et al., 2019). Ainda segundo os autores, o sensor Sentinel-2, comparado ao Landsat 8, possui uma maior resolução espacial, além do tempo de revisitação mais curto e a adição de novas bandas em NIR, específicas para estudo da vegetação em 703, 740 e 783 nm.

Além disso, a escolha do sensor adequado ao projeto dependerá do objeto ou fenômeno de estudo e as informações e resultados que se quer obter. Certas regiões e bandas do espectro eletromagnético podem ser relacionadas com certas características químicas, biológicas e

físicas do material de estudo. Assim, a seleção correta das bandas influenciará diretamente na resolução espectral do produto gerado, tendo em vista que esta escolha deve maximizar o contraste entre o objeto de interesse e os demais elementos (fundo) (JENSEN, 2011).

O conhecimento prévio do comportamento espectral do alvo de interesse também é importante na definição dos sensores, na definição do tipo de processamento a que devem ser submetidos os dados, assim como na definição da forma de aquisição dos mesmos. (NOVO, 2010).

Após a seleção do sensor remoto mais condizente com o objetivo da pesquisa, e respectivamente da imagem a ser utilizada, cabe ao pesquisador ter o conhecimento sobre o tipo de processamento que será necessário que esta imagem passe para que possa, então, ser considerada como objeto final de análise e interpretação da superfície terrestre. Desta forma, serão discutidos a seguir alguns aspectos referentes ao processamento digital de imagens.

2.2.1 Processamento digital de imagens

Nos últimos anos, o desenvolvimento de técnicas voltadas para a análise de dados multidimensionais, adquiridos por diversos tipos de sensores, tem sido desenvolvidas e aprimoradas. Estas técnicas têm recebido o nome de processamento digital de imagens, que se define como a análise e a manipulação de dados via computador com o objetivo de facilitar a identificação de alvos e a extração das informações (PRADO, 2004).

As técnicas típicas de pré-processamento de uma imagem digital bruta registrada pelos sensores de um satélite envolvem os processos de correções radiométricas, atmosféricas e geométricas. Liu (2007) aponta que todas estas operações tem o objetivo de restaurar as imagens adquiridas, removendo os efeitos dos ruídos causados pela interferência atmosférica e as limitações dos sistemas de satélite, a curvatura do globo, desgastes e degradação dos sensores e deslocamento do satélite no espaço durante seu tempo de funcionamento.

A correção atmosférica é necessária pois devido a presença de vapor d'água, nuvens e outros constituintes atmosféricos, os valores de reflectância recebidos pelo sensor na altura acima de 700 km estão sujeitos a interferências atmosféricas como absorção, espalhamento, emissão e reflexão. Existem diversos modelos físicos que são utilizados para a execução deste processo de correção, cada qual com suas particularidades e aplicações distintas de acordo com o objetivo do processamento da imagem (LIU, 2007).

Novo (2010) destaca, ainda, que para que se possam extrair informações a partir de dados de sensoriamento remoto, é fundamental o conhecimento do comportamento espectral dos objetos da superfície terrestre e dos fatores que interferem no seu comportamento. Em relação a isso, Jensen (2011) afirma que a maioria das pesquisas de sensoriamento remoto são baseadas no desenvolvimento de uma relação entre a quantidade de energia eletromagnética refletida, emitida, ou retroespalhada em bandas específicas e as características químicas, biológicas e físicas dos fenômenos em investigação.

Segundo Crósta (1992), em processamento digital de imagens várias operações matemáticas são utilizadas com o objetivo de analisar imagens multiespectrais (diferentes bandas espectrais de uma mesma cena) e/ou multi-temporais (bandas individuais adquiridas sobre uma mesma área em diferentes datas). Ainda segundo o autor, como regra geral destas operações, pode-se dizer que a adição e multiplicação servem para realçar similaridades espectrais entre bandas ou diferentes imagens, ao passo que a subtração e a divisão servem para realçar diferenças espectrais.

Dentre essas operações, a razão de bandas é a mais utilizada, tendo em vista a sua capacidade de realçar determinadas feições da curva de assinatura espectral de alguns materiais naturais e, por isso, acaba sendo de particular interesse em aplicações em geologia, agricultura e meio ambiente. Destaca-se, ainda, que se as bandas a serem divididas cobrem máximos e mínimos de absorção, assim como mudanças na inclinação da curva de assinatura, elas podem ser combinadas em pares de razões, com o objetivo de acentuar aspectos das assinaturas espectrais dos materiais (CRÓSTA, 1992).

Embora exista uma variedade muito grande de índices espectrais baseados em operações de bandas, considerando que o foco do trabalho é a utilização de sensoriamento remoto para a distinção de compostos dentro da água (sendo eles clorofila e sólidos suspensos), aqui serão apresentados e discutidos apenas os índices mais usuais que apresentam relação com a presença de vegetação e água na superfície terrestre.

Destas razões, uma das mais conhecidas é o chamado Índice de Vegetação por Diferença Normalizada – NDVI (sigla em inglês de *Normalized Difference Vegetation Index*), proposto por Rouse et al. (1974) para monitoramento do estado da vegetação, e sua equação apresenta uma razão entre as faixas espectrais do infravermelho próximo (NIR) e do vermelho (R):

$$NDVI = \frac{NIR - R}{NIR + R}$$

Os valores de NDVI computados variam de -1 a +1, sendo os valores negativos correspondentes à presença de água e os valores positivos, a uma vegetação densa em biomassa. A vantagem do NDVI sobre outros índices é que ele tende a ser linearmente mais proporcional à biomassa. Também se mostra mais apropriado quando se pretende fazer comparações ao longo do tempo de uma mesma área, pois seria pouco influenciado pelas variações das condições atmosféricas (LISSNER; GUASSELLI, 2013).

Segundo Jensen (2011), o NDVI é importante por que através dele podem ser monitoradas mudanças sazonais e interanuais no desenvolvimento da vegetação e, ainda, esta razão reduz muitas formas de ruídos (diferença de iluminação solar, sombras de nuvens, algumas alterações atmosféricas, algumas variações topográficas) presentes em múltiplas bandas de imagens de inúmeras datas.

Mishra e Mishra (2012) propuseram um novo índice para a quantificação da clorofila em corpos d'água, o Índice Normalizado de Diferença de Clorofila (NDCI – sigla em inglês de *Normalized Difference Chlorophyll Index*). Os autores seguem o mesmo conceito do NDVI, porém considerando as feições espectrais do pico de reflectância centrado em 700 nm e o pico de absorção espectral entre 665 nm e 675 nm (ambos sensíveis às variações de clorofila):

$$NDCI = \frac{NIR_{700nm} - R_{665nm}}{NIR_{700nm} + R_{665nm}}$$

Destaca-se, ainda, outra variação do NDVI, agora com a substituição do NIR pelo verde, com a intenção de se adotar uma banda que possui menor contraste entre solo e vegetação (TUCKER et al., 1979; GITELSON et al., 2002).

$$NRAVI = \frac{G - R}{G + R}$$

Embora nas referências originais não haja um nome específico para este índice, Coelho et al. (2011) e Candido et al. (2016) adotaram a nomenclatura para o mesmo como Índice Normalizado de Razão de Vegetação Aquática (NRAVI – sigla em inglês de *Normalized Ratio Aquatic Vegetation Index*).

Outro índice importante é o índice de água por diferença normalizada – NDWI (sigla em inglês de *Normalized Difference Water Index*), o qual foi desenvolvido para realçar as características espectrais da água, facilitando sua identificação em superfícies terrestres e

vegetadas. Esta razão relaciona as bandas do verde (G) e NIR, sendo calculada pela seguinte equação (McFEETERS, 1996):

$$NDWI = \frac{G - NIR}{G + NIR}$$

Este índice maximiza a reflectância da água pelo uso do espectro verde, minimiza a baixa reflectância da água no NIR e utiliza a alta reflectância da NIR pela vegetação e solo. Como resultado, os valores positivos do NDWI são correspondentes à presença de água, enquanto que as demais coberturas (solo, vegetação) apresentam valores negativos ou igual a zero (McFEETERS, 1996). Estudo conduzido por Oyama, Matsushita e Fukushima (2015) utilizou este índice para distinguir macrófitas aquáticas de florações de cianobactérias, além de salientar corpos d'água sem a presença das mesmas.

Como pode ser percebido, no estudo de sensoriamento remoto é de extrema importância que o pesquisador compreenda o comportamento espectral do alvo de interesse para que, então, possa decidir como processar as imagens obtidas de forma a realçar suas características.

Segundo Jensen (2011), os sistemas de sensoriamento remoto podem ter como aplicações medições diretas de algumas variáveis biofísicas, desde que sejam utilizados os sensores adequados para adquirir os dados. Neste contexto, o autor destaca que para estudos com o objetivo de caracterizar a vegetação, variáveis como pigmentos (clorofila a e b, por exemplo), estrutura e altura do dossel, biomassa derivada de índices de vegetação e evapotranspiração podem ser determinadas. Já quando o foco é a caracterização da água, estes sistemas podem fornecer informações sobre possíveis minerais em suspensão, clorofila, material orgânico em suspensão ou dissolvido e hidrologia de superfície.

Os corpos d'água presentes na natureza apresentam em suas composições constituintes orgânicos (fitoplâncton/clorofila, material orgânico dissolvido, entre outros) e inorgânicos (como minerais em suspensão) de origem natural ou antropogênica. Quando esses constituintes estão misturados na água, a identificação e quantificação de cada substância em separado se torna mais difícil por meio de técnicas de sensoriamento remoto (GOODIN et al., 1993). Por isso, faz-se necessário a compreensão do comportamento espectral individual dos constituintes, bem como a interação entre eles.

2.2.2 Sensoriamento remoto da água

Ao conduzir uma investigação de sensoriamento remoto de ambientes aquáticos, é necessário entender que o fluxo de energia radiante que atravessa a interface ar/água está sujeito a dois processos principais: absorção e espalhamento. Estes processos são quantificados através de coeficientes específicos que, por sua vez, são conhecidos como propriedades ópticas inerentes do corpo d'água. Estas propriedades dependem somente do meio em questão, sendo os valores dos coeficientes de absorção e espalhamento diretamente relacionados à presença (ou não), tipo e concentração de substâncias chamadas Compostos Ópticamente Ativos (COAs), que caracterizam-se por afetar o espectro de absorção e espalhamento da água pura, podendo ser formados por partículas em suspensão (orgânicas e inorgânicas), organismos vivos (fitoplâncton, zooplâncton e bacterioplâncton) e substâncias orgânicas dissolvidas (LONDE, 2008; NOVO, 2010).

De acordo com Jensen (2011) em estudos que visem à aplicabilidade de sensoriamento remoto para corpos d'água, é primeiramente útil entender como a água pura seletivamente absorve e/ou espalha a radiação incidente ou a luz solar descendente na coluna d'água. Depois, é importante considerar como a luz incidente é afetada quando a coluna da água não é pura, mas contém materiais orgânicos e inorgânicos.

Tal como já demonstrado na Figura 1, a água pura no estado líquido apresenta um comportamento espectral diferente dos demais alvos da superfície terrestre, tendo em vista que, diferente do solo e da vegetação, a energia refletida por ela é consideravelmente baixa (MACEDO; GALO, 2011). A principal característica da assinatura espectral da água pura é que acima de aproximadamente $0,7 \mu\text{m}$ a água absorve toda a radiação e que nos comprimentos de onda do visível, grande parte dela é transmitida, pouca luz é absorvida e uma pequena quantidade é refletida (MACEDO; GALO, 2011; NOVO, 2010).

Segundo Jensen (2011), a característica mais notável do comportamento espectral da água pura é que a quantidade mínima de absorção e espalhamento da luz incidente na coluna d'água (portanto, a melhor transmissão) ocorre na região do comprimento de onda do azul ($0,4$ a $0,5 \mu\text{m}$), com o valor mínimo localizado em aproximadamente $0,46 - 0,48 \mu\text{m}$. Considerando a forte absorção da radiação do infravermelho próximo e médio pela água, no processamento de imagens de sensoriamento remoto é possível perceber um forte contraste entre a água e os seus limites de terra (MACEDO; GALO, 2011).

Da mesma forma que as imagens de sensoriamento remoto podem identificar os diferentes comportamentos espectrais de alvos da superfície terrestre, elas também podem registrar estas alterações no comportamento da água, sejam aquelas adquiridas por sensores instalados em plataformas terrestres, aéreas ou orbitais (CRUZ; GALO, 2005).

As substâncias presentes na água são determinantes para sua análise, pois determinam a composição da água no momento em que é feita a coleta de dados. Assim, em termos de monitoramento por sensoriamento remoto, os comportamentos espectrais destas substâncias devem ser considerados (VILELA, 2010).

Em relação aos pigmentos fitoplanctônicos, embora haja uma grande variedade deles dentro de um corpo de água, os principais são os fotossintetizantes, como as clorofilas a, b, e c e os carotenoides. Entretanto, é a clorofila-a o pigmento mais comum nos diferentes gêneros presentes na água, sendo ela que melhor indica a quantidade de biomassa fitoplanctônica no ambiente e, ainda, a principal responsável pela absorção de energia luminosa (LISSNER; GUASSELLI, 2013; NOVO, 2010).

A Figura 2, apresentada a seguir, demonstra um conjunto de membros de referência, construído por Rudorff (2006), para representar as seguintes massas de águas espectralmente distintas: água clara, matéria orgânica dissolvida, sedimentos em suspensão e fitoplâncton.

Figura 2 - Modelos de referência representando massas de água distintas

Fonte: Rudorff (2006).

Ao analisar o comportamento espectral das diferentes massas d'água apresentados na Figura 2, é possível notar que a matéria orgânica dissolvida absorve radiação na faixa de comprimentos de onda do azul e pode gerar espalhamento por fluorescência no NIR, porém ambos os efeitos produzem feições espectrais com sinais baixos de reflectância e pouco notáveis. Tal constatação confirma a dificuldade em detectar variações de concentração de

matéria orgânica dissolvida por meio de dados de reflectância, uma vez que as respostas espectrais produzidas pelos demais COAs são bem mais dominantes (RUDORFF, 2006).

Em relação à presença da clorofila na água e sua respectiva alteração na curva espectral da água pura, Vilela (2010) destaca que para realizar a fotossíntese, que é a fixação da energia radiante na síntese de compostos orgânicos, as algas absorvem a REM, sendo o pigmento responsável por dar início a este processo é a clorofila-a.

Sobre estes pigmentos fotossinteticamente ativos, Cruz e Galo (2005) apontam que os mesmos são responsáveis pela absorção nas regiões espectrais do azul e do vermelho, de modo que um aumento na quantidade de fitoplâncton na água produz uma redução na quantidade dessa energia e a cor da água é percebida como verde.

A Figura 3 apresenta o efeito da presença de clorofila na água, onde é possível observar as características da reflectância espectral da água clara e da água contendo algas, compostas basicamente por clorofila.

Figura 3 – Resposta espectral de água clara e de água com algas

Fonte: Jensen (2011).

As feições características da curva espectral da água rica em clorofila que os autores relatam são:

- a) Forte absorção da luz azul entre 400 e 500 nm, apresentando um pico em 433 nm, denominado "Soret", causando baixa reflectância nesta região (BARBOSA, 2005; LONDE, 2008; JENSEN, 2011);
- b) Máximo de reflectância entre de 550 e 570 nm (pico do verde), causado pela absorção relativamente menor da luz verde pela alga (BARBOSA, 2005; JENSEN, 2011);

- c) Um pequeno ponto de inflexão na curva espectral em torno de 640 nm, devido ao retroespalhamento causado por pigmentos acessórios (BARBOSA, 2005);
- d) Forte absorção da luz vermelha entre 670 e 690 nm, apresentando um pico em 686 nm, denominado pico "alpha", causando baixos valores de reflectância nesta faixa (BARBOSA, 2005; LONDE, 2008; JENSEN, 2011);
- e) Um pico definido de reflectância no infravermelho próximo, entre 700 e 720 nm, causado por uma interação de espalhamento celular de algas e um efeito combinado mínimo de absorção por pigmento e água (BARBOSA, 2005; JENSEN, 2011);
- f) Um pico menor de reflectância próximo a 810 nm, provavelmente causado pelo retroespalhamento de matéria orgânica (células algais), combinado com a absorção pela água no infravermelho (BARBOSA, 2005).

Por fim, cabe ressaltar que Jensen (2011) propõe que a altura do pico na faixa do infravermelho próximo (em torno de 700 nm) acima da linha de base (mínimo de absorção) pode ser usada para medir precisamente a quantidade de clorofila presente na água.

Já em relação a presença de sólidos dissolvidos e em suspensão na água, ressalta-se que acaba acarretando alteração das suas características e a sua coloração para tons escuros de marrom e amarelo. Desta forma, segundo Novo (2010), corpos hídricos que apresentam partículas inorgânicas em suspensão tendem a apresentar curvas de comportamento espectral superiores à da água pura. Desta forma, quanto maior a concentração de sedimentos em suspensão na água, maior será sua reflectância, tendo em vista que estes componentes aumentam o coeficiente de espalhamento do volume de água.

A Figura 4 ilustra a reflectância espectral da água clara pura e da água contendo diversas concentrações de sólidos em suspensão.

Figura 4 - Resposta espectral da água contendo sólidos em suspensão

Fonte: Jensen (2011).

Nota-se que, apesar de haver uma relação entre a concentração de sedimentos em suspensão e a reflectância da água, principalmente na faixa entre 400 e 900 nm, esta relação não é linear, sendo controlada por diversos fatores, incluindo propriedades do sedimento como granulometria, forma das partículas e composição mineralógica (BARBOSA, 2005; VILELA, 2010; JENSEN, 2011).

Barbosa (2005) destaca as seguintes feições na curva espectral da água contendo sólidos suspensos:

- a) Um crescimento rápido da reflectância entre 400 e 550 nm, seguida por uma alta reflectância na faixa entre 550 e 650 nm, feições estas associadas ao espalhamento devido ao material particulado presente no sedimento e à baixa absorção pela água da REM nesta região;
- b) Um decréscimo rápido entre 700 e 740 nm, devido ao forte aumento de absorção da água nesta região;
- c) Um pequeno pico de reflectância entre 800 e 810 nm.

Segundo Jensen (2011), a faixa de comprimento de onda do infravermelho próximo (de 714 a 880 nm) pode ser utilizada para determinar a quantidade de sedimentos em suspensão nas águas em que eles sejam os constituintes predominantes, tendo em vista que neste intervalo os comportamentos das curvas das diferentes concentrações de sedimentos suspensos são semelhantes.

De acordo com Vilela (2010, p. 26), no estudo do comportamento espectral da água a principal dificuldade se deve ao fato de que “quando se estuda o comportamento de outro alvo qualquer, busca-se conhecer as propriedades daquele alvo; no caso da água, o que se busca conhecer são os componentes que se encontram nela presentes, sejam dissolvidos ou suspensos”. Neste sentido, vale ressaltar que reflectância espectral de cada componente na água deve ser vista como um somatório da interação da água com a REM mais a interação do componente com a REM (BARBOSA, 2005).

Considerando que corpos d’água dificilmente são formados por apenas um COA, Jensen (2011) ressalta que quando sedimentos em suspensão e clorofila estão presentes no corpo d’água ao mesmo tempo, uma resposta espectral muito diferente é produzida.

Tal situação pode ser exemplificada nas Figuras 5 e 6, que representam, respectivamente, espectros de águas ricas em clorofila com variadas concentrações de sólidos inorgânicos em suspensão (SIS) e espectros de água com alta concentração de SIS e variadas concentrações de clorofila, respectivamente.

Figura 5 - Resposta espectral da água contendo algas e sedimentos em suspensão

Fonte: Jensen (2011).

Figura 6 - Resposta espectral da água contendo sólidos suspensos e clorofila-a

Fonte: Sváb et al. (2005).

Ao analisar o gráfico da Figura 5, nota-se uma elevação da reflectância entre 550 e 650 nm em função do aumento da concentração de sólidos suspensos, com uma mudança no pico de reflectância na região do visível, deslocando-se de próximo a faixa de 550 nm (luz verde) para próximo a faixa de 600 nm (luz laranja). Destaca-se, ainda, a migração do pico de máxima reflexão do verde (550 nm) para o infravermelho próximo (710 nm) e a permanência da banda de absorção típica de clorofila em aproximadamente 675 nm, com aumento de contraste em relação ao espalhamento máximo entre 705-710 nm (LOBO, 2009; JENSEN, 2011).

Na situação em que se manteve alta a concentração de sólidos suspensos (340 mg/L) aumentando-se progressivamente a clorofila-a (Figura 6), observa-se que a presença dos sólidos eleva a porcentagem de reflectância em toda a região do visível, mascarando as feições características da presença de clorofila nas concentrações mais baixas (<24 µg/L). Tal situação

demonstra a dificuldade para identificação das feições de clorofila quando ocorre em massas d'água com altas concentrações de sólidos suspensos. Ainda é possível constatar que o pico próximo a 810 nm não é alterado com o aumento da clorofila, indicando que o maior espalhamento causado nesse comprimento de onda foi saturado pela presença de sólidos suspensos neste ambiente (LOBO, 2009).

Portanto, no sensoriamento remoto, o estudo do comportamento espectral da água é, na verdade, o estudo de um sistema aquático, que abrange os processos ocorridos na bacia hidrográfica e sua consequente interação com água (VILELA, 2010).

2.3 APLICAÇÃO DE SENSORIAMENTO REMOTO NA QUALIDADE DA ÁGUA

A necessidade de monitoramento contínuo e do manejo adequado dos recursos hídricos torna essencial a busca de métodos de pesquisa inovadores e eficientes que proporcionem o acompanhamento de forma prática e de longa duração. A demanda crescente pelo uso de técnicas de geoprocessamento e sensoriamento remoto na análise de parâmetros de qualidade da água amplia e agiliza essas possibilidades de gestão dos recursos hídricos (LISSNER; GUASSELL, 2013).

Guo et al. (2016) destacam que as técnicas de sensoriamento remoto são capazes de superar as deficiências dos métodos observacionais tradicionais. Em particular, as melhorias da geometria das imagens e da resolução espectral associadas ao desenvolvimento de tecnologia de sensoriamento remoto apresentaram novas possibilidades para a avaliação de recursos hídricos através do monitoramento da concentração de COAs.

De acordo com Londe (2008), a maioria dos algoritmos desenvolvidos para o sensoriamento remoto da água é baseada nos conceitos sobre as propriedades ópticas do ambiente aquático e considera a sua subdivisão em dois tipos: águas do Tipo I e do Tipo II. Em águas do Tipo I, a variabilidade nas propriedades ópticas da coluna de água é influenciada principalmente pela abundância do fitoplâncton ou de substâncias relacionadas ao seu ciclo de vida, permitindo que estas águas sejam modeladas em função da concentração de clorofila. Já em águas do Tipo II, existem também outros COAs, como matéria inorgânica particulada e matéria orgânica dissolvida, interferindo nas características ópticas da água e que devem ser considerados no momento da modelagem destes ambientes.

Os modelos de que envolvem a estimativa dos COAs em águas continentais caracterizadas como Tipo II tendem a ser mais complexos pelo fato desses corpos d'água

apresentarem além da clorofila, elevadas concentrações de SIS, os quais exercem influências significativas sobre as propriedades ópticas da água (RANDOLPH, 2007; LOBO, 2009). Desta forma, considerando a maior complexidade das águas do Tipo II, alguns pesquisadores (FENG et al., 2005; CHEN et al., 2017; KONG et al., 2018) afirmam que o desenvolvimento de algoritmos regionais possui melhores resultados para estimar parâmetros bio-ópticos nestes ambientes.

Gholizadeh, Melesse e Reddi (2016) apontam que as técnicas de sensoriamento remoto são utilizadas para a avaliação da qualidade da água desde a década de 1970 e continuam a ser amplamente utilizadas até hoje. Clarke, Ewing e Lorenzen (1970) foram os primeiros pesquisadores que lançaram a hipótese de que a quantidade de fitoplâncton no mar alterava a quantidade de energia que aquela superfície absorvia, retroespalhava e refletia.

Considerando que os modelos teóricos propostos para regiões oceânicas (em grande parte águas do Tipo I) não podiam ser utilizados no estudo na composição variada dos corpos d'água continentais, uma outra linha de atuação começou a ser desenvolvida principalmente a partir de 1972, com o lançamento do primeiro satélite de recursos naturais da série Landsat. Surgiu então uma série de trabalhos voltados à avaliação de dados orbitais focados nesta área de pesquisa (CESTARI, 1996).

Ao longo do tempo foram surgindo diversos sensores montados em satélites e outras plataformas, com as mais diferentes especificações. Os estudos sobre a quantidade de radiação em vários comprimentos de onda refletidos a partir da superfície da água foram se intensificando e atualmente, Gholizadeh, Melesse e Reddi (2016) apontam que essas reflexões podem ser usadas direta ou indiretamente para detectar diferentes indicadores de qualidade da água, tais como: concentração de clorofila-a, sólidos suspensos totais (SST), turbidez, salinidade, fósforo total, profundidade do disco Secchi, temperatura, pH, carbono orgânico dissolvido, entre outros.

Embora possa se considerar que as tecnologias atuais de sensoriamento remoto possuem muitas aplicações reais e potenciais para avaliar os recursos hídricos e para monitorar a qualidade da água, as limitações na resolução espectral e espacial dos sensores atuais em satélites atualmente restringem a ampla aplicação de dados de satélite para este fim (RITCHIE, ZIMBA, EVERITT, 2003). Sobre estas limitações nos estudos que visam monitorar as qualidades da água usando diferentes sensores e modelos, Amanollahi, Kabbodvandpour e Majidi (2017) destacam que a baixa qualidade de dados (relação sinal-ruído) e baixa quantificação radiométrica (inferior 12 bits) nos sensores utilizados podem ser um dos motivos para tal.

Diversos autores (WATANABE et al., 2015; HA et al., 2017; AMANOLLAHI; KABOODVANDPOUR; MAJIDI, 2017) apontam que o novo sensor OLI (*Operational Land Imager*), a bordo do satélite Landsat 8, por apresentar alta qualidade de dados (relação sinal-ruído) e quantificação radiométrica (12 bits), poderia melhorar os resultados estimados de diferentes propriedades químicas e físicas da água.

Em relação a utilização dos satélites Landsat para estudos de corpos d'água, Montanher, Barbosa e Novo (2013) apontam que, ao contrário dos dados de satélites como o MERIS, por exemplo, que é um sensor cujas características são adequadas aos sistemas aquáticos, os sensores da série de satélites Landsat foram desenvolvidos para aplicações relacionadas ao estudo de sistemas terrestres. No entanto, Ha et al. (2017) afirmam que, embora os sensores da série Landsat não tenham sido projetados para a aplicação da qualidade da água, desde seus estágios iniciais as imagens Landsat foram extensivamente aplicadas a isso através da estimativa das concentrações de clorofila-a e fitoplâncton e o monitoramento de florações de algas e macrófitas.

Neste sentido, o mais recente satélite Landsat 8 OLI, lançado no dia 11 de fevereiro de 2013, permite a continuação dos estudos sobre o monitoramento da qualidade da água com os dados anteriores do sensor Landsat TM e ETM+ (HA et al., 2017). Watanabe et al. (2015) apontam que embora a maioria das bandas OLI tenham aplicações terrestres, as bandas com aplicações em vegetação e pigmentos fotossintéticos podem ser adequadas para estimar as concentrações de pigmento de fitoplâncton em corpos d'água altamente produtivos. Os autores ainda destacam que as vantagens de se usar imagens OLI/Landsat-8 são a aquisição de dados a cada 16 dias e sua disponibilidade gratuita.

Diante do exposto, diversos são os estudos que aplicam esta relação entre a energia da REM recebida por sensores remotos e a qualidade da água. No tópico a seguir serão apresentados alguns destes estudos, com foco naqueles que utilizaram imagens de Landsat em sua modelagem, de forma que possam vir a ser comparados com este presente estudo.

2.3.1 Estudos desenvolvidos

Estudos conduzidos por diversos pesquisadores com base em dados obtidos coletas de campo, laboratório e obtidos por sensoriamento remoto analisaram os efeitos de diferentes concentrações dos COAs na resposta espectral de corpos d'água e propõem modelos que visam estimativas de concentração dos mesmos presentes na água, através de razões de bandas

(RUNDQUIST et al., 1996; ZIMBA; GITELSON, 2006; GITELSON et al., 2007; LE et al., 2009; NOVO et al., 2013; GUO et al., 2016; AMANOLLAHI; KABOODVANDPOUR; MAJIDI, 2017), sejam elas simples, com apenas duas feições, ou mais complexas (LONDE, 2008; RUDORFF, 2006; GOODIN et al., 1993; CHENG et al., 2013; GUO et al., 2016; AMANOLLAHI; KABOODVANDPOUR; MAJIDI, 2017).

Cabe ressaltar que, embora sejam três os COAs (clorofila, sólidos suspensos e matéria orgânica), a grande maioria da literatura estudada foca na estimativa apenas da clorofila, pois a mesma apresenta a maior concentração nestes ambientes e, conseqüentemente, maior impacto sobre a resposta espectral da água. Tal constatação ainda justifica-se devido aos sérios problemas ambientais causados em águas do mundo inteiro devido ao processo de eutrofização, sendo a clorofila um ótimo indicador deste.

Londe (2008) sugere que a escolha das feições de reflectância para o desenvolvimento do algoritmo seja baseada nas propriedades do pigmento de interesse. Para a clorofila-a, por exemplo, pode-se usar a banda de absorção na região do vermelho (em aproximadamente 670 nm) e a banda de fluorescência na região do infravermelho próximo, usualmente denominada NIR, em aproximadamente 700 nm. Esta razão é conhecida como “NIR/red” e fundamenta-se na sensibilidade de ambas feições para mudanças na concentração de clorofila-a, demonstrando que a variabilidade na densidade de pigmentos pode embasar um algoritmo para estimativa da concentração de clorofila-a através dos espectros.

Augusto-Silva et al. (2014) também confirmam que as bandas do vermelho e do infravermelho próximo são as geralmente utilizada nos algoritmos para a determinação da clorofila-a. Dall’olmo e Gitelson (2005) ainda justificam esta escolha pois dados espectrais não coincidentes e superpostos por matéria orgânica dissolvida (MOD) e SST na região azul do espectro tornam a relação azul-para-verde imprecisa para estimar a concentração de clorofila-a em águas onde esses componentes não estão correlacionados ao fitoplâncton.

Considerando que a estimativa precisa da clorofila torna-se mais complexa em águas turvas e produtivas, alguns autores propõem a aplicabilidade da utilização de algoritmos de três bandas na estimativa de concentração de clorofila, como é o caso de Gitelson et al. (2007) e Le et al. (2009).

Cândido et al. (2016) ressaltam que os algoritmos gerados a partir de índices de vegetação são bastante eficientes em estimar a concentração de clorofila em um corpo hídrico. Outros trabalhos como Coelho et al. (2011) e Veronez et al. (2018) também exploraram as relações entre os índices espectrais como NDVI, NDCI, NRAVI e NDWI e parâmetros de qualidade da água SST e MOD.

Especificamente referente a utilização do satélite Landsat, destaca-se o trabalho de Novo et al. (2013), que propôs a criação de um índice de estado trófico baseado na estimativa da concentração de clorofila no Reservatório de Ibitinga/SP através de sensoriamento remoto. Os autores apresentam um modelo consistente que considera a razão de duas bandas (NIR e vermelho) para a estimativa da clorofila na área de estudo.

Guo et al. (2016) apresentaram que o melhor resultado da análise de correlação entre as combinações de bandas de Landsat 8 OLI e a concentração de clorofila foi a razão entre a banda azul e a soma das bandas verde e vermelha. Destaca-se que os autores ainda compararam os resultados das correlações obtidos através de regressões lineares ($R^2=0,56$) e através da utilização de Redes Neurais Artificiais - RNA ($R^2=0,96$).

Em relação à correlação das imagens de Landsat e as concentrações de sólidos suspensos totais (SST) nos corpos d'água, destacam-se os trabalhos de Montanher et al. (2014) e Lobo, Costa e Novo (2015), ambos considerando como área de estudos os rios Amazônicos.

Montanher et al. (2014) propuseram modelos multivariados com diversas bandas derivadas do satélite Landsat 5/TM e obtiveram resultados significativos tanto para modelos regionais quanto para modelos globais (considerando vários locais de coleta). Guimarães et al. (2017) também propuseram modelos lineares múltiplos para determinação de clorofila-a em pequenos corpos d'água através de dados espectrais coletados em campo.

Já Lobo, Costa e Novo (2015), que utilizaram os sensores da família de satélites Landsat (TM e OLI) para recuperar os sólidos suspensos totais (SST) da água, obtiveram a melhor correlação empírica entre SST e reflectância através de uma função utilizando a banda vermelha.

Considerando que as concentrações de clorofila-a e de matéria em suspensão (SST) apresentam semelhanças em termos de padrões de distribuição espacial, diversos autores apontam dificuldades quanto a construção de um modelo de inversão de dados de sensoriamento remoto amplamente aplicável e de alta precisão destes parâmetros em conjunto em águas relativamente complexas, onde as concentrações variam de forma significativa. (GUO et al., 2016).

Breunig et al. (2017), Amanollahi, Kaboodvandpour e Majidi (2017) e Masocha et al. (2017) conseguiram resultados significativos quanto às correlações entre COAs em conjunto e dados espectrais, destacando que estes resultados variam de acordo com as concentrações dos mesmos dentro da água. Porém, os autores indicam a necessidade da utilização de técnicas de processamento destes dados mais complexas para o estudo destas relações, como as Redes

Neurais Artificiais (RNA), ferramenta também utilizada por Guo et al.. (2016) para a modelagem apenas da clorofila.

2.3.2 Vantagens e desafios

A inversão de parâmetros de qualidade da água usando a tecnologia de sensoriamento remoto pode melhorar o monitoramento da qualidade da água superficial e obter informações dinâmicas sobre a qualidade da água em tempo real. Dessa forma, esta técnica representa um importante complemento ao monitoramento regular da qualidade da água e pode fornecer uma sólida base científica para a tomada de decisões governamentais em relação à zona econômica ecológica (GUO et al., 2016).

É urgente a necessidade de se passar a monitorar a qualidade da água de maneira pontual para espacial (considerando toda a superfície) e de estática para dinâmica. Contudo, é difícil realizar este monitoramento (espacial e dinâmico) a longo prazo e em grandes áreas (GUO et al., 2016).

É neste contexto que o sensoriamento remoto se consolida como uma alternativa para se fazer uma estimativa da qualidade da água dos rios, lagos e oceanos. O potencial do sensoriamento remoto é destacado principalmente no direcionamento de trabalhos de campo, proporcionando um monitoramento constante e de baixo custo, identificando possíveis pontos críticos para coleta de amostras de água, auxiliando no monitoramento da qualidade do ambiente aquático (VILELA, 2010).

Amanollahi, Kaboodvandpour e Majidi (2017) destacam que com vantagens como a detecção remota, precisão aceitável, produção rápida de dados (o que possibilita sua alta frequência), metodologia compreensível (mesmo para não especialistas), cobertura global e alta rentabilidade, esta tecnologia abriu um novo corredor em direção a estudos ecológicos relacionados aos ambientes aquáticos.

No entanto, também se faz necessário comentar que diversos autores chamam atenção para a aplicabilidade global e temporal de modelos gerados a partir de sensoriamento remoto para o monitoramento da qualidade da água.

Por exemplo, Montanher, Barbosa e Novo (2013) apontam que muitos destes modelos acabam sendo aplicáveis apenas sobre as imagens em que foram gerados, não sendo úteis para utilização em outras datas e, conseqüentemente, para a proposta de monitoramento da qualidade. Os autores destacam ainda que para que os modelos possam responder de forma

adequada a esta variação temporal, devem ser desenvolvidos com base em várias imagens de diferentes datas, que abranjam a amplitude e as variações na composição do COA de interesse.

Ha et al. (2017), Chen et al., (2017) e Kong et al. (2018) ainda apontam que como esses métodos são fortemente dependentes do conjunto de dados, a aplicabilidade dos modelos gerados acaba muitas vezes sendo limitada ao local onde o mesmo foi gerado ou, no máximo, a outros ambientes da região com características semelhantes.

Breunig et al. (2017) ressalta que é importante, na ausência de modelos físicos, dados *in situ* são essenciais para construir e validar modelos de regressão entre as concentrações de COA e a resposta espectral das águas. Desta forma, a detecção remota não é totalmente independente do monitoramento baseado em campo (MASOCHA et al., 2017) pois a mesma é incapaz de capturar todos os indicadores utilizados na limnologia ou identificar os mesmos níveis de detalhes que as medições *in situ* (DORNHOFER; OPPELT, 2016).

Neste sentido, Dornhofer e Oppelt (2016) destacam a importância do uso sinérgico de medidas *in situ* e dados de observação da Terra (sensoriamento remoto) para que se possa preencher lacunas de dados de monitoramento da água e apoiar o gerenciamento de recursos hídricos. Os autores ainda apontam que o uso sinérgico de sensores com diferentes resoluções temporais, espaciais e espectrais pode superar as limitações que venham a existir em sistemas únicos.

O uso complementar de medidas convencionais e dados de sensoriamento remoto maximiza os pontos fortes e minimiza as fraquezas existentes no processo de monitoramento da qualidade da água em ambientes como lagos, represas e reservatórios (DORNHOFER; OPPELT, 2016).

Por fim, Gholizadeh, Melesse e Reddi (2016) destacam a importância da aplicação de ferramentas de detecção remota da qualidade da água em conformidade com outros programas que visem tal monitoramento, apontando como principais vantagens desta aplicação: visão sinóptica de todo o corpo de água para um monitoramento mais efetivo da variação espacial e temporal da qualidade; visão sincronizada da qualidade da água em um conjunto de lagos/represas em uma dada região; registro histórico da qualidade da água em uma área, indicando tendências ao longo do tempo; detecção de prioridades de locais de amostragem, impactando em menor tempo de levantamento de campo.

3 METODOLOGIA

A metodologia do presente trabalho foi dividida em três principais linhas, as quais estão apresentadas de forma simplificada no fluxograma da Figura 7. Observa-se que as duas primeiras linhas ocorreram de maneira simultânea e que a terceira teve como objetivo correlacionar os resultados finais das duas anteriores.

Figura 7 – Esquema metodológico

Fonte: Elaborado pela autora.

A descrição de cada etapa proposta, bem como seu maior detalhamento, será discutida nos itens que seguem, após a delimitação e caracterização da área de estudo do trabalho.

3.1 ÁREA DE ESTUDO

A área de estudo adotada para o desenvolvimento da pesquisa foi a Represa do Lobo (ou Represa do Broa), localizada entre os municípios de Brotas e Itirapina/SP. A represa está situada na Bacia Hidrográfica do Ribeirão do Lobo que, por sua vez, está inserida na Unidade de Gerenciamento de Recursos Hídricos 13 – Tietê/Jacaré. A Figura 8 apresenta o mapa da localização da Represa do Lobo.

A escolha da represa justifica-se pela proximidade da mesma com o Centro de Recursos Hídricos e Ecologia Aplicada (CRHEA), centro de pesquisa vinculado ao Programa de Pós-Graduação de Ciências da Engenharia Ambiental e a Escola de Engenharia de São Carlos (EESC) da Universidade de São Paulo (USP). Sua localização facilitou as coletas de dados e logística do trabalho. Além disso, trata-se de um ambiente amplamente estudado na comunidade científica, sendo apontada como a represa mais estudada do Brasil (CAMPREGHER; MARTINS, 2016). Pesquisas com ênfase neste reservatório, sejam relacionadas à quantidade ou qualidade da água, são realizadas desde meados de 1970, gerando uma vasta base de dados sobre as condições do local ao longo dos anos e possibilitando aos pesquisadores uma análise temporal de sua situação.

Figura 8 – Localização da Represa do Lobo

Fonte: Elaborado pela autora.

A Usina Hidrelétrica - UHE Carlos Botelho (mais conhecida como Represa do Lobo ou Broa) foi construída em 1936 com o objetivo principal de produção de energia elétrica em pequena escala. Atualmente o reservatório também é utilizado pela população para fins desportivos, recreacionais e de pesca amadora. Além disso, está localizada em uma área com usos distintos do solo, como ocupação com condomínios residenciais, reflorestamento de Pinus e Eucaliptus, cultivo de cana-de-açúcar e de pastagens, entre outros. (DELELLO, 2008; MEDEIROS, 2011; ARROIO JUNIOR, 2013).

As principais características da Represa do Lobo são apresentadas na Tabela 1. Seus principais afluentes são o Ribeirão do Lobo (que dá nome à bacia), o Rio Itaqueri e os Córregos do Geraldo e das Perdizes (Figura 8), sendo estes distintos entre si quanto à disponibilidade e qualidade da água que chega ao reservatório. Carvalho (2002) aponta que 80% do volume de água do reservatório vem da contribuição do Rio Itaqueri e do Ribeirão do Lobo, sendo também estes afluentes os que mais contribuem com o aumento de nutrientes e materiais alóctones ao mesmo.

Tabela 1 – Características gerais da Represa do Lobo

Parâmetro	Valor
Comprimento	8 km
Largura máxima	2 km
Largura média	0,9 km
Profundidade máxima	12 m
Profundidade média	3 m
Área	6,8 km ²
Volume	22 x 10 ⁶ m ³

Fonte: Adaptado de Tundisi, Matsumura-Tundisi e Rodrigues (2003).

Segundo Calijuri e Tundisi (1990), o Reservatório do Lobo caracteriza-se como um ambiente tropical raso e espacialmente pode ser dividido em dois compartimentos, sendo eles: compartimento superior, onde desaguam os rios Itaqueri e Lobo, que possui um banco de macrófitas que funciona como um filtro à entrada de nutrientes na represa por estes tributários; e compartimento inferior, caracterizando-se por ser mais profundo, misturado e verticalmente homogêneo.

Outros autores, como Santos (2003), Diniz (2016) e Vicentin et al. (2018), reportam uma subdivisão da represa em três partes ou zonas: zona de rio, zona de transição e zona

lacustre. A zona de rio localiza-se na entrada dos tributários Lobo, Itaqueri e Geraldo e é a que mais se assemelha a um sistema lótico, tendo menor profundidade e maior velocidade da água. A zona de transição caracteriza-se pela transição de um sistema lótico (rio) para lêntico (lago/lacustre). Por fim, a zona lacustre localiza-se próxima a barragem do reservatório e ao tributário Perdizes, sendo esta semelhante a um sistema lêntico e, portanto, possui maiores profundidades e velocidade praticamente nula, tendo apenas uma vazão de saída que pode ser vertida ou turbinada para geração de energia.

Em relação à qualidade da água e seu consequente nível de trofia, autores como Calijuri e Tundisi (1990), Argenton (2004) e Dellelo (2008) caracterizavam o ambiente como oligotrófico ou mesotrófico, ou seja, com nenhum ou pouco indício de eutrofização. Segundo Freitas (2012), essa situação se modifica quando, a partir do ano de 2010, a represa passa a ser caracterizada em alguns períodos do ano como eutrófica, apresentando águas já com concentrações significativas de nutrientes e clorofila-a.

Destaca-se, ainda, que entre os anos de 2014 e 2015, época da crise hídrica no Estado de São Paulo, a Represa do Lobo passou por sérios problemas ambientais ligados a eutrofização. Confirmando tal problemática, em outubro e novembro de 2014 a mesma foi caracterizada como imprópria para banho pela Companhia Ambiental do Estado de São Paulo – CETESB (CAMPREGHER; MARTINS, 2016). Estudos desta época apontam para ambientes hipereutróficos, com altas concentrações de nutrientes e clorofila-a na represa (SANTOS et al., 2016; MARAFÃO, 2016; NERI, 2016; DINIZ, 2016), bem como presença de *blooms* de cianobactérias em algumas épocas, sendo estas algas tóxicas e extremamente nocivas ao meio ambiente (CAMPREGHER; MARTINS, 2016; VICENTIN et al., 2018).

Embora sejam escassas as pesquisas sobre o monitoramento da qualidade da água na represa após o ano de 2015, a CETESB iniciou o monitoramento de forma bimestral deste ambiente a partir do ano de 2017, com análises não apenas focadas na sua balneabilidade (como anteriormente), mas também na qualidade da água e do sedimento do reservatório.

Desta forma, os dados do “Relatório de Qualidade das Águas Interiores do Estado de São Paulo - 2017” (CETESB, 2018) reportam uma possível recuperação deste ambiente, considerando que o Índice de Estado Trófico (IET) foi considerado mesotrófico em todas as coletas realizadas, assim como o Índice de Qualidade da Água (IQA) que também apresentou a classificação “boa” em todo o período. Além disso, destaca-se que os dois pontos de monitoramento de balneabilidade da represa, localizados no Balneário Santo Antônio, foram considerados próprios para banho durante todos os meses do mesmo ano.

Por fim, considerando que as condições de qualidade da represa estão diretamente interligadas com os fatores climáticos de seu entorno, cabe ressaltar que o clima da região é caracterizado por possuir dois períodos bem demarcados, sendo estes: verão úmido (de novembro a abril) e inverno seco (de maio a outubro) (TUNDISI; MATSUMURA-TUNDISI; RODRIGUES, 2003). Este comportamento pode ser confirmado a partir dos dados de precipitação coletados da estação climatológica do CRHEA para os anos de 2017 e 2018, apresentados na Figura 9. No gráfico é possível perceber as altas precipitações mensais no verão, principalmente no mês de janeiro, e o inverso ocorrendo no inverno, com destaque para os meses de junho e julho.

Figura 9 – Precipitação mensal de 2017 e 2018 (Estação Climatológica do CRHEA)

Fonte dos dados: Estação Climatológica do CRHEA. Elaborado pela autora.

Diante do exposto neste tópico a respeito da distribuição espacial das características da represa, as diferentes ocupações do solo na região e o aporte de diferentes tributários, bem como a influência das condições climáticas neste ambiente, cabe ressaltar que a coleta de dados buscou considerar da melhor maneira todas estas contribuições.

3.2 COLETA DE DADOS LIMNOLÓGICOS

As datas das amostragens de campo foram adotadas considerando que a sazonalidade pode influenciar diretamente nos parâmetros que foram analisados no presente estudo, tanto no quesito limnológico quanto em relação à assinatura espectral da água. Desta forma, as coletas ocorreram durante o ano de 2018 em três datas, onde se buscou avaliar os períodos chuvoso (23 de janeiro), intermediário (23 de maio) e seco (24 de julho), sendo possível assim obter uma amostra representativa do comportamento das variáveis ao longo destes períodos.

É importante destacar que as datas das coletas de água foram adotadas de forma a também coincidirem com o mais próximo possível da data de passagem do satélite na região, pois para fins de relação de dados entre o campo e a imagem coletada, mudanças climáticas no local, como eventos de chuva, poderiam influenciar nos resultados e representar dados não significativos para posterior comparação.

A distribuição dos pontos amostrais no reservatório buscou apontar as diferenças nos comportamentos dos parâmetros analisados e suas possíveis relações com o uso e ocupação do solo e com a chegada dos tributários. Para tal, optou-se por considerar a subdivisão da represa em três zonas (de rio, transição e lacustre), como já apontado anteriormente e adotado por outros autores que estudaram a represa do Lobo, concentrando a maioria dos pontos nas zonas de rio e lacustre e menos amostras na zona de transição por considerar que a mesma seria mais homogênea.

Destaca-se, ainda, a preocupação para a existência de um número de pontos suficientes para que os dados coletados correspondessem da melhor forma possível a totalidade da distribuição espacial dos parâmetros e que pudessem ser geradas análises estatísticas e modelos de correlação consistentes com base no tamanho da amostra.

Desta forma, estabeleceram-se para esta pesquisa de campo 30 pontos amostrais, sendo destes 40% localizados na região adotada como “zona de rio” (pontos 1 a 12), 20% na “zona de transição” (pontos 13 a 18) e os restantes 40% na “zona lacustre” (pontos 19 a 30). A localização dos mesmos pode ser observada na Figura 10.

O georreferenciamento dos pontos foi realizado no momento das coletas de água, por meio de GPS portátil da marca Garmin, modelo Montana 680. Foi adotado como sistema de referência o Geodésico SIRGAS 2000 (Sistema de Referência Geocêntrico para as Américas), na projeção UTM (*Universal Transversa de Mercator*), fuso 23S.

Figura 10 - Localização dos pontos amostrais

Fonte: Elaborado pela autora.

A coleta de amostras de água no interior do reservatório foi realizada por meio de amostragem simples e superficial (profundidade de até 30 cm da lâmina d'água), com galões de 5L, respeitando as orientações de coleta e preservação de amostras contidas no Guia Nacional de Coleta e Preservação de Amostras (CETESB, 2011).

No momento da coleta de água também ocorreu a leitura in situ com a Sonda Multiparâmetros YSI 6820 dos parâmetros pH, temperatura, condutividade elétrica e turbidez. Estes dados físico-químicos serviram de suporte para a compreensão da qualidade da água do local no momento da coleta.

As amostras de água coletadas foram encaminhadas para o Laboratório de Estudos Quali-Quantitativos de Sedimentos do Núcleo de Hidrometria, pertencente ao CRHEA/EESC/USP, para que pudessem ser analisados os parâmetros sólidos suspensos totais (SST) e clorofila-a.

Para a determinação da concentração de SST nas amostras de água foi considerado o procedimento via método gravimétrico, descrito no *Standard Methods for the Examination of Water and Wastewater* (APHA, 1995).

A determinação da concentração de clorofila-a nas amostras de água foi realizada através de método espectrofotométrico, proposto por Nusch (1980). Para isso, filtrou-se uma amostra conhecida de água em membrana de fibra de vidro GF-3 e, após, a extração da clorofila-a foi realizada utilizando como solvente o etanol 80% e posterior choque térmico. Finalizando o processo de extração, as amostras permaneceram refrigeradas por 24 h e, após, leu-se as absorbâncias nos comprimentos de onda de 665 nm e 750 nm em espectrofotômetro (comprimentos característicos na presença de clorofila). Por fim, com o objetivo de descontar a feoftina (degradação da clorofila) presente na amostra, acidificou-se as amostras com HCl até pH 2,6-2,8 e a leitura foi realizada novamente nos dois comprimentos de onda.

Os valores encontrados foram aplicados na seguinte equação:

$$\text{Clorofila } a \text{ } (\mu\text{g/L}) = \frac{[(U_{665} - U_{750}) - (A_{665} - A_{750})] \cdot v \cdot P}{V \cdot L}$$

Em que,

U_{665} = absorbância do extrato antes da acidificação em 665 nm

U_{750} = absorbância do extrato antes da acidificação em 750 nm

A_{665} = absorbância do extrato depois da acidificação em 665 nm

A_{750} = absorbância do extrato depois da acidificação em 750 nm

v = volume do etanol utilizado (10 mL)

P = constante derivada do coeficiente de absorção da clorofila-a para o etanol e do fator para equiparar redução em absorbância para concentração de clorofila-a ($P = 29,6 \text{ mg.cm.L}^{-1}$)

V = volume da água filtrada (L)

L = comprimento da cubeta espectrofotométrica utilizada (1 cm)

Por fim, a partir das coordenadas geográficas de cada ponto coletadas em campo e dos valores obtidos em laboratório para cada variável, estas observações foram convertidas em representações matriciais através da geração de mapas espacializados, tendo como objetivo fornecer uma visão sobre o comportamento espacial das variáveis analisadas. Este processo foi realizado via o software ArcGIS, utilizando como método de interpolação a Ponderação pelo Inverso da Distância (IDW) e como máscara o polígono da represa, restituído a partir das imagens de satélite da região.

3.3 AQUISIÇÃO E PROCESSAMENTO DAS IMAGENS

As imagens de sensoriamento remoto utilizadas neste estudo foram as dos satélites Sentinel-2A e 2B, sensor *MultiSpectral Instrument* – MSI, desenvolvido e controlado pela Agência Espacial Europeia - ESA (sigla em inglês de *European Space Agency*).

O Sentinel-2 é uma missão de imageamento multiespectral, de alta resolução e grande espectro, desenvolvida para apoiar estudos de monitoramento do programa *Copernicus* (programa de observação terrestre da União Europeia), incluindo o monitoramento da vegetação, cobertura de solo e água. Atualmente a constelação Sentinel-2 conta com satélites gêmeos (2A e 2B) voando na mesma órbita, mas em fase de 180°, para fornecer uma alta frequência de revisita de cinco dias próximo ao Equador (ESA, 2018).

Entre as características principais deste satélite e sensor utilizado, destacam-se: sua resolução espacial que varia de 10 a 60m; resolução radiométrica de 12 bits e resolução temporal de cinco dias (ESA, 2018). Na Tabela 2 são apresentadas as bandas espectrais deste satélite, seus intervalos de comprimentos de onda e suas respectivas resoluções espaciais.

Tabela 2 – Características do satélite Sentinel-2

Bandas espectrais*	Comprimentos de onda [μm]	Resolução Espacial [m]
Aerosol (B1)	0,421-0,457	60
Blue (B2)	0,439-0,535	10
Green (B3)	0,537-0,582	10
Red (B4)	0,646-0,685	10
Red Edge 1 (B5)	0,694-0,714	20
Red Edge 2 (B6)	0,731-0,749	20
Red Edge 3 (B7)	0,768-0,796	20
NIR (B8)	0,767-0,908	10
Red Edge 4 (B8A)	0,848-0,881	20
Water Vapor (B9)	0,931-0,958	60
Cirrus (B10)	1,338-1,414	60
SWIR-1 (B11)	1,539-1,681	20
SWIR-2 (B12)	2,072-2,312	20

*Nomes preservados da referência original (em inglês).

Fonte: ESA (2018).

A escolha deste satélite em detrimento de outros (como por exemplo, o Landsat-8 ou CBERS-4) deu-se considerando sua melhor resolução espacial e temporal, características que influenciariam positivamente na análise das imagens e na qualidade dos resultados finais. Além disso, a série Sentinel-2 apresenta a vantagem de possuir 4 bandas denominadas “Red Edge” e localizadas entre as bandas do vermelho e infravermelho próximo (NIR), região esta de grande interesse em estudos de vegetação e aplicados à água.

Com a intenção de que as imagens Sentinel adquiridas representassem da melhor forma possível as condições da represa no momento da coleta de dados em campo, procurou-se estabelecer o menor intervalo possível entre a data da coleta e de passagem do satélite. Estas informações a respeito de datas e distância entre o dia da coleta e da imagem Sentinel constam na Tabela 3.

Tabela 3 – Datas das coletas de campo e passagens do satélite

Mês	Coleta de campo	Passagem do Sentinel-2	Intervalo entre coleta e satélite
Janeiro	23/01/2018	04/02/2018	12 dias
Maio	23/05/2018	20/05/2018	3 dias
Julho	24/07/2018	19/07/2018	5 dias

Nota-se, analisando a Tabela 3, que o maior intervalo de tempo foi na primeira coleta, do mês de janeiro. Este fato se justifica devido à amostragem em campo ter sido realizada antes da data prevista de passagem do satélite, porém no dia do imageamento as condições do tempo estavam instáveis e a imagem não pode ser aproveitada devido a presença de nuvens. Destaca-se que esta coleta refere-se justamente ao período chuvoso e, por isso, houve a dificuldade em adquirir uma imagem do período próximo que não fora prejudicada pela presença de nuvens.

Considerando este ocorrido em janeiro, as coletas de campo na represa referentes aos meses de maio e julho foram realizadas somente após a passagem do satélite, garantindo assim que a imagem a ser utilizada tivesse a qualidade necessária para a finalidade em questão.

A aquisição das imagens Sentinel-2 não tem custo e foi feita junto ao site *Earth Explorer*, do Serviço Geológico dos Estados Unidos - USGS (sigla em inglês de *United States Geological Survey*). Para a área de estudo do presente trabalho (Represa do Lobo/Broa), foi realizada uma busca no site pela cidade de Itirapina e, após, foi constatado que a grade com o código T22KHA seria a mais adequada para esta pesquisa por englobar toda a bacia hidrográfica do Ribeirão do Lobo.

A imagem Sentinel disponível para download é de Nível 1C e já passou por um processo de pré-processamento que contempla as etapas de: descompressão e análises telemétricas (Nível 0), correções radiométricas e geométricas (Nível 1A) e reamostragem de pixels e transformação de números digitais em reflectância (Nível 1B). Desta forma, o produto final entregue ao usuário (Nível 1C) representa a Reflectância de Topo de Atmosfera - TOA (sigla em inglês de *Top of Atmosphere*) (ESA, 2018).

Para o processamento das imagens adquiridas foi utilizado o software SNAP 6.0, programa gratuito e de código aberto desenvolvido pela ESA. O software possui diversas funcionalidades para visualização, análise e processamento de imagens de diversos satélites, como Sentinel, Landsat, SPOT, MODIS, RapidEye, entre outros.

A primeira etapa do processamento foi a correção das imagens para desconsiderar o efeito atmosférico presente nos dados de Nível 1C – Reflectância TOA e transformá-los em Reflectância de Fundo de Atmosfera – BOA (sigla em inglês de *Bottom of Atmosphere*) ou simplesmente reflectância de superfície, denominada de Nível 2A (ESA, 2018).

Para isso foi utilizado o processador “*Sentinel-2 Atmospheric Correction*” (Sen2Cor), disponível na caixa de ferramentas específicas para o Sentinel-2 no SNAP. O algoritmo incluso no Sen2Cor é baseado no código de transferência radiativa e utiliza tabelas de referência geradas via LibRadtran, uma biblioteca para o cálculo da radiação solar e térmica na atmosfera da Terra (STEP, 2018).

A correção atmosférica no Sen2Cor deve ser realizada considerando uma resolução espacial específica (10, 20 ou 60m) e, neste caso, optou-se por realizar o processamento considerando a resolução de 10m. Destaca-se, ainda, que para todas as imagens o parâmetro de configuração “*Aerosol*” foi considerado o modelo rural e para o parâmetro “*Mid lat*”, que pondera as condições da atmosfera de acordo com as estações do ano, foi considerado o modelo de verão de meia latitude.

Os produtos finais após o processamento com o Sen2Cor possuem o mesmo formato dos dados de entrada (JPEG2000) e contém dados de reflectância de superfície de 10 bandas espectrais, sendo elas bandas 2-8, 8a, 11 e 12, sendo as demais ausentes devido a sua maior resolução espacial (bandas 1 e 9) ou porque não representam dados de superfície (banda 9). Os valores finais de cada pixel foram então multiplicados por 10.000 para que fossem convertidos de números digitais para valores físicos de reflectância.

Após estas correções, considerando que as imagens processadas foram de uma grande área e que a área de interesse já estava estabelecida, as imagens foram cortadas no limite da

represa, sendo as informações de terra removidas. Este processo visou facilitar a análise das informações e reduzir o tempo nos processamentos dos dados das próximas fases.

Finalmente, a partir das imagens processadas da Represa do Lobo para cada coleta, foram derivadas imagens com os índices NDVI, NDCI, NDWI e NRAVI, já apresentados anteriormente na revisão bibliográfica, cujas equações são:

$$NDVI = \frac{(b8-b4)}{(b8+b4)}$$

$$NDCI = \frac{(b5-b4)}{(b5+b4)}$$

$$NDWI = \frac{(b3-b8)}{(b3+b8)}$$

$$NRAVI = \frac{(b3-b4)}{(b4+b4)}$$

A escolha destes índices deve-se ao fato de que os mesmos exploram a relação entre regiões do espectro eletromagnético que são características da presença de COAs em corpos d'água, sendo elas: vermelho e NIR (índices NDVI e NDCI), verde e NIR (NDWI) e verde e vermelho (NRAVI).

Durante esta etapa de processamento das imagens foram gerados produtos cartográficos (mapas) que possibilitaram a posterior comparação visual e a correlação matemática dos dados obtidos entre si.

Para que os dados gerados a partir das imagens processadas fossem utilizados para a geração de modelos de predição de clorofila-a e SST, foi necessário extrair das imagens os valores numéricos de reflectância espectral ou dos índices gerados para cada ponto amostral. Para isso foram utilizadas as coordenadas UTM de cada ponto, para que fossem localizados os pixels da imagem referentes a este e, assim, seus respectivos valores fossem tabelados. Notou-se nesta fase que um dos pontos amostrais (P19) estava localizado muito próximo à margem da represa e que seus valores de pixels destoavam dos demais pontos em todas as coletas realizadas. Considerando que o tamanho do pixel das imagens utilizadas era de 10m, os mesmos poderiam estar sofrendo a influência da vegetação presente na margem e, por isso, optou-se por excluí-los do conjunto de dados utilizados nas análises posteriores.

3.4 GERAÇÃO DE MODELOS DE PREDIÇÃO

De posse do conjunto de dados provenientes das etapas anteriores (concentrações dos COAs clorofila-a e SST e variáveis espectrais provenientes das imagens Sentinel), a última etapa deste trabalho foi a de realizar análises entre os mesmos a fim de estabelecer modelos empíricos de predição de clorofila-a e sólidos suspensos para a área de estudo utilizando imagens Sentinel. Para atingir esse objetivo foram realizadas análises de regressão (AR) e, ainda, de inteligência artificial por meio de redes neurais artificiais (RNA).

O desempenho das análises foi avaliado utilizando as seguintes métricas estatísticas: RMSE (raiz do erro médio quadrático) e coeficiente de determinação (R^2). Suas respectivas equações são apresentadas abaixo:

$$RMSE = \sqrt{\frac{\sum (y'_i - y_i)^2}{n}}$$

$$R^2 = 1 - \frac{\sum (y_i - y'_i)^2}{\sum (y_i - \bar{y}_i)^2}$$

Onde y_i representa o valor observado, y'_i o valor predito, $\bar{y}_i$ a média das observações e n o número de amostras.

Para ambas abordagens, AR e RNA, o conjunto de dados coletados foi dividido aleatoriamente para que 80% deles fossem utilizados na calibração dos modelos de regressão ou no treinamento da RNA. Os 20% restantes foram utilizados na validação/teste dos modelos ou das redes geradas. Desta forma seria possível afirmar se os COAs de interesse estão sendo preditos de maneira esperada ou se o modelo não apresenta a capacidade de estimar adequadamente os compostos através de dados que não foram utilizados na sua calibração.

Nos tópicos a seguir serão detalhados os aspectos metodológicos referentes às análises de regressão e à rede neural artificial.

3.4.1 Análises de Regressão

Para as análises de regressão deste estudo os dados coletados foram avaliados separadamente por coleta (janeiro, maio e julho) e, também, todos juntos. Desta forma foi possível compreender qual das variáveis espectrais utilizadas foi mais pertinente para modelar

cada coleta (podendo representar diferentes estações do ano) e qual se ajustou melhor a uma análise conjunta, onde as diferenças de sazonalidade foram desprezadas.

Também foram considerados duas formas de tratamento de dados. Na primeira foram realizados os testes com todo o conjunto de dados coletados ($n=29$ para cada coleta individualmente e $n=87$ para as todas as coletas) e na segunda foram excluídos *outliers* que, por serem valores discrepantes à distribuição dos dados, poderiam estar prejudicando os ajustes das regressões. Neste caso, foi considerado como critério de seleção dos outliers aqueles que se encontravam fora dos limites apresentados no boxplot de cada coleta e parâmetro, ou seja, valores fora do range entre o menor e o maior ponto coletado dentro das amplitudes interquartis de 1,5 (MONTGOMERY; RUNGER; HUBELE, 2011), sendo eles:

- Janeiro: para clorofila-a P05 ($13,84\mu\text{g/L}$); para SST não houve;
- Maio: para clorofila-a P02 ($10,06\mu\text{g/L}$), P03 ($9,18\mu\text{g/L}$), P11 ($9,77\mu\text{g/L}$) e P20 ($13,62\mu\text{g/L}$); para SST P01 ($5,0\text{mg/L}$);
- Julho: para clorofila-a P06 ($15,39\mu\text{g/L}$); para SST P01 ($7,40\text{mg/L}$).

AR investigadas consistiram em modelos de regressão lineares e não-lineares considerando como variáveis dependentes a clorofila-a e o SST, analisados separadamente, e como variáveis independentes aquelas referentes às imagens Sentinel, sendo elas: reflectância das bandas individuais (B2 a B8, B8a, B11 e B12); razões entre bandas (todas as possibilidades de variações das bandas entre numerador e denominador, totalizando 90 razões); e índices espectrais (NDVI, NDCI, NDWI e NRAVI). Cabe ressaltar ainda que nas regressões não-lineares foram considerados os ajustes exponencial, logarítmico e quadrático.

Análises de regressões lineares múltiplas, com duas ou mais variáveis independentes combinadas, não foram consideradas neste estudo embora diversos estudos reportem uma significativa melhora nos resultados dos modelos gerados se forem consideradas nos ajustes das regressões mais de uma variável (GUIMARÃES et al., 2017; MORIDNEJAD et al., ; ANSPER; ALIKAS, 2019).

A opção de testar as regressões com razões entre bandas deu-se com o objetivo de realçar algumas características espectrais dos compostos analisados além de tentar remover possíveis diferenças na correção atmosférica de imagens de diferentes datas, técnica essa já utilizada na literatura. Porém, além das razões usuais apresentadas na literatura entre regiões do visível e infravermelho próximo, neste estudo também foram exploradas nas análises as bandas 11 e 12 (região do infravermelho médio) com objetivo de avaliar se a resposta destas bandas individualmente ou relacionadas a outras poderiam ter alguma relação com os COAs.

Após todos os testes realizados, os ajustes que obtiveram resultados de R^2 igual ou maior que 0,5 tiveram seus resíduos verificados para averiguar a validade das suposições para o ajustamento de regressões, sendo elas: homocedasticidade, normalidade e ausência de correlação entre os resíduos (MONTGOMERY; RUNGER; HUBELE, 2011). Para estas verificações dos modelos foram avaliados os seguintes gráficos de diagnóstico: valor predito versus valor medido; resíduo versus variável independente; resíduo versus valor predito; e probabilidade normal dos resíduos padronizados. Além disso, para confirmar a suposição de normalidade dos resíduos foram realizados os testes de Shapiro-Wilk e Kolmogorov-Smirnov.

Desta forma, para os modelos estimados que fossem adequados (suposições residuais verificadas), a etapa de validação foi executada. Nela, o conjunto de dados separado anteriormente (20%) que não foi utilizado para a calibração do modelo foi inserido no mesmo para averiguar se o mesmo teria a capacidade de realizar a predição do COAs de interesse de maneira que ficasse o mais próximo possível dos valores alvos. Para essa comparação foram calculados R^2 e RMSE entre os valores preditos na validação e os observados/medidos.

Todas as análises estatísticas e de regressão (lineares e não-lineares) foram realizadas no software livre R, sendo utilizado também o Microsoft Excel como suporte para organização e formatação dos dados.

3.4.2 Redes Neurais Artificiais

As análises que tinham como objetivo a predição de clorofila-a e SST a partir de redes neurais, assim como as análises de regressão, foram divididas em duas etapas: treinamento da rede neural e sua posterior validação com conjunto de dados diferente do primeiro estágio.

A rede adotada para este estudo foi a do tipo *backpropagation feed-forward*, sendo uma rede de treinamento supervisionado caracterizada pela aplicação sucessiva de duas fases específicas: na primeira os sinais são inseridos nas entradas da rede e se propagam camada a camada até a saída (*forward*), onde os valores de saída da rede são comparados às respostas desejadas e são calculados os erros e, assim, a segunda fase consiste em ajustar os pesos sinápticos e limiares de todos os neurônios da rede com base no erro calculado (*backward*) (SILVA; SPATTI; FLAUZINO, 2010). Diversos trabalhos aplicados a sensoriamento remoto da água utilizam esse tipo de rede, como Guo et al. (2016), Amanollahi, Kabbodvandpour e Majidi (2017) e Kong et al. (2018).

Como dados de entrada da rede, foram considerados os parâmetros relativos à característica espectral da água na região de estudo, ou seja, os dados coletados a partir das imagens Sentinel, e como saída dos processamentos da RNA, foram adotados os parâmetros clorofila-a e SST, analisados separadamente. Cabe ressaltar que todos os conjuntos da rede, tanto os de entrada quanto os de saída, foram normalizados entre [0,1] a fim de que os resultados da rede fossem alcançados com o menor esforço de treinamento (SOLA; SEVILLA, 1997).

Considerando que as imagens processadas do Sentinel (Nível 2A – Reflectância de Superfície) possuem 10 bandas, sendo oito destas na região do visível e infravermelho próximo e duas no infravermelho médio, foram analisados quatro conjuntos de entrada para os treinamentos das RNAs, sendo eles:

- Conjunto 1: 6 entradas - B2 a B7;
- Conjunto 2: 8 entradas - B2 a B8a;
- Conjunto 3: 10 entradas - B2 a B8a, B11 e B12;
- Conjunto 4: 4 entradas - Índices NDVI, NDWI, NDCI e NRAVI.

Os conjuntos 1 e 2 visam explorar as relações das bandas do visível (bandas 2 a 4) e infravermelho próximo (bandas 5 a 8a) com os COAs, sendo que o conjunto 1 se restringiu às bandas próximas a 0,8 μ m. Já com o conjunto 3, assim como nas regressões, buscou-se entender se as informações contidas nas bandas do infravermelho médio (bandas 11 e 12), embora não usuais, poderiam ser úteis na predição da clorofila-a e SST. Por fim, o conjunto 4 foi adotado pois seria uma maneira de incluir diversas relações espectrais entre regiões de interesse destes compostos com um número menor de variáveis de entrada e, além disso, por serem índices já normalizados pelas suas respectivas equações, dispensariam a necessidade de normalização dos dados para processamento na rede.

Na fase de treinamento das RNAs, os parâmetros que foram variados durante os testes foram os seguintes: números de neurônios na única camada oculta (de 5 a 20); funções de transferência/ativação das camadas oculta e de saída (sigmóide, tangente hiperbólica e linear); e, ainda, o número de ciclos/*epochs* de treinamento (de 100 a 500).

Alguns parâmetros foram considerados fixos, como: número de camadas ocultas (uma única); função de treinamento (Levenberg-Marquardt); taxa de aprendizagem (igual a 0,01) e taxa de *momentum* (igual a 0,9). A escolha do algoritmo de treinamento e a inserção do termo *momentum* foi visando potencializar a eficiência do processo de treinamento, conforme apontado em Silva, Spatti e Flauzino (2010), Din, Zhang e Suliman (2017) e Kong et al. (2018).

Assim como nas análises de regressão, os dados foram avaliados separadamente por coleta (janeiro, maio e julho) e, também, todos juntos. Destaca-se que para as análises que englobavam as coletas reunidas também foram realizados testes incluindo duas variáveis relacionadas ao clima como entradas (também normalizadas) no treinamento, sendo elas: temperatura média e umidade relativa do ar média, ambas mensais. A Tabela 4 apresenta os dados utilizados para estes testes, coletados da estação climatológica do CRHEA para os meses de janeiro, maio e julho de 2018.

Tabela 4 – Dados climáticos dos meses de coleta

Coletas	Temperatura Média (°C)	Umidade Relativa (%)
Janeiro	23,7	80,8
Maio	19,7	70,7
Julho	19,0	62,5

Fonte dos dados: Estação Climatológica do CRHEA.

Com a inserção destas variáveis, o objetivo era que a rede pudesse perceber que embora os dados estivessem todos no mesmo conjunto, possíveis diferenças entre os valores das demais entradas (reflectâncias ou índices espectrais) entre as coletas poderiam estar relacionados, além das diferentes saídas, com outras condições do ambiente, representadas nos testes pelo clima na região.

Todas as variações entre conjuntos de entrada, com ou sem as variáveis climáticas, topologias de RNA (números de neurônios e funções de transferência) e ciclos de treinamento foram testadas, mas apenas aquelas que obtiveram R^2 maior que 0,6 durante o treinamento foram validadas com o conjunto de dados diferente do treinamento. O critério de seleção para a fase de validação ($R^2 > 0,6$) se difere do da etapa de análises de regressão ($R^2 > 0,5$) pois foi considerado que este tipo de ferramenta proporciona resultados mais satisfatórios ao modelar fenômenos complexos e não-lineares e, por isso, os resultados tenderiam a ser melhores.

Durante esta etapa do trabalho, foram realizados inúmeros testes para obter a melhor configuração de RNA aplicável ao objetivo final de predição dos COAs através dos dados espectrais extraídos das imagens Sentinel, sendo utilizado como critério de seleção a rede que forneceu o maior R^2 e o menor RMSE durante as fases de treinamento e de validação.

Todo o processamento das RNAs foi realizado no software MATLAB R2015a, via interface gráfica própria para aplicação de redes neurais (*nntool*), sendo a organização dos dados de saída das redes para posterior apresentação feita no Microsoft Excel.

4 RESULTADOS E DISCUSSÕES

4.1 DADOS LIMNOLÓGICOS

Os dados a serem apresentados nesta seção são provenientes da leitura em campo dos parâmetros pH, temperatura, condutividade e turbidez com sonda multiparâmetros, bem como análises laboratoriais para determinação dos parâmetros sólidos suspensos totais (SST) e clorofila-a. Os mesmos serviram de suporte para uma breve discussão da qualidade da água da Represa do Lobo/Broa e, principalmente, para a geração de modelos de predição de clorofila-a e SST a partir de imagens de sensoriamento remoto.

A Tabela 5 apresenta a síntese dos dados coletados em campo para cada coleta realizada, bem como para todos os resultados reunidos. A tabela completa com os dados por ponto amostral e coleta encontra-se no Apêndice A.

Tabela 5 – Síntese dos dados coletados com a Sonda Multiparâmetros

Coleta	Parâmetro	Unidade	Média	Desvio Padrão	Valor Mínimo	Valor Máximo
Janeiro	pH	-	5,80	0,48	5,12	7,55
	Temperatura	°C	27,66	1,14	26,34	29,52
	Condutividade	µS/cm	17,20	0,16	13,00	20,00
	Turbidez	NTU	4,71	2,82	3,20	8,20
Maio	pH	-	5,12	0,24	4,78	5,86
	Temperatura	°C	20,55	0,81	17,89	21,40
	Condutividade	µS/cm	16,43	1,02	13,00	18,00
	Turbidez	NTU	4,50	0,91	3,40	7,30
Julho	pH	-	6,20	0,16	5,98	6,72
	Temperatura	°C	19,56	0,66	17,79	20,57
	Condutividade	µS/cm	25,17	2,82	23,00	38,00
	Turbidez	NTU	2,28	1,28	0,60	5,30
Todas	pH	-	5,70	0,55	4,78	7,55
	Temperatura	°C	22,59	3,71	17,79	29,52
	Condutividade	µS/cm	19,6	4,39	13,00	38,00
	Turbidez	NTU	3,85	1,68	0,60	8,20

Fonte: Elaborado pela autora.

Conforme os dados expostos na Tabela 5, tem-se que os parâmetros pH e condutividade apresentaram maiores valores na coleta do mês de julho, sendo que esta apresentou menor resultado de turbidez do período. Destaca-se que a variável pH apresentou resultado médio entre as três coletas de 5,70, sendo este valor abaixo do limite estabelecido pela Resolução CONAMA 357/2005 para rios de Classe II, que é de 6 a 9.

Como já mencionado no item 3.2, os parâmetros coletados em campo com a sonda multiparâmetros serviram para que fosse possível compreender melhor o comportamento da clorofila-a e SST.

Os resultados das análises laboratoriais realizadas para os parâmetros SST e clorofila-a, que são o foco desta pesquisa, são apresentados na Tabela 6 de forma resumida com os valores de média, desvio padrão, coeficiente de variação (CV) e valores mínimos e máximos. Os dados completos podem ser observados no Apêndice B.

Tabela 6 – Síntese dos resultados das análises laboratoriais

Coleta	Parâmetro	Unidade	Média	Desvio Padrão	CV (%)	Mínimo/ Máximo
Janeiro	SST	mg/L	2,47	1,43	57,22	0,80/5,67
	Clorofila-a	µg/L	7,06	2,67	38,12	3,16/13,81
Maio	SST	mg/L	3,22	0,68	21,81	2,17/5,00
	Clorofila-a	µg/L	5,81	2,27	40,38	2,66/13,62
Julho	SST	mg/L	3,45	1,31	39,49	1,38/7,40
	Clorofila-a	µg/L	9,18	1,77	19,78	6,22/15,39
Todas	SST	mg/L	3,05	1,26	41,22	0,80/7,40
	Clorofila-a	µg/L	7,35	2,66	36,46	2,66/15,39

Fonte: Elaborado pela autora.

Com base no exposto na Tabela 6, pode-se afirmar que em relação às médias dos pontos coletados, o parâmetro SST pouco variou durante as três coletas, embora o desvio padrão e o CV entre as coletas tenha se alterado, com destaque para a coleta do mês de janeiro que apresentou os maiores valores. A variação temporal da clorofila-a, apesar de pequena, pode ser percebida se observarmos as médias das coletas, apresentado menor valor em maio, seguido do mês de janeiro e, por fim, maiores concentrações no mês de julho. Tal comportamento também pode ser observado na Figura 11, que apresenta o gráfico boxplot com os resultados de clorofila-a e SST para cada coleta.

Figura 11 – Boxplot dos resultados de clorofila-a e SST

Fonte: Elaborado pela autora.

Observando a Figura 11 é possível perceber principalmente a distinção da distribuição dos resultados das coletas de janeiro, tanto para clorofila-a quanto para SST, sendo acentuadamente assimétrica, e a elevada dispersão dos dados coletados em janeiro para SST, característica também confirmada pelo alto valor de CV, apresentado na Tabela 6.

Ainda analisando os boxplots apresentados na Figura 11 nota-se ainda a presença de *outliers* nas amostras para cada parâmetro e coleta, com exceção do SST do mês de janeiro que não apresentou nenhum. Destaca-se, ainda, que o parâmetro clorofila-a durante a coleta de maio apresentou no conjunto dos dados quatro *outliers*, sendo eles P02, P03, P11 e P20, com concentrações iguais a 10,06µg/L, 9,18µg/L, 9,77µg/L e 13,62µg/L, respectivamente, sendo este último superior ao intervalo de três vezes o interquartil e, por isso, considerado um valor anômalo (MONTGOMERY; RUNGER; HUBELE, 2011).

Em relação aos valores encontrados neste estudo para as concentrações de clorofila-a na Represa do Lobo/Broa, destaca-se que os mesmos são menores que os apontados pela CETESB no “Relatório de Qualidade das Águas Interiores do Estado de São Paulo - 2017” para o mesmo período (janeiro, maio e julho) do ano de 2017. Além disso, destaca-se que os resultados se encontram bem abaixo do limite estabelecido pela Resolução CONAMA 357/2005 para rios de Classe II, que é de 30 µg/L.

Tal constatação, embora de forma preliminar, pode ser um indicativo de melhora da qualidade da água deste ambiente que, entre 2014 e 2015, chegou a possuir concentrações superiores a 100 µg/L em alguns pontos de coleta ao longo do período (SANTOS et al., 2016; MARAFÃO, 2016; NERI, 2016; DINIZ, 2016).

Buscando compreender qual a interferência dos parâmetros coletados em campo nas concentrações de clorofila-a e SST, foi construída uma matriz de correlação entre estas variáveis, apresentada na Tabela 7.

Tabela 7 – Matriz de correlação entre as variáveis de qualidade da água

	pH	Temp.	Cond.	Turb.	SST	Cl-a
pH	1					
Temp.	0,06	1				
Cond.	0,51	-0,50	1			
Turb.	-0,41	0,27	-0,49	1		
SST	0,05	-0,46	0,29	0,35	1	
Cl-a	0,44	-0,20	0,50	-0,02	0,41	1

Fonte: Elaborado pela autora.

Analisando os valores de correlação de Pearson (r) entre as variáveis, dispostos na Tabela 7, é possível concluir que no ambiente de estudo deste trabalho os parâmetros que apresentaram maior relação com SST foram temperatura ($r=-0,46$), clorofila-a ($r=0,41$) e turbidez ($r=0,35$). De acordo com a própria definição de SST, já era esperado que o mesmo apresentasse relações com a turbidez, tendo em vista que a presença de partículas suspensas na água reduz a sua transparência, e com a clorofila-a, pois os fitoplânctons encontram-se em suspensão nos corpos hídricos e, por isso, também estão incluídos na medição de SST (CETESB, 2009). A respeito da correlação com a temperatura da água, destaca-se que outros trabalhos, como Lane et al. (2007) e Tyrrell (2015), também apontam esta tendência decrescente da concentração de SST à medida que a temperatura aumenta, pois com este aumento ocorre uma queda da viscosidade da água e, assim, as partículas acabam se estabilizando mais facilmente e se sedimentam.

Já em relação a clorofila-a, nota-se na Tabela 7 que as variáveis que obtiveram valores de r mais elevados foram condutividade ($r=0,50$), pH ($r=0,44$) e SST ($r=0,41$). Esteves (1988) aponta que em um ecossistema aquático zonas de maior produtividade primária (ou seja, maior quantidade de fitoplânctons e, conseqüentemente, de clorofila-a) tendem a registrar maiores valores de condutividade elétrica. O mesmo autor ainda afirma que flutuações do pH da água estão relacionadas a processos de decomposição e atividades fotossintéticas, sendo estas condicionadas à densidade de comunidade e às atividades de algas e macrófitas aquáticas.

Como suporte para a discussão da variação espacial e temporal da clorofila-a e dos SST são apresentados nas Figuras 12 e 13, respectivamente, os mapas espacializados das mesmas para cada coleta.

Figura 12 – Distribuição espacial da clorofila-a

Fonte: Elaborado pela autora.

Figura 13 – Distribuição espacial dos sólidos suspensos

Fonte: Elaborado pela autora.

Em relação à distribuição espacial da clorofila-a na represa no período estudado, apresentada na Figura 12, tem-se as maiores concentrações em janeiro localizadas na zona de rio (próxima aos principais afluentes), com concentração média de $9,41 \mu\text{g/L}$, e uma

homogeneização dos valores a medida que aproxima-se da barragem nas zonas de transição e lacustre, com médias de 5,77 e 5,35 $\mu\text{g/L}$, respectivamente. Os resultados de maio apontam para uma distribuição mais uniforme da variável, destacando-se apenas um ponto amostral com concentração elevada (13,6 $\mu\text{g/L}$ no ponto 20), podendo indicar possível contaminação nesta região através da entrada de nutrientes provenientes das residências do entorno. Por fim, como já mencionado, o mês de julho apresentou as maiores concentrações de clorofila-a, sendo esta condição também apresentada de forma homogênea ao longo da represa, com valores mais altos nas zonas de rio e lacustre.

O comportamento espacial dos sólidos suspensos durante as coletas, demonstrado na Figura 13, foi em alguns aspectos semelhante ao da clorofila-a, como em relação aos maiores valores encontrados em janeiro na zona de rio e a distribuição uniforme do parâmetro na coleta de maio. A região próxima aos afluentes (zona de rio) apresentou maiores concentrações em todas as coletas, podendo ser justificada pelo fato de que neste local a profundidade da represa é pequena e a velocidade da água é maior, fazendo com que o material de fundo seja ressuspensionado.

A avaliação e compreensão do comportamento espacial destes dois parâmetros é importante tendo em vista que a resposta espectral coletada das imagens de satélite deste estudo pode ser influenciada por essa dinâmica específica do reservatório, com suas zonas de rio e lacustre, principalmente, bem delimitada e, por vezes, com características distintas.

4.2 IMAGENS

A etapa de processamento das imagens provenientes de sensoriamento remoto gerou diversos produtos cartográficos que serão apresentados nesta seção. Desta forma, como primeiro resultado tem-se os mapas gerados a partir das imagens corrigidas para valores de reflectância de superfície do satélite Sentinel-2, apresentados na Figura 14.

Como as três imagens passaram por processamento idênticos, ou seja, tiveram os mesmos parâmetros considerados na correção atmosférica, diferenças entre as mesmas podem estar relacionadas a alguma interferência da atmosfera que não foi corrigida no processamento ou ainda ao próprio comportamento espectral distinto nessa época do ano (estação chuvosa).

Figura 14 – Imagens Sentinel-2 processadas

Fonte: Elaborada pela autora.

Analisando a Figura 14 nota-se a visível diferença da imagem referente à coleta de janeiro em relação as demais, distinguindo-se por ser mais clara e, ainda, com a superfície da represa representada não de maneira uniforme como as outras duas e sim apresentando algumas regiões mais claras, podendo indicar distintos comportamentos espectrais. Além disso, destaca-se que na imagem de maio existem pequenas nuvens e sombras de nuvens na região da represa, fato este que foi averiguado para que nenhum ponto amostral tivesse localizado nestas regiões pois, se isso acontecesse, seus valores de reflectância estariam alterados.

Para visualização da diferença entre os comportamentos espectrais das imagens na região VIS e NIR foi construído o gráfico exibido na Figura 15, onde constam os valores médios de reflectância das bandas 2 a 7 e 8a para cada coleta. Neste caso, optou-se por não apresentar no gráfico os valores da banda 8 por esta ter como característica um intervalo de comprimento onda semelhante as bandas 7 e 8a juntas, conforme já demonstrado na Tabela 2.

Figura 15 – Gráfico do comportamento espectral médio extraído das imagens Sentinel-2

Fonte: Elaborado pela autora.

Observando a Figura 15 é possível corroborar a existência de uma diferença dos resultados do mês de janeiro em comparação a maio e julho, fato este que já havia sido evidenciado ao comparar as imagens da Figura 14. Avaliando apenas as respostas dos meses de maio e julho, nota-se um leve aumento nos valores de reflectância de maio para julho, sendo que os valores de clorofila-a também aumentaram no período, de 5,81 para 9,18 μ g/L.

Analisando o gráfico da Figura 15 nota-se, ainda, que embora os valores de reflectância de janeiro sejam maiores, o comportamento espectral das três coletas é bem semelhante, com valor máximo de reflectância na região do verde (B3) e mínimo nas regiões do infravermelho próximo, próximas a 750nm (B6) e 850nm (B8a). As únicas distinções entre os comportamentos das três coletas estão também em janeiro, onde a banda vermelha (B4) tem valor praticamente igual ao da *Red Edge 1* (B5), sendo nos outros meses levemente superior, e o inverso ocorrendo com as reflectâncias da *Red Edge 3* (B7) em comparação a *Red Edge 2* (B6), sendo levemente superior para janeiro e praticamente iguais para as outras coletas.

Cabe ressaltar que análises do comportamento da curva espectral média separado por zonas da represa (rio, de transição e lacustre) também foram realizadas, mas não apresentaram diferença significativa em relação ao apresentado na Figura 15 e, por isso, optou-se por não apresentá-las neste trabalho.

Comparando as curvas espectrais encontradas neste estudo com as apresentadas na literatura (Figuras 3 a 6), é possível perceber que as mesmas não apresentam o comportamento

típico de águas que contenham clorofila-a, sendo este: pico na região do verde, seguido de baixos valores de reflectância na faixa do vermelho e um novo pico no NIR (entre 700 e 720nm) (BARBOSA, 2005; JENSEN, 2011). Destaca-se que embora estudiosos apontem que as feições espectrais da água com sólidos suspensos apresentem maiores reflectâncias nas faixas do verde e vermelho devido ao espalhamento do material particulado e à baixa absorção pela água da REM nesta região (BARBOSA, 2005), o que também ocorreu neste estudo, os valores tendem a ser altos, sendo maiores que 5% e podendo chegar a 15%.

Neste sentido, considerado o já exposto e ainda os baixos valores de reflectância (entre 0,3 e 3%), conclui-se que o comportamento espectral extraídos das imagens Sentinel para as coletas de janeiro, maio e julho se assemelha mais ao da água clara, sem a presença de feições características que possam ser relacionadas aos COAs presentes nela.

A partir das imagens de reflectância de superfície processadas e delimitadas para a área da represa foram geradas as imagens dos índices NDVI, NDCI, NDWI e NRAVI para cada uma das três coletas, totalizando 12 imagens. Estas imagens são apresentadas na Figura 16. Destaca-se que embora a mesma paleta de cores tenha sido utilizada, cada imagem possui intervalos de respostas diferentes e, conseqüentemente, as cores que são apresentadas em cada um não necessariamente representam o mesmo valor numérico.

Figura 16 – Índices obtidos através das imagens Sentinel-2

Fonte: Elaborada pela autora.

Ao observar a Figura 16 com os resultados dos índices e seus respectivos intervalos de resposta, nota-se a predominância de valores negativos para a superfície da água para os índices NDWI e NDCI e valores positivos para o NDVI, o que é condizente com a literatura consultada (ROUSE et al., 1974; McFEETERS, 1996; LISSNER; GUASSELLI, 2013). Porém, não é possível perceber variações espaciais destes índices ao longo da represa, com exceção do NDCI de maio, que apresentou uma leve distinção entre os valores da zona de rio em comparação com as outras. Já o índice NRAVI foi o que proporcionou maior variação espacial para as três coletas, sempre apresentando os menores valores na zona de rio e em parte na de transição.

Para auxiliar na discussão dos resultados da Figura 16, a partir da extração dos valores dos índices das imagens por ponto amostral foi construída a Tabela 8, que contém os dados médios de NDVI, NDCI, NDWI e NRAVI por zona da represa e totais para os três meses, bem como considerando todas as coletas juntas.

Tabela 8 – Valores médios dos COAs e dos índices espectrais por zona da represa e totais

Coleta	Zona	Cl-a	SST	NDVI	NDCI	NDWI	NRAVI
Janeiro	Rio	9,41	3,81	-0,2091	-0,0086	0,2321	0,0242
	Transição	5,77	1,84	-0,2474	-0,0101	0,2958	0,0523
	Lacustre	5,35	1,45	-0,2230	-0,0095	0,2922	0,0740
	Média	7,06	2,47	-0,2223	-0,0093	0,2681	0,0489
Maio	Rio	6,59	3,44	-0,5439	-0,0772	0,5585	0,0232
	Transição	4,49	3,94	-0,5051	-0,0780	0,5255	0,0259
	Lacustre	5,70	3,14	-0,5017	-0,1095	0,5766	0,1100
	Média	5,81	3,22	-0,5199	-0,0896	0,5585	0,0567
Julho	Rio	9,72	4,12	-0,4613	-0,0883	0,5302	0,0938
	Transição	7,15	3,50	-0,4292	-0,0678	0,5678	0,1746
	Lacustre	9,64	2,76	-0,3575	-0,0771	0,5007	0,1888
	Média	9,18	3,45	-0,4153	-0,0798	0,5268	0,1441
Todas	Rio	8,57	3,79	-0,4048	-0,0580	0,4403	0,0471
	Transição	5,80	2,76	-0,3939	-0,0520	0,4630	0,0890
	Lacustre	6,90	2,45	-0,3607	-0,0654	0,4565	0,1196
	Média	7,36	3,05	-0,3858	-0,0596	0,4511	0,0833

Fonte: Elaborada pela autora.

De forma geral, analisando todos os resultados reunidos, a zona lacustre apresenta maiores valores de NDVI e NRAVI em comparação com as zonas de rio e de transição, comportamento este que se repete em maio e julho para o NDVI e em todas as coletas para o NRAVI.

O mês de janeiro foi o único mês em que as concentrações, tanto de clorofila-a quanto de SST, se destoaram de maneira mais evidente entre as zonas da represa, sendo a zona de rio tendo os maiores valores em comparação as outras duas, que apresentaram resultados próximos. Nesta coleta também a zona de rio apresentou o maior valor médio de NDVI e menor de NDWI e NRAVI, embora apenas a imagem referente ao NRAVI apresente esta situação se analisarmos a sua distribuição espacial.

4.3 MODELOS DE PREDIÇÃO DE CLOROFILA-A E SÓLIDOS SUSPENSOS

Os resultados da etapa de geração de modelos de predição pra clorofila-a e SST, como já mencionado anteriormente, foram divididos em duas abordagens distintas: análises de regressão e redes neurais artificiais. Os resultados de cada uma destas abordagens serão apresentados e discutidos nos tópicos a seguir.

4.3.1 Regressões

Durante a etapa que englobou as análises de regressão entre os COAs de interesse deste estudo (clorofila-a e SST) e os dados espectrais obtidos das imagens Sentinel, inúmeros testes foram realizados com o objetivo de encontrar quais variáveis estavam melhor correlacionadas com os parâmetros de qualidade e quais funções melhor se ajustavam a esta relação.

As análises para os meses de maio e julho modelados separadamente não retornaram resultados com desempenho satisfatório e, por isso, não serão apresentadas e discutidas neste trabalho. O mesmo ocorreu com as regressões que consideraram dados das três coletas juntas, provavelmente pela grande distinção entre as respostas espectrais do mês de janeiro em comparação a maio e julho (já apresentada na Figura 15).

Considerando o exposto, destaca-se que mais um conjunto de dados foi testado nas análises de regressão com o objetivo de tentar modelar juntos então os dois meses com resposta espectral próxima. Sendo assim, as respostas das amostragens de maio e julho foram reunidas e passaram pelas mesmas análises de regressão dos outros conjuntos.

Os resultados obtidos nas calibrações e validações dos modelos de regressão para clorofila-a que obtiveram coeficiente de determinação (R^2) igual ou superior a 0,50 encontram-se na Tabela 9. Para resultados idênticos e com variáveis semelhantes, como por exemplo B4/B3 e B3/B4, apenas a variável com melhor R^2 foi apresentado, sendo que no Apêndice C encontra-se a tabela com todos os resultados das regressões com R^2 maior que 0,30.

Tabela 9 – Resultados das análises de regressão para clorofila-a

Tratamento	Conjunto	Variável	Ajuste	Calibração			Validação		
				n	R^2	RMSE	N	R^2	RMSE
Nenhum	Janeiro	NRAVI	Quadrático	23	0,63	1,56	6	0,61	2,25
		B4/B3	Quadrático		0,64	1,56		0,62	2,24
		B5/B3	Quadrático		0,62	1,60		0,52	2,56
Exc. Outliers	Janeiro	NRAVI	Quadrático	23	0,53	1,50	5	0,67	2,51
		B3/B4	Quadrático		0,53	1,50		0,66	2,51
Exc. Outliers	Maio/ Julho	B12	Linear	42	0,68	1,35	11	0,74	1,17
		B12/B3	Quadrático		0,64	1,44		0,82	1,12
		B12/B4	Linear		0,64	1,44		0,63	1,55
		B12/B5	Linear		0,60	1,52		0,66	1,56

Fonte: Elaborada pela autora.

De forma geral, analisando os dados apresentados na Tabela 9, percebe-se que, embora as curvas espectrais médias de cada coleta apresentadas na Figura 15 não apresentassem visivelmente comportamentos que indicassem a presença de COAs, os resultados das análises de regressões realizadas neste estudo demonstraram correlações significativas (p -valor<0,001) entre a clorofila-a e as imagens em algumas coletas. Os valores de R^2 variaram de 0,53 a 0,68 na calibração e de 0,52 a 0,83 na validação. Já o RMSE variou de 1,35 a 1,60 $\mu\text{g/L}$ na calibração e de 1,12 a 2,56 $\mu\text{g/L}$ na validação.

Analisando os dados contidos na Tabela 9, tem-se que os melhores resultados das análises de regressão com a clorofila-a e os dados espectrais coletados em janeiro ocorreram com as variáveis que incluem bandas na região do verde (B3) e vermelho (B4), sendo elas: NRAVI, B4/B3 (para o conjunto completo, sem nenhum tratamento nos dados) e B3/B4 (conjunto sem outliers).

A regressão com a razão de bandas B4/B3 retornou R^2 de 0,64 e RMSE de 1,56 $\mu\text{g/L}$ na calibração do modelo e 0,62 e 2,24 $\mu\text{g/L}$ em sua validação. Para B3/B4 os resultados de R^2 da

calibração e validação foram respectivamente 0,53 e 0,66, enquanto o RMSE foi 1,50 e 2,51 $\mu\text{g/L}$. O NRAVI apresentou resultados distintos dependendo se o conjunto amostral utilizado tinha ou não *outliers*, sendo que os valores de R^2 do conjunto sem *outliers* foram inferiores aos do conjunto completo na etapa de calibração (de 0,63 para 0,53) e superiores na etapa de validação (de 0,61 para 0,67). Já considerando como métrica de desempenho o RMSE, a exclusão de *outliers* do conjunto de dados resultou em uma leve diminuição do erro na etapa de calibração dos modelos de 1,56 para 1,50 $\mu\text{g/L}$, fato este que não se repetiu durante a validação, pois o RMSE aumentou de 2,25 para 2,51 $\mu\text{g/L}$.

Embora grande parte dos estudos que abordem a mesma metodologia deste, ou ainda semelhantes, indiquem a maior sensibilidade da clorofila-a com a razão NIR/vermelho (LONDE, 2008; AUGUSTO-SILVA et al., 2014; SONG et al., 2012; MASOCHA et al., 2017), tem-se que Le et al. (2013) e Ha et al. (2017) também apresentaram resultados que indicam a correlação entre clorofila-a e a razão entre as bandas do vermelho e verde. Ha et al. (2017) apontam que em ambientes aquáticos onde sólidos suspensos são baixos, o pico de refletância na região verde em relação ao vermelho tem um potencial para estimar a clorofila-a, pois nestas condições o efeito dos SST neste pico torna-se insignificante.

Além disso, destaca-se que, assim como neste trabalho, nas condições da água observadas por Ha et al. (2017), o comportamento espectral dos pontos amostrais não apresentou com clareza o pico de refletância próximo a 700nm, sendo inclusive os valores de refletância nesta região do NIR inferior à refletância do vermelho em vários pontos. Assim, os autores justificam o porquê da razão entre as bandas NIR-vermelho ter sido muito menos apropriada do que a razão entre as verde-vermelho.

Já em relação especificamente ao NRAVI, destaca-se que Coelho et al. (2011) e Candido et al. (2016) também obtiveram ótimos resultados ao relacionarem o mesmo com a clorofila-a ($R^2 > 0,9$), sendo que ambos utilizaram imagens de satélite com resolução semelhantes a este trabalho (CBERS - 20m e Landsat 8 - 30m), embora as concentrações de clorofila-a sejam diferentes, pois Coelho et al. (2011) obtiveram até 80 $\mu\text{g/L}$, enquanto os ambientes estudados por Candido et al. (2016) não passaram da concentração de 5 $\mu\text{g/L}$.

Tem-se ainda que, de acordo com a Tabela 9, as análises de regressão considerando imagens de mais de uma coleta, ou seja, com o conjunto Maio/Julho, não apresentaram o mesmo comportamento de janeiro nos seus resultados, pois os melhores ajustes se deram com variáveis que incluíam a banda SWIR-2 (B12) individual ou razões desta com as bandas verde e vermelha (B3 e B4, respectivamente).

Embora as variáveis espectrais sejam diferentes das utilizadas para janeiro, destaca-se que os desempenhos dos modelos de Maio/Julho foram superiores aos gerados para Janeiro, provavelmente devido a possíveis interferências atmosféricas nas imagens de janeiro que vieram a prejudicar sua modelagem. Na calibração o R^2 foi de 0,64 para B12/B3 e B12/B4 e de 0,68 para B12 e o RMSE foi de 1,44 μ g/L para B12/B3 e B12/B4 e 1,35 μ g/L para a B12. Já a validação dos modelos retornou o melhor resultado para a razão B12/B3, que apresentou R^2 de 0,82 e RMSE de 1,12 μ g/L.

Como já mencionado na metodologia, neste trabalho optou-se por explorar as relações entre os COAs de interesse e as reflectâncias na região do SWIR, mesmo ciente de que a literatura praticamente não menciona esta aplicação pelo fato da água absorver praticamente toda a REM nestes comprimentos de onda. Mesmo assim, só foi possível modelar a concentração de clorofila-a nos meses de maio e julho considerando a variável B12.

Embora não sejam encontradas na literatura aplicações semelhantes a deste trabalho em relação a inserção da banda SWIR como possibilidade de correlação com a clorofila-a, destaca-se que Knaeps et al. (2015) apontaram que a suposição de reflectância nula nestes comprimentos de onda mais altos (SWIR-1 e 2) nem sempre é válida, podendo ser esperada alguma contribuição de radiação nesta região dependendo das características da água, como, por exemplo, se elas forem muito turvas. Shi e Wang (2014) também evidenciaram valores de reflectância diferentes de zero no SWIR das imagens MODIS de águas oceânicas. Veronez et al. (2018) foram precursores nesta aplicação de bandas do SWIR para a estimativa de COAs. Esses autores substituíram a banda na região do NIR pelo SWIR em índices como NDVI e NDWI para estimar sólidos suspensos totais e matéria orgânica dissolvida na água e obtiveram com isso melhoria dos seus resultados.

Neste sentido, a utilização de bandas na região do SWIR na correlação com dados de qualidade da água deve ser melhor estudada, pois o indicativo que os resultados deste trabalho apontam é de que não só as mesmas são passíveis de se utilizar na predição de clorofila-a como também talvez influenciam positivamente nos resultados quando imagens de mais de uma data são modeladas juntas.

Por fim, cabe ressaltar que observando os resultados das calibrações e validações dos modelos de regressão para a clorofila-a (Tabela 9), percebe-se que a exclusão dos *outliers* presentes nas amostras coletadas aprimorou os resultados dos modelos obtidos tendo em vista que possibilitou que todos os meses de amostragem fossem modelados a partir dos dados espectrais. Desta forma, os modelos adotados para a predição de clorofila-a na Represa do Lobo

foram aqueles que consideraram a variável explicativa NRAVI para o mês de janeiro e B12/B3 para maio e julho. As respectivas equações obtidas destes modelos adotados são apresentadas a seguir.

Para janeiro:

$$Cl - a (\mu\text{g/L}) = 237,55 * NRAVI^2 - 77,60 * NRAVI + 10,26 \quad \text{Eq. (1)}$$

Para maio e julho:

$$Cl - a (\mu\text{g/L}) = 8,70 * (B12/B3)^2 + 1,59 * (B12/B3) + 4,15 \quad \text{Eq. (2)}$$

Aplicando nas equações os respectivos valores de NRAVI para os todos os pontos amostrais de janeiro e de B12/B3 para todos os dados de maio e julho foram construídos os gráficos da Figura 17, que apresentam os dados de clorofila-a observados em campo (eixo x) e seus respectivos valores preditos pelos modelos de regressão (eixo y).

Figura 17 – Gráfico de clorofila-a observada e predita por regressões

Primeiramente cabe ressaltar que os valores de R^2 e RMSE apresentados nos gráficos da Figura 17 são diferentes dos resultados que constam na Tabela 9, pois são análises do desempenho dos modelos considerando os conjuntos de calibração e validação reunidos.

Observando os gráficos é possível confirmar o melhor ajuste das regressões para Maio/Julho em relação à Janeiro, como já apresentado na Tabela 9 e também mencionado anteriormente. Enquanto para janeiro o modelo NRAVI obteve R^2 de 0,58 e RMSE de 1,80 µg/L, para o modelo único gerado para os meses de maio e julho o desempenho foi de 0,66 o R^2 e 1,38µg/L o RMSE. Estes baixos valores de RMSE confirmam a capacidade da utilização de sensoriamento remoto e análises de regressão para estimar clorofila-a na represa, tendo em

vista que para fins de monitoramento ambiental a variação de 1,5 a 2 µg/L não deve afetar significativamente os resultados, ainda mais se isso for comparado aos benefícios da utilização de ferramentas como essa considerando um melhor controle da variação temporal e espacial da clorofila-a.

Por fim, de posse das duas equações de predição de clorofila-a, para janeiro (eq. 1) e para maio e julho (eq. 2), foram gerados mapas de predição da clorofila-a para toda a área da Represa do Lobo para os meses da coleta, apresentados na Figura 18.

Figura 18 – Mapas preditos de clorofila-a por meio de regressões

Observando na Figura 18 o mapa de clorofila-a predito para o mês de janeiro pelo NRAVI, é possível perceber que o mesmo conseguiu modelar bem as condições da represa, sendo que sua faixa de resultados ficou entre 0 e 14 µg/L, condizente com o observado em campo que foi de 3,16 a 13,81 µg/L. A distribuição espacial apresentada no mapa também se assemelha com a apresentada na Figura 12, com os maiores valores de concentração de clorofila-a localizados na zona de rio e em direção a zona de transição. Além disso, destaca-se que a presença de valores negativos na imagem predita para janeiro (destacados em preto) está relacionada a presença de macrófitas aquáticas naquela região, que possuem resposta espectral semelhante à da vegetação e diferente das respostas para água calibradas no modelo.

A imagem de maio, por apresentar pequenas nuvens e sombras destas em áreas da represa (ver Figura 14), retornou alguns valores para clorofila-a acima do esperado, que foram

marcados em preto no mapa. Além disso, destaca-se que o range de clorofila-a previsto para a represa em maio através de B12/B3 foi apenas de 4 a 5 $\mu\text{g/L}$, valores não condizentes com o observado em campo, que foi de 2,66 a 13,62 $\mu\text{g/L}$.

A imagem predita para julho, por sua vez, apesar de estar com o intervalo de valores mais de acordo com o estabelecido nas coletas de campo, que foi de 6,22 a 15,39 $\mu\text{g/L}$, não apresentou o comportamento espacial semelhante ao apresentado na Figura 12. Enquanto que no mapa de clorofila-a espacializada da Figura 12 os maiores valores encontram-se nas zonas de rio e lacustre e os valores intermediários estejam na zona de transição, o mapa predito através da variável B12/B3 apresenta os menores valores concentrados na região entre a zona de transição e a lacustre, não indicando a distinção clara entre as três zonas que aparece no mapa original.

Estes apontamentos a respeito da inconsistência do mapa de maio e parcial do mapa de julho servem de indicativo para que o modelo apresentado seja melhor estudado, pois poderia estar apresentando resultados significativos de ajuste apenas para o conjunto Maio/Julho reunidos, não representando adequadamente cada mês separado pelo mesmo modelo.

Assim como para a clorofila-a, a Tabela 10 apresenta os resultados obtidos nas calibrações e validações dos modelos de regressão para SST que obtiveram coeficiente de determinação (R^2) igual ou superior a 0,50. Todos os modelos ajustados que tiveram R^2 superior a 0,30 encontram-se no Apêndice C.

Tabela 10 – Resultados das análises de regressão para SST

Tratamento	Conjunto	Variável	Ajuste	Calibração			Validação		
				N	R^2	RMSE	n	R^2	RMSE
Nenhum	Janeiro	NDWI	Quadrático	23	0,53	0,93	6	0,70	1,24
		B5/B3	Quadrático		0,58	0,88		0,60	1,02
		B6/B3	Quadrático		0,60	0,86		0,51	1,30
		B8/B3	Quadrático		0,53	0,93		0,69	1,26

Fonte: Elaborada pela autora.

Observando os resultados expostos na Tabela 10, percebe-se que apenas modelos com o conjunto de dados referente a coleta do mês de janeiro possuíram ajustes com R^2 superior a 0,50, tanto na etapa de calibração dos modelos quanto em suas validações. Os valores de R^2 variaram de 0,53 a 0,60 na calibração ($n=23$) e de 0,51 a 0,70 nas validações ($n=6$), já os

resultados da RMSE foram de 0,86 a 0,93 mg/L na calibração e de 1,02 a 1,30 mg/L na validação.

As variáveis que melhor se correlacionaram com SST foram o NDWI, B5/B3, B6/B3 e B8/B3, sendo as quatro representativas de uma sensibilidade do COA com a relação entre as bandas espectrais do NIR (B5, B6 e B8) e do verde (B3). Observando na Figura 15 o comportamento espectral médio da imagem de janeiro, nota-se que realmente estas regiões do espectro possuem características distintas, com as maiores reflectâncias no verde e as menores no NIR.

Song et al. (2012) também alcançaram os melhores resultados nas análises de regressão com SST para NIR/verde utilizando imagens do satélite indiano IRS-P6 (*Indian Remote Sensing Satellite*). Porém, enquanto neste trabalho o R^2 foi de 0,58 e 0,60 na calibração e validação, respectivamente, destaca-se que os modelos gerados pelos autores citados apresentaram desempenho bem superior, com valor de R^2 igual a 0,94. Uma possível justificativa para esta diferença na performance das regressões pode estar na concentração de sólidos suspensos de ambos, pois enquanto Song et al. (2012) obtiveram concentrações de até 90 mg/L, com uma média de 52 mg/L, na Represa do Lobo os maiores valores foram próximos a 7 mg/L.

Já a respeito da relação entre SST e NDWI, Mohanty, Pal e Mishra (2017) e Veronez et al. (2018) também apontaram correlações significativas entre estes parâmetros, ambos com valores para R^2 de 0,77. Embora os resultados dos autores sejam condizentes com o obtido para a Represa do Lobo onde o R^2 foi 0,53 na calibração e 0,70 na validação, cabe ressaltar que as condições dos corpos d'água avaliados nos dois estudos são distintas em relação a represa. Mohanty, Pal e Mishra (2017) avaliaram um lago costeiro onde a concentração de SST era elevadíssima, superando 800 mg/L, e Veronez et al. (2018) não, pois o range de SST reportado foi de 9 a 20mg/L, sendo ainda superior ao presente trabalho.

Estes resultados apontam, de forma superficial, que o índice NDWI, além de suas aplicações usuais para realçar corpos d'água na superfície terrestre, também pode ser considerado para estimar parâmetros de qualidade da água, como sólidos suspensos, em certos ambientes. Além disso, de acordo com o reportado na bibliografia consultada, o NDWI apresenta relação com SST em diferentes concentrações, o que pode ser uma vantagem considerando o monitoramento de sistemas aquáticos dinâmicos e em constante modificação devido a degradação ambiental.

Como forma de observar melhor a capacidade de predição de SST na represa a partir das regressões apresentadas na Tabela 10, a Figura 19 apresenta os gráficos entre todos os dados de SST observados em campo e seus respectivos valores preditos pelas regressões considerando como variáveis explicativas B5/B3 e NDWI. Destaca-se que tendo em vista que foram utilizados para a construção deste gráfico os conjuntos de calibração e validação reunidos, os valores de R^2 diferem dos já apresentados na Tabela 10.

Figura 19 – Gráfico de SST observado e predito por regressões

Observa-se na Figura 19 que embora o ajuste linear entre o SST predito e o observado, que deveriam ficar o mais próximo de 1 possível, tenha retornado valores de R^2 de 0,59 para B5/B3 e de 0,52 para NDWI, os valores de RMSE são consideravelmente pequenos, de 0,91mg/L para B5/B3 e 1,00mg/L, se compararmos ao impacto que esta variação nos resultados preditos poderia causar em possíveis programas de monitoramento de SST, por exemplo.

Embora os resultados das análises de regressões para SST e a coleta de janeiro apresentados na Tabela 10 e demonstrados na Figura 19 tenham sido estatisticamente significativos ($p\text{-valor} < 0,001$), pelo fato de que apenas uma das três coletas deste trabalho obteve resultados positivos, optou-se por considerar este método não satisfatório de prever sólidos suspensos na Represa do Lobo no período estudado. A complexidade óptica ou ainda as baixas concentrações de SST deste ambiente podem ser motivos pelo qual houve maior dificuldade em ajustar modelos de regressão usuais lineares ou não-lineares para prever sólidos suspensos nas condições presentes na Represa do Lobo.

Considerando o exposto e entendendo que o objetivo do trabalho seria propor uma metodologia que fosse aplicável em todos os dados coletados e não apenas em parte deles, não foram gerados os mapas preditos de SST para janeiro considerando as equações resultantes dos melhores ajustes encontrados.

Os resultados apresentados nesta seção indicam que, embora métodos de regressão sejam amplamente utilizados em estudos de sensoriamento da água e retornem bons resultados para diversas aplicações, como foi o caso da predição de clorofila-a deste estudo, em alguns casos eles também podem não ser adequados para capturar as relações lineares e/ou não-lineares entre os compostos de interesse e as respostas espectrais da água recebidas pelo satélite, como o ocorrido com a modelagem de SST.

Neste sentido, as redes neurais possuem a capacidade de modelar relações mais complexas, pois estabelecem pesos diferentes para cada entrada na rede e, assim, tiram o máximo proveito das características dos COAs de interesse incluídas nas diferentes bandas espectrais (KONG et al., 2018). No tópico a seguir serão apresentados os resultados obtidos na utilização de RNA para predição de clorofila-a e SST.

4.3.2 Redes Neurais Artificiais

Durante a etapa de testes para obtenção das melhores configurações de RNA aplicáveis ao objetivo deste estudo diversas combinações entre conjuntos de entrada, topologias de RNA e ciclos de treinamento foram exploradas para cada parâmetro de saída (clorofila-a ou SST). Embora diversos destes tenham obtido ótimos resultados na etapa de treinamento (com valores de R^2 maiores que 0,9, por exemplo), foram considerados somente aqueles que também apresentaram resultados satisfatórios na etapa de validação ($R^2 > 0,5$), onde a rede neural foi testada com dados diferentes aos que ela foi treinada. Só assim seria possível afirmar que além de aprender com os dados do treinamento, a RNA adquiriu a capacidade de extrapolar seu aprendizado para outros conjuntos de dados.

A Tabela 11 apresenta os melhores resultados das RNAs testadas neste trabalho para a predição de clorofila-a, considerando seu desempenho tanto no treinamento quanto na validação dos modelos. Encontram-se no Apêndice D os demais dados de treinamento e validação das redes neurais. Destaca-se que foram estabelecidos números para cada rede, como JaC1, TC1 ou MS3, apenas para facilitar a discussão dos resultados e comparação das redes entre si.

Tabela 11 – Resultados das RNAs para clorofila-a

Conjunto	Nº	Entrada da rede ¹	Topologia ²	Função de ativação ³	Ciclos	Treinamento		Validação	
						R ²	RMSE	R ²	RMSE
Janeiro	JaC1	C4	4-7-1	tang./tang.	500	0,79	1,57	0,84	1,59
	JaC2	C1	6-13-1	tang./tang.	500	0,86	1,10	0,75	2,96
Maio	MaC2	C4	4-7-1	tang./lin.	300	0,93	0,64	0,52	3,93
	MaC3	C1	6-15-1	tang./lin.	200	0,90	0,82	0,83	2,52
Julho	JuC1	C4	4-5-1	tang./tang.	400	0,97	0,34	0,60	2,10
	JuC3	C1	6-10-1	tang./tang.	300	0,92	0,58	0,51	1,97
Todos	TC3	C3 + ut	12-7-1	tang./tang.	200	0,65	1,65	0,75	1,51
	TC4	C3 + ut	12-20-1	tang./lin.	300	0,64	1,67	0,78	1,27

¹ C1: Conjunto 1; “+ ut”: variáveis umidade (u) e temperatura (t) foram incluídas como entrada da rede. ² Entrada-nº de neurônios na cama oculta-saída. ³ Camada oculta/camada de saída.

Fonte: Elaborada pela autora.

Da mesma forma, na Tabela 12 são apresentados os melhores resultados para as RNAs processadas considerando como saída da rede o parâmetro sólidos suspensos totais. Mais resultados de treinamento e validações de outras topologias podem ser encontrados no Apêndice D.

Tabela 12 – Resultados das RNAs para SST

Conjunto	Nº	Entrada da rede ¹	Topologia ²	Função de ativação ³	Ciclos	Treinamento		Validação	
						R ²	RMSE	R ²	RMSE
Janeiro	JaS1	C4	4-5-1	tang./tang.	500	0,96	0,31	0,86	1,02
	JaS4	C1	6-10-1	tang./tang.	500	0,88	0,53	0,81	0,49
Maio	MaS1	C4	4-7-1	tang./lin.	500	0,90	0,21	0,71	0,84
	MaS2	C1	6-10-1	tang./lin.	500	0,91	0,21	0,70	0,80
Julho	JuS1	C4	4-5-1	tang./lin.	200	0,98	0,16	0,73	2,29
	JuS3	C1	6-10-1	tang./lin.	300	0,93	0,37	0,75	1,37
Todos	TS3	C3 + ut	12-7-1	tang./lin.	200	0,64	0,75	0,68	0,71
	TS4	C3 + ut	12-15-1	sigm./lin.	400	0,77	0,60	0,62	0,82

¹ C1: Conjunto 1; “+ ut”: variáveis umidade (u) e temperatura (t) foram incluídas como entrada da rede. ² Entrada-nº de neurônios na cama oculta-saída. ³ Camada oculta/camada de saída.

Fonte: Elaborada pela autora.

De forma geral, avaliando os resultados apresentados nas Tabelas 11 e 12 é possível perceber que RNAs geradas por período/coleta obtiveram melhores desempenhos do que aquelas com todos os dados reunidos. Isso já era esperando, tendo em vista a maior dificuldade em modelar dados multi-temporais (coletados em épocas diferentes), ainda mais considerando que a imagem Sentinel de janeiro apresentou comportamento espectral bastante distinto das demais.

Cabe ressaltar, ainda, que a única maneira possível de se obter resultados satisfatórios considerando o conjunto de dados com as três coletas reunidas foi inserindo como entrada nas redes também os parâmetros umidade e temperatura média do mês da coleta (parâmetro “+ ut” apresentado nas tabelas), além das entradas provenientes das imagens do satélite. Desta forma, entende-se que a rede adquiriu a capacidade de reconhecer os padrões de variação sazonal juntamente com as variáveis espectrais de entrada para predizer o COA de interesse. Embora não tenham sido encontrados na literatura estudos que incluíssem variáveis ambientais e/ou climáticas na entrada de dados da rede neural juntamente com os dados espectrais, neste trabalho essa questão foi o fator determinante para a obtenção dos resultados apresentados.

Outro aspecto a ser destacado é que dependendo se a modelagem por RNA foi separada por coleta ou com todas reunidas, os conjuntos de entrada da rede que tiveram melhores resultados também se alteraram. Como observa-se na Tabelas 11 e 12, para análises por coleta os conjuntos 1 (C1) e 4 (C4) obtiveram os melhores resultados para todas as coletas, tanto para clorofila-a quanto para SST, sendo que C1 possuía 6 entradas (B2 a B7) enquanto o C4 os 4 índices espectrais adotados neste estudo (NDVI, NDWI, NDCI e NRAVI). Já para as análises com o conjunto completo dos dados, embora C4 também tenha retornado alguns resultados satisfatórios (ver Apêndice D), o melhor conjunto de entrada foi C3, que considera todas as 10 bandas de reflectância de superfície disponíveis e processadas do Sentinel-2 (B2 a B8, B8a, B11 e B12).

Chen et al. (2017) também utilizaram as bandas 2 a 7 do satélite Sentinel-2 como entrada em uma RNA do tipo *backpropagation* para estimar clorofila-a e obtiveram bons resultados. Neste trabalho optou-se por fazer esta separação entre C1 (B2 a B7) e C2 (B2 a B8a) justamente para avaliar se existia diferença na modelagem da rede se bandas com comprimentos de onda maiores que 800nm (B8 e B8a) estivessem ausentes. Os resultados indicaram que quando C2 foi considerado como entrada os modelos não se ajustaram bem, diferentemente de C1, que foi o conjunto que apresentou melhores desempenhos.

A respeito dos melhores resultados para as análises das coletas reunidas terem se dado com C3, tem-se que, assim como mencionado no tópico anterior, a utilização de bandas na região do SWIR aparentemente melhorou a capacidade da rede em prever dados de clorofila-a e SST com imagens multi-temporais, aliada a presença das duas entradas com informações climáticas (umidade e temperatura). Din et al. (2017) também decidiram incluir as bandas de infravermelho de ondas curtas do satélite Landsat 8 OLI (SWIR-1 e SWIR-2) como entradas na RNA para prever parâmetros de qualidade da água após realizarem análises estatísticas de correlação entre as bandas e os parâmetros de interesse de forma a escolher quais bandas seriam ideais para serem consideradas como entrada da rede.

Porém, cabe ressaltar que esta utilização não é usual em artigos sobre RNA para prever parâmetros de qualidade de água, visto que em sua grande maioria apenas regiões visíveis e infravermelhas próximas são exploradas (SONG et al., 2012; WU et al., 2014; MORIDNEJAD et al., 2015; GUO et al., 2016; AMANOLLAHY, KABOODVANDPOUR, MAJIDI, 2017; CHEN et al., 2017; KONG et al., 2018; PETERSON et al., 2018).

Além disso, destaca-se que, embora também não sejam usuais, os resultados das RNA geradas considerando como entrada os índices espectrais são promissores, tendo em vista que estes índices possuem a finalidade de representar justamente feições características dos COAs através de relações entre as bandas do NIR com vermelho (NDVI e NDCI), do NIR com verde (NDWI) e também do verde com o vermelho (NRAVI). Ademais, como todos os índices utilizados já são normalizados pelas suas respectivas equações, isso reduziria a etapa necessária de normalização dos dados para entrada na RNA.

Feitos estes apontamentos genéricos sobre os dados apresentados nas Tabelas 11 e 12, principalmente no que diz respeito à escolha das entradas das RNAs, como forma de se estabelecer o melhor método para predição de sólidos suspensos foram construídos os gráficos com as relações entre a clorofila-a e o SST observados em campo e seus respectivos valores preditos pelas RNAs treinadas e validadas. A Figura 20 apresenta estes gráficos dos modelos gerados por coleta para a clorofila-a, enquanto que a Figura 21 ilustra o gráfico para os modelos de SST.

Assim como apontado no tópico anterior, os resultados de R^2 e RMSE que constam nos gráficos referem-se ao conjunto os dados utilizados no treinamento e na validação das redes reunidos e, por isso, não coincidem com os apresentados nas Tabelas 11 e 12. Destaca-se que os pontos abertos representam os dados utilizados no treinamento da RNA e os pontos fechados aqueles usados na validação do modelo.

Figura 20 - Gráfico de clorofila-a observada e predita por RNA, separados por coleta

Fonte: Elaborada pela autora.

A partir dos gráficos apresentados na Figura 20, conclui-se que os melhores modelos ajustados para clorofila-a foram JaC1 para janeiro, com R^2 de 0,78 e RMSE de 1,38 $\mu\text{g/L}$. Esta rede possui as seguintes características: conjunto de entrada C4 (índices espectrais), 7 neurônios na única camada oculta, utilizando como funções de ativação as funções tangentes, tanto na camada oculta quanto na de saída e 500 ciclos de treinamento tendo sido realizados. Para maio a melhor RNA para prever clorofila-a foi a MaC3, com valores de 0,71 para o R^2 e 2,39 $\mu\text{g/L}$ para o RMSE. Esta RNA possui 6 entradas (Conjunto C1), 15 neurônios na camada oculta, sendo suas funções de ativação tangente e linear, para as camadas ocultas e de saída, respectivamente. Já para julho, a melhor RNA foi a JuC1, retornando R^2

de 0,79 e 1,0 $\mu\text{g/L}$ como RMSE. Novamente esta rede tem como entrada o C4 com os índices espectrais, 5 neurônios na camada oculta e funções de transferência tangente hiperbólica para a camada oculta e de saída, considerando 400 ciclos de treinamento.

Figura 21 - Gráfico de SST observado e predito por RNA, separados por coleta

Fonte: Elaborada pela autora.

Considerando os resultados para as análises de RNA para SST apresentados na Figura 21, conclui-se que os melhores modelos ajustados para clorofila-a foram JaS1 para janeiro, com R^2 de 0,89 e RMSE de 0,54 mg/L. Esta rede possui as seguintes características: conjunto de entrada C4 (índices

espectrais), 5 neurônios na camada oculta, utilizando como funções de ativação as funções tangentes, tanto na camada oculta quanto na de saída e 500 ciclos de treinamento tendo sido realizados. Para maio a melhor RNA para prever SST foi a MaS2, com valores de 0,74 para o R^2 e 0,41 mg/L para o RMSE. Esta RNA possui 6 entradas (Conjunto C1), 10 neurônios na camada oculta, sendo suas funções de ativação tangente e linear, para as camadas ocultas e de saída, respectivamente. Já para julho, a melhor RNA foi a JuS1, retornando R^2 de 0,71 e 1,05 mg/L como RMSE. Novamente esta rede tem como entrada o C4 com os índices espectrais, 5 neurônios na camada oculta e funções de transferência tangente para a camada oculta e linear para a de saída, considerando 200 ciclos de treinamento.

Já na Figura 22 são demonstrados os mesmos gráficos para RNAs nas figuras acima, mas com as redes processadas com todos os dados reunidos. São incluídos na figura os resultados para clorofila-a (TC3 e TC4) e para SST (TS3 e TS4).

Figura 22 - Gráfico de clorofila-a e SST observado e predito por RNA, analisados em conjunto

Fonte: Elaborada pela autora.

Os melhores resultados modelados por RNA para todos os dados das três coletas foram para a clorofila-a o TC3, que apresentou R^2 de 0,65 e RMSE 1,59 $\mu\text{g/L}$, sendo que a mesma possui 12 entradas na rede (C3 com 10 bandas do Sentinel-2 e mais umidade e temperatura), 7 neurônios na camada oculta e funções de ativação tangentes para camada oculta e de saída.

Destaca-se que a escolha desta rede em detrimento da TC4, que apresentou resultados similares, considerou que TC3 possui menos neurônios na camada oculta em comparação a TC4 que possuía 20 neurônios e, assim, optou-se pela RNA cujo menor número de interações fosse necessário, para facilitar o processo de modelagem futura.

Já para a RNA treinada para prever SST, a que obteve melhor desempenho foi a TS4, que apresentou R^2 de 0,73 e 0,65 mg/L de RMSE. As características da rede são, assim como a TC3, 12 entradas na rede (C3 + ut), 15 neurônios na única camada oculta e função de ativação sigmoidal para a camada oculta e linear para a camada de saída, considerando 400 ciclos de treinamento.

Neste sentido, são propostas diversas opções de redes neurais para predição de clorofila-a e SST que apresentaram ótimo de desempenho em suas modelagens, tanto em suas análises separadamente por coleta (para janeiro JaC1 e JaS1, para maio MaC3 e MaS2 e para julho JuC1 e JuS1) quanto em conjunto (TC3 e TS4). Os valores de R^2 de todos os modelos citados superaram 0,65 quando dados de treinamento e validação foram reunidos, resultados que são promissores considerando o objetivo final destes modelos que seria a estimativa da qualidade da água via os parâmetros clorofila-a e sólidos suspensos a partir de imagens de satélite. Tem-se que os resultados do RMSE variaram de 1,0 a 2,39 $\mu\text{g/L}$ para clorofila-a e de 0,41 a 1,05 mg/L para SST, sendo estes considerados pequenos na ordem de grandeza destes parâmetros se comparados a vantagem da aplicabilidade desta metodologia de monitoramento de corpos d'água em detrimento da metodologia convencional.

Por fim, considerando a significância dos resultados obtidos, aplicou-se os modelos de RNA adotados como os melhores sobre as imagens Sentinel processadas de cada coleta para toda a área da Represa do Lobo (na verdade, sobre os valores de reflectância de cada pixel das imagens) e, assim, foram gerados mapas preditos de clorofila-a e SST para os respectivos meses da coleta. Desta forma, o resultado das modelagens realizadas passa de pontual para espacial, aspecto este de grande interesse para o monitoramento da qualidade da água.

Sendo assim, a Figura 23 apresenta os mapas preditos de clorofila-a para janeiro, maio e julho aplicando os respectivos modelos treinados unicamente com os meses de coleta e, também, como forma comparativa os mapas gerados pela RNA conjunta.

Figura 23 – Mapas preditos de clorofila-a por RNA

Fonte: Elaborada pela autora.

Analisando na Figura 23 os intervalos dos valores preditos para cada mapa gerado, tem-se que para os dois mapas de janeiro os valores foram condizentes com o observado em campo que foi de 3,16 a 13,81 $\mu\text{g/L}$. Em relação a distribuição espacial da clorofila-a, tem-se que para ambos mapas os maiores valores se concentraram na zona de rio, sendo condizente com o já demonstrado na Figura 12. Destaca-se que a imagem TC3 permite uma melhor observação da espacialidade deste parâmetro.

Já nos mapas preditos de maio a mesma situação não ocorreu, pois a imagem MaC3, modelada apenas com o conjunto de dados da coleta de maio, apresentou diversos valores negativos em algumas regiões, isto pode ter ocorrido pela presença de nuvens nestas imagens. A imagem de maio TC3, cuja rede foi treinada com os dados de todas as coletas e ainda considerando variáveis ambientais como entradas da rede junto com os dados espectrais, apresentou valores mais condizentes com o observado em campo, que foi 2,66 a 13,62 $\mu\text{g/L}$. Mesmo assim esta imagem apresenta algumas regiões com valores mais altos (próximos a 15 $\mu\text{g/L}$) onde existem pequenas nuvens, o que pode indicar que nestas regiões o valor de clorofila-a não condiz com a realidade, pois os valores dos pixels provavelmente sofreram interferências e não representam, então, valores de reflectância de água. A distribuição espacial da clorofila-a nos mapas preditos de maio podem ser melhor observadas em TC3, onde os maiores valores encontram-se na zona de rio e os menores próximos a barragem, na zona lacustre. Destaca-se que visualmente esta espacialização não parece se assemelhar aos mapas especializados para clorofila-a apresentados na Figura 12.

Nos mapas preditos para julho o que melhor representou os valores coletados em campo (de 6,22 a 15,39 $\mu\text{g/L}$) foi o JuC1, sendo que o TC3 indicou algumas áreas da represa com menores concentrações do que as obtidas nos pontos amostrais, o que também poderia ocorrer considerando que esta análise é espacial e não pontual. Em relação a distribuição espacial deste parâmetro em comparação com o exposto na Figura 12, nota-se que JuC1 e TC3 apresentam características distintas, pois enquanto JuC1 indica em sua grande maioria valores baixos de clorofila-a, apenas com uma porção central da represa com valores mais baixos, TC3 apresenta concentrações mais intermediárias ao seu range.

De forma geral, embora cada RNA tenha influenciado de alguma forma na saída dos dados utilizados para gerar os mapas, as imagens TC3 aparentam ter tido melhores resultados em relação as redes geradas especificamente para cada coleta.

Da mesma forma que foi realizado para a clorofila-a, na Figura 24 são apresentados os mapas preditos de SST para a Represa do Lobo.

Figura 24 – Mapas preditos de SST por RNA

Fonte: Elaborada pela autora.

Analisando a Figura 24, tem-se que em relação aos mapas preditos de SST para janeiro, maio e julho percebe-se só por observar os intervalos de predição gerados pelos mapas que os resultados não foram tão satisfatórios quanto os de clorofila-a tendo em vista que grande parte dos mapas apresentaram valores mínimos negativos.

Destaca-se que apenas o mapa de janeiro JaS1 apresentou valores próximos ao observado em campo, que foi de 0,80 a 5,67 mg/L. Todos os outros mapas preditos apresentaram, em

diferentes intensidades, valores negativos. A imagem de janeiro TS4 embora tenha apresentada uma destruição espacial semelhante a demonstrada na Figura 13, seus valores não condizem com o esperado. As outras quatro imagens, maio MaS2 e TS4 e julho JuS1 e TS4, aparentemente não estão condizentes nem com os intervalos observados em campo para estes meses, que foram de 2,17 a 5,0mg/L e 1,38 a 7,40 mg/L, nem com sua distribuição espacial, o que indica a maior complexidade em modelar este parâmetro na Represa do Lobo.

Os resultados apresentados indicam a maior dificuldade em se modelar o parâmetro sólidos suspensos na área de estudo, o que já havia sido indicado nos resultados das análises de regressão. As baixas concentrações de SST poderiam ser uma possível justificativa para tal resultado, ou ainda a complexidade óptica do ambiente, onde a clorofila-a apresentou melhores relações com o comportamento espectral extraído das imagens e pode ter camuflado o impacto dos SST. Neste sentido, há a necessidade de continuidade da pesquisa para que essa questão possa vir a ser sanada.

Por fim, cabe ressaltar que devem ser realizadas mais pesquisas para poder compreender como estas RNAs apresentadas, tanto por coleta quanto coletivas, se comportariam com imagens de outros períodos em que elas não foram treinadas, como outros meses com condições diferentes e/ou outros anos.

5 CONCLUSÕES

O uso de sensoriamento remoto no mapeamento da qualidade da água mostra-se uma ferramenta necessária, pois preenche as lacunas deixadas no monitoramento in situ usual, como insuficiência de dados e alto consumo de tempo e custo.

Os resultados de qualidade da água para as três coletas realizadas (janeiro, maio e julho) indicam, embora de forma preliminar, que as baixas concentrações de clorofila-a e sólidos suspensos obtidos neste trabalho podem ser um indicativo de melhora da qualidade da água na Represa do Lobo nos últimos anos. Este ambiente passou por sérios problemas de eutrofização nos anos de 2014 e 2015, acarretados entre outros fatores pela crise hídrica no Estado de São Paulo.

A espacialização das concentrações de clorofila-a e SST para toda a área de estudo permitiu a análise do comportamento espacial destes dois parâmetros, sendo importante para que fossem confirmadas as diferenças entre as características das zonas de rio, de transição e lacustre da represa.

Os comportamentos espectrais extraídos das imagens Sentinel-2 para as coletas de janeiro, maio e julho não apresentaram feições características que possam ser relacionadas aos compostos opticamente ativos presentes nela, se assemelhando a resposta da água clara. As baixas concentrações de clorofila-a e SST obtidas em campo podem justificar esta conclusão.

A respeito da geração dos modelos de predição dos Compostos Opticamente Ativos (clorofila-a e SST), tem-se que, embora os métodos de regressão sejam amplamente utilizados em aplicações de sensoriamento remoto na qualidade da água, eles podem não ser adequados para capturar as relações lineares e/ou não-lineares de interesse em ambientes aquáticos complexos, o que se confirmou nos resultados deste trabalho. Ressalta-se, então, a aplicabilidade do uso de inteligência artificial através de redes neurais artificiais para atender a necessidade de modelagem de COAs em ambientes onde análises mais simplistas como modelos de regressão podem não ser suficientes, como apresentado neste estudo.

Assim, através da análise da resposta que o sensor MSI do satélite Sentinel-2 coletou nas regiões do visível ao infravermelho médio, foi possível modelar através da utilização de RNA a concentração de clorofila-a e gerar mapas que permitam seu monitoramento temporal e análise espacial na área de estudo. Os resultados para SST não foram satisfatórios devido a complexidade óptica do ambiente analisado, bem como as baixas concentrações de SST na represa.

Os modelos de RNA gerados neste trabalho apresentaram ótimo de desempenho para modelagem e predição da clorofila-a na Represa do Lobo, com valores de R^2 superiores a 0,65 e de RMSE inferiores a 2,5 $\mu\text{g/L}$, dependendo se a análise foi realizada separadamente por coleta (janeiro, maio e julho) ou com dados reunidos. Estes resultados foram considerados positivos considerando o objetivo final destes modelos e se comparados a vantagem da aplicabilidade desta metodologia de monitoramento de corpos d'água em detrimento da metodologia convencional.

Cabe ressaltar a importância da escolha das variáveis corretas para que a RNA tenha o seu melhor desempenho. Neste estudo a inserção de duas variáveis ambientais (umidade e temperatura), além das entradas provenientes das imagens do satélite, permitiu a modelagem de dados de coletas de campo realizadas em épocas distintas, fazendo com que a rede adquirisse a capacidade de reconhecer os padrões de variação sazonal juntamente com as variáveis espectrais de entrada para prever o COA de interesse. Além disso, destaca-se que a utilização de bandas na região do SWIR nestas aplicações deve ser melhor estudada, pois o indicativo que os resultados deste trabalho apontam é de que não só as mesmas são passíveis de se utilizar na predição de COAs como também talvez influenciam positivamente nos resultados quando imagens de mais de uma data são modeladas reunidas.

A integração de dados de sensoriamento remoto no mapeamento de corpos d'água com a aplicação de redes neurais na análise de dados é uma abordagem promissora para prever clorofila-a e sólidos suspensos, bem como suas variações temporais e espaciais. Este método de monitoramento dinâmico e espacial de parâmetros de qualidade da água deve beneficiar todas as partes envolvidas na gestão e controle de recursos hídricos, principalmente aqueles ligados à Represa do Lobo.

No entanto, embora os modelos apresentados possam prever as concentrações dos COAs em escala espacial e temporal, seus usos são limitados apenas à área de estudo onde a RNA foi treinada e validada. Para que a mesma possa ser extrapolada para outras regiões, possíveis adaptações em suas características devem ser necessárias e novo treinamento com dados do local deve ser realizado.

Por fim, enfatiza-se a necessidade de continuidade da pesquisa para que os modelos gerados possam ser aprimorados, bem como para que outros aspectos não explorados neste trabalho sejam considerados.

6 TRABALHOS FUTUROS

A continuidade da pesquisa desenvolvida neste trabalho apresenta-se de extrema importância, tendo em vista os inúmeros benefícios que este método proposto de integralização de sensoriamento remoto orbital com análises por redes neurais artificiais pode trazer para o monitoramento da qualidade da água da Represa do Lobo.

Sendo assim, propõe-se:

- Aplicar as RNAs geradas em imagens de outras datas para que possam ser utilizadas como ferramenta para possíveis estudos de séries temporais de clorofila-a e SST;
- Considerar as análises dos dados espectrais coletados através de regressões lineares múltiplas, de forma a confirmar se duas ou mais variáveis poderiam melhorar os resultados obtidos nas regressões deste trabalho;
- Avaliar a interferência de outros COAs, como a matéria orgânica, na resposta espectral da água da área de estudo e, conseqüentemente, o seu impacto na rede neural gerada;
- Considerando as distintas características das três zonas da represa (de rio, de transição e lacustre), analisar a aplicabilidade de modelos de predição de COAs separados para cada zona;
- Analisar diferentes algoritmos de correções atmosféricas para avaliar qual melhor corresponde a reflectância da água, tendo em vista que a maioria dos algoritmos disponíveis para essas funções foram desenvolvidos para superfície terrestre, podendo apresentar erros quando a resposta é água.

Por fim, destaca-se que, ao longo do desenvolvimento deste trabalho, um amplo banco de dados com imagens de satélite da Represa do Lobo foi construído, sendo que além de imagens Sentinel-2, foram obtidas imagens dos satélites Landsat 8 e CBERS-4. Desta forma, pretende-se explorar este banco de dados para que sejam realizadas análises comparativas entre as respostas destes satélites para a superfície da água, além de que possam ser avaliadas abordagens conjuntas destes sensores, pelo fato deles terem características semelhantes.

REFERÊNCIAS

- AMANOLLAHI, J.; KABOODVANDPOUR, S.; MAJIDI, H. Evaluating the accuracy of ANN and LR models to estimate the water quality in Zarivar International Wetland, Iran. **Nat Hazards**, vol. 85, p. 1511–1527, 2017.
- ANSPER, A.; ALIKAS, Kr. Retrieval of Chlorophyll a from Sentinel-2 MSI Data for the European Union Water Framework Directive Reporting Purposes. **Remote Sensing**, p. 1-26, 2019.
- APHA - American Public Health Association. **Standard methods for examination of water and wastewater**. 19^a ed., Washington, American Public Health Association, 1995. 1368 p.
- ARANTES, D. M.; MOCCELLIN, J.; CAMARGO, A. A. B.; KUWAJIMA, J. I.; MAUAD, F. F. Deposição de nutrientes em uma sub-bacia do Baixo Tietê (SP). In: **XIV World Water Congress**, 2011, Porto de Galinhas. Anais do XIV World Water Congress, 2011.
- ARGENTON, É.C. **Limnologia, balneabilidade e impactos ambientais: uma análise temporal e espacial na represa do Lobo (Broa), Itirapina/ Brotas - SP**. Dissertação (Mestrado em Ciências da Engenharia Ambiental) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2004.
- ARROIO JUNIOR, P. P. **Avaliação da produção e transporte de sedimentos na bacia hidrográfica do Rio Itaqueri, municípios de Itirapina e Brotas – SP**. Dissertação (Mestrado). Programa de Pós-Graduação em Ciências da Engenharia Ambiental - Escola de Engenharia de São Carlos da Universidade de São Paulo. São Carlos, 2013.
- AUGUSTO-SILVA, P. B. et al. Analysis of MERIS Reflectance Algorithms for Estimating Chlorophyll-a Concentration in a Brazilian Reservoir. **Remote Sensing**, vol. 6, p. 11689-11707, 2014.
- BABAN, Serwan M. J. Use of remote sensing and geographical information systems in developing lake management strategies. **Hydrobiologia**, v. 395, n. 3, p. 211-226, 1999.
- BARBOSA, C. C. F. **Sensoriamento Remoto da Dinâmica da Circulação da Água do Sistema Planície de Curuai/Rio Amazonas. 2005**. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005.
- BEN-DOR, E.; CHABRILLAT, S.; DEMATTÊ, J. A. M.; TAYLOR, G. R.; HILL, J.; WHITING, M. L.; SOMMER, S. Using imaging spectroscopy to study soil properties. **Remote Sensing of Environment**, vol. 113, p. 38-55, 2009.
- BRASIL. Ministério do Meio Ambiente, Conselho Nacional de Meio Ambiente - CONAMA. **Resolução nº 357, de 17 de março de 2005**. 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. Disponível em: <<http://www.mma.gov.br/port/conama/res/res05/res35705.pdf>>. Acesso em: 20 mai. 2017.

BRASIL. **Manual de controle da qualidade da água para técnicos que trabalham com ETAs**. Fundação Nacional de Saúde. Brasília: Ministério da Saúde, 2014. 116 p.

BREUNIG, F. M. et al. Dynamics of limnological parameters in reservoirs: A case study in South Brazil using remote sensing and meteorological data. **Science of the Total Environment**, vol. 574, p. 253–263, 2017.

BREZONIK, P. L. et al. Factors affecting the measurement of CDOM by remote sensing of optically complex inland waters. Article in press. **Remote Sensing of Environment**, 2014.

CALIJURI, M.C.; TUNDISI, J.G. Limnologia comparada das represas do Lobo (Broa) e Barra Bonita – Estado de São Paulo: Mecanismos de funcionamento e bases para o gerenciamento. **Rev. Brasil. Biol.**, 50(4): 893-913, 1990.

CAMPBELL, G.; PHINN, S. R.; DEKKER, A. G.; BRANDO, V. E. Remote sensing of water quality in an Australian tropical freshwater impoundment using matrix inversion and MERIS images. **Remote Sensing of Environment**, vol. 115, p. 2402–2414, 2011.

CÂNDIDO, A. K. A. A.; PARANHOS FILHO, A. C.; HAUPENTHAL, M. R.; SILVA, N. M.; CORREA, J. S.; RIBEIRO, M. L. Water quality and chlorophyll measurement through vegetation indices generated from orbital and suborbital images. **Water Air Soil Pollut**, 227:224, 2016.

CARVALHO, D.P. **Distribuição espacial e mudanças temporais da comunidade fitoplânctônica no Reservatório do Lobo (Itirapina – SP)**. Dissertação (Mestrado em Ciências da Engenharia Ambiental). Escola de Engenharia de São Carlos da Universidade de São Paulo. São Carlos, 2002.

CESTARI, A.C. **Estimativa da concentração média de clorofila na zona eufótica em função da concentração de clorofila na superfície d'água a partir de dados TM-Landsat**. Dissertação (Mestrado em Ciências da Engenharia Ambiental). Escola de Engenharia de São Carlos da Universidade de São Paulo. São Carlos, 1996.

CETESB - COMPANHIA AMBIENTAL DO ESTADO DE SÃO PAULO. **Guia Nacional de Coleta e Preservação de Amostras**. São Paulo, 2011. Disponível em: <<http://laboratorios.cetesb.sp.gov.br/wp-content/uploads/sites/47/2013/11/guia-nacional-coleta-2012.pdf>>. Acesso em: 20 mai. 2017.

CETESB - COMPANHIA AMBIENTAL DO ESTADO DE SÃO PAULO. **Qualidade das águas interiores no estado de São Paulo**. São Paulo, 2009. Disponível em: <<https://cetesb.sp.gov.br/aguas-interiores/publicacoes-e-relatorios/>>. Acesso em: 20 mai. 2017.

CETESB - COMPANHIA AMBIENTAL DO ESTADO DE SÃO PAULO. **Relatório de Qualidade das Águas Interiores do Estado de São Paulo – 2017**. São Paulo, 2018. <<http://cetesb.sp.gov.br/aguas-interiores/wp-content/uploads/sites/32/2013/11/variaveis.pdf>>. Acesso em: agosto 2018.

CHEN, C. J.; ZHU, W.; TIAN, Y. Q.; YU, Q.; ZHENG, Y.; HUANG, L. Remote estimation of colored dissolved organic matter and chlorophyll-a in Lake Huron using Sentinel-2 measurements. **J. Appl. Remote Sens.** 2017 11, 3, 036007

CHENG, et al. Estimation of Chlorophyll-a Concentration in Turbid Lake Using Spectral Smoothing and Derivative Analysis. **Int. J. Environ. Res. Public Health**, 2013, vol. 10, p. 2979-2994.

CLARKE, G.L.; EWING, G.C.; LORENZEN, C.J. Spectra of backscattered light from the sea obtained from aircraft as a measure of chlorophyll concentration. **Science**, 167, p. 1119-1121, 1970.

COELHO, L.; ROCHE, K. F.; PARANHOS FILHO, A. C.; LEMOS, V. B. Uso do sensor CBERS/CCD na avaliação do estado trófico do Reservatório Lago do Amor (Campo Grande, MS). **Revista Brasileira de Cartografia**, vol. 6, n.2, p. 221–232, 2011.

CRÓSTA, A. P. **Processamento digital de imagens de sensoriamento**. Campinas, SP: IG/UNICAMP, 1992. 170 p.

CRUZ, N. C.; GALO, M. L. B. T. Mapeamento das infestações por plantas aquáticas em reservatórios utilizando imagens multiescala e redes neurais artificiais. **RBC - Revista Brasileira de Cartografia**, Nº 57/02, 2005.

DALL'OLMO, G.; GITELSON, A.A. Effect of bio-optical parameter variability on the remote estimation of chlorophyll-a concentration in turbid productive waters: Experimental results. **Applied Optics**, vol. 44, n. 3, p. 412–422, 2005.

DEKKER, Arnold Graham. Detection of optical water quality parameters for eutrophic waters by high resolution remote sensing. **Vrije Universiteit**: Amsterdam, 1993.

DELELLO, D. **Composição e distribuição (espacial e temporal) de macrófitas aquáticas no Reservatório do Lobo (Broa), Itirapina/Brotas, SP**. Dissertação (Mestrado em Ciências da Engenharia Ambiental) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2008.

DIN, E.S.E.; ZHANG, Y.; SULIMAN, A. Mapping concentrations of surface water quality parameters using a novel remote sensing and artificial intelligence framework. **International Journal of Remote Sensing**, v.38, n.4, p.1023-1042, 2017.

DINIZ, V. **Avaliação da qualidade da água e do sedimento em diferentes compartimentos do reservatório do lobo (sp) com auxílio de testes ecotoxicológicos**. Monografia (Graduação em Engenharia Ambiental) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

DORNHOFFER, K.; OPPELT, N. Remote sensing for lake research and monitoring – Recent advances. **Ecological Indicators**, vol. 64, p. 105–122, 2016.

ESA - European Space Agency. **Sentinel-2A e AB**. Disponível em: <<https://earth.esa.int/web/sentinel/user-guides/sentinel-2-msi>>. Acesso em: nov. 2018.

ESTEVEES, F.A. **Fundamentos em Limnologia**. 2 ed. Rio de Janeiro: Interciência, 1998.

FENG, H. et al. Modeling spectral reflectance of optically complex waters using bio-optical measurements from Tokyo Bay. **Remote Sensing of Environment**, vol. 99, p. 232 – 243, 2005.

FERREIRA, M. S.; ENNES, R.; GALO, M. L. B. T. Estudo do comportamento espectral das águas da planície de inundação do Alto Rio Paraná baseada em técnicas de análise de dados hiperspectrais. **III Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação**, Recife - PE, julho de 2010. p. 001-009.

FLORENZANO, T. G. **Imagens de satélite para estudos ambientais**. São Paulo: Oficina de Textos, 2002. 97 p.

FREITAS, L. D. **Heterogeneidade espacial e temporal do zooplâncton em sistemas lóticos e lênticos da bacia hidrográfica do Lobo (Itirapina/Brotas/SP)**. Dissertação (Mestrado em Ciências da Engenharia Ambiental) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2012.

GAO, B.C. NDWI - A normalized difference water index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, vol. 58, p. 257-266, 1996.

GITELSON A. A. et al. Remote chlorophyll-a retrieval in turbid, productive estuaries: Chesapeake Bay case study. **Remote Sensing of Environment**, vol. 109, p. 464–472, 2007.

GHOLIZADEH, M.H.; MELESSE, A.M.; REDDI, L. A Comprehensive Review on Water Quality Parameters Estimation Using Remote Sensing Techniques. **Sensors**, vol. 16, 1298, 2016.

GONS, H.J.; AUER, M.T.; EFFLER, S.W. MERIS satellite chlorophyll mapping of oligotrophic and eutrophic waters in the Laurentian Great Lakes. **Remote Sensing of Environment**, vol. 112, p. 4098–4106, 2008.

GOODIN D. G. et al. Analysis of Suspended Solids in Water Using Remotely Sensed High Resolution Derivative Spectra. **Photogrammetric Engineering & Remote Sensing**, vol. 59, nº 4, p. 505-510, 1993.

GUIMARÃES, T.T.; VERONEZ, M.R.; KOSTE, E.C.; GONZAGA JR., L; BORDIN, F.; INOCENCIO, L.C.; LAROCCA, A.P.C.; OLIVEIRA, M.Z.; VITTI, D.C.; MAUAD, F.F. An Alternative Method of Spatial Autocorrelation for Chlorophyll Detection in Water Bodies Using Remote Sensing. **Sustainability**, v.9, n.416, p.1-13, 2017.

GUO, Q. et al. Study on Retrieval of Chlorophyll-a Concentration Based on Landsat OLI Imagery in the Haihe River, China. **Sustainability**, vol 8 (758), 2016.

HA et al. 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**. No prelo, 2017.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: Uma Perspectiva em Recursos Terrestres**. Tradução José Carlos Neves Epiphany (coordenador) et. al. São José dos Campos: Parêntese, 2011. 598 p.

KIRK, John T.O. **Light and Photosynthesis in Aquatic Ecosystems**. 3. ed. Cambridge University Press: Cambridge, UK, 2011.

KNAEPS, E.; RUDDICK, K.G.; DOXARAN, D.; DOGLIOTTI, A.I.; NECHAD, B.; RAYMAEKERS, D.; STERCKX, S. A SWIR based algorithm to retrieve total suspended matter in extremely turbid waters. **Remote Sensing of Environment**, p. 66-79, 2015.

KONG, J.; SHAN, Z.; CHEN, Y.; YANG, J.; HU, Y.; WANG, L. Assessment of remote-sensing retrieval models for suspended sediment concentration in the Gulf of Bohai. **Int. J. Remote Sens.** 2018, 0, 1-19

KUDELA, R. M.; PALACIOS, S. L.; AUSTERBERRY, D. C.; ACCORSI, E. K.; GUILD, L. S.; TORRES-PEREZ, J. Application of hyperspectral remote sensing to cyanobacterial blooms in inland waters. **Remote Sensing of Environment**, vol. 167, 196–205, 2015.

KUHN, C.; VALERIO, A.; WARD, N.; LOKEN, L.; SAWAKUCHI, H.; KAMPEL, M.; RICHEY, J.; STADLER, P.; CRAWFORD, J.; STRIEGL, R.; VERMOTE, E.; PAHLEVAN, N.; BUTMAN, D. Performance of Landsat-8 and Sentinel-2 surface reflectance products for river remote sensing retrievals of chlorophyll-a and turbidity. **Remote Sensing of Environment**, vol.224, p.104-118, 2019.

LANE, R.R.; JR, D.W.J.; MARX, B.D.; REYES, E.; HYFIELD, E.; DAY, J.N. The effects of riverine discharge on temperature, salinity, suspended sediment and chlorophyll a in Mississippi delta estuary measured using a flow-thorough system. **Estuarine Coastal and Shelf Science**, p.145-154, 2007.

LE, C.; HU, C.; CANNIZZARO, J.; DUAN, H.; Long-term distribution patterns of remotely sensed water quality parameters in Chesapeake Bay. **Estuarine Coastal and Shelf Science**, p.93-103, 2013.

LE C. et al. A four-band semi-analytical model for estimating chlorophyll a in highly turbid lakes: The case of Taihu Lake, China. **Remote Sensing of Environment**, vol. 113, p. 1175–1182, 2009.

LEITE, M.E.; LEITE, M.R.; CLEMENTE, C.M.S. O uso do solo e o conflito por água no alto rio Riachão – norte de minas gerais: uma análise Auxiliada pelas geotecnologias. **Revista Geográfica Acadêmica**, vol. 4, nº 1, p. 46 – 55, 2010.

LISSNER, J. B; GUASSELLI, L. A. Variação do Índice de Vegetação por Viferença Vormalizada na Lagoa Itapeva, Litoral Norte do Rio Grande do Sul, Brasil, a partir de análise de séries temporais. **Soc. & Nat.**, Uberlândia, 25 (2): 427-440, mai/ago/2013.

LIU, W.T.H. **Aplicações de sensoriamento remoto**. Campo Grande: Ed. Uniderp, 2007.

LOBO, F. L. **Biblioteca espectral: Determinação de espectros de referência para a classificação de tipos de água das áreas alagáveis da Amazônia**. 2009. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2009.

LOBO, F.L.; COSTA, M.P.F.; NOVO, E.M.L.M. Time-series analysis of Landsat-MSS/TM/OLI images over Amazonian waters impacted by gold mining activities. **Remote Sensing of Environment**, vol. 157, p. 170–184, 2015.

LONDE, L. de R. **Comportamento espectral do fitoplâncton de um reservatório brasileiro eutrofizado – Ibitinga (SP)**. 2008. Tese (Doutorado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2008.

LOPES, F.B. et al. Simulation of spectral bands of the MERIS sensor to estimate chlorophyll-a concentrations in a reservoir of the semi-arid region. **Revista Agro@mbiente On-line**, v. 10(2), p. 96 - 106, 2016

MACEDO, C. R.; GALO, M. L. B. T. Utilização de dados e técnicas de sensoriamento remoto no monitoramento da infestação por plantas aquáticas em reservatório de hidrelétrica. **Periódico Eletrônico Fórum Ambiental da Alta Paulista**, v. 7(2), 2011.

MANTOVANI, J. E.; NOVO, E. M.L.M. Comportamento espectral da matéria orgânica dissolvida. **Anais... VIII Simpósio Brasileiro de Sensoriamento Remoto**, Salvador, Brasil, 14-19 abril 1996, INPE, p. 917-923.

MARAFÃO, G.A. **Estudo in situ da fixação biológica de nitrogênio pelo fitoplâncton em reservatórios subtropicais (SP)**. Dissertação (Mestrado em Ciências da Engenharia Hidráulica e Saneamento) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

MASOCHA, M. et al. Testing utility of Landsat 8 for remote assessment of water quality in two subtropical African reservoirs with contrasting trophic states. **Geocarto International**, 2017.

McFEETERS, S.K. The use of normalized difference water index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, vol. 17, p. 1425-1432, 1996.

MEDEIROS, G. R. **Desenvolvimento e distribuição de espécies de macrófitas aquáticas em áreas alagadas da Represa do Lobo-Broa (UHE Carlos Botelho) em função do estado trófico**. Dissertação (Mestrado em Ecologia e Recursos Naturais) – Centro de Ciências Biológicas e da Saúde, Universidade Federal de São Paulo, São Carlos, 2011. Disponível em: <http://www.btd.ufscar.br/htdocs/tedeSimplificado/tde_busca/arquivo.php?codArquivo=4952>.

MENESES, P. R. **Princípios de sensoriamento remoto**. In: MENESES, P. R.; ALMEIDA, T. (Org.). Introdução ao processamento de imagens de sensoriamento remoto. Brasília: UNB/CNPq, 2012. p. 1-33.

MILTON, E.J., et al. Progress in field spectroscopy. **Remote Sensing of Environment**, vol. 113: S92-S109, 2009.

MISHRA, S.; MISHRA, D. R. Normalized difference chlorophyll index: A novel model for remote estimation of chlorophyll-a concentration in turbid productive Waters. **Remote Sensing of Environment**, vol. 117, p. 394–406, 2012.

MOHANTY, P.K.; PAL, S.R.; K.P. Monitoring Ecological Conditions of a Coastal Lagoon using IRS Data: A Case Study in Chilka, East Coast of India. **Journal of Coastal Resear**, p.459-469, 2015.

MONTANHER, O.C; BARBOSA, C.C.F.; NOVO, E.M.L.M. Integração de dados TM/ Landsat e medidas in situ para estimativa de sedimentos em suspensão em rios amazônicos: um estudo de viabilidade. **GEOGRAFIA, Rio Claro**, v. 38(1), p. 175-188, 2013.

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

MONTGOMERY, Douglas C.; RUNGER, George C.; HUBELE, Norma Faria. **Estatística aplicada à engenharia**. Tradução Verônica Calado - 2.ed. - Rio de Janeiro: LTC, 2011.

MORAES, E. C. **Fundamentos de Sensoriamento Remoto**. Instituto Nacional de Pesquisas Espaciais – INPE, São José dos Campos, 2002. Disponível em: <[http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2005/06.14.12.18/doc/ CAP1_ECMoraes.pdf](http://mtc-m12.sid.inpe.br/col/sid.inpe.br/sergio/2005/06.14.12.18/doc/CAP1_ECMoraes.pdf)>. Acesso em: 21 jun. 2017.

MORIDNEJAD, A.; ABDOLLAHI, H.; ALAVIPANAH, S. K.; SAMANI, J. M. V.; MORIDNEJAD, O.; KARIMI, N. Applying artificial neural networks to estimate suspended sediment concentrations along the southern coast of the Caspian Sea using MODIS images. **Arab. J. Geosci.** 2015, 8, 891–901.

NÉRI, A.M. **Assimilação de nitrato, amônio e ureia pelo fitoplâncton com uso de traçador 15N: experimentos com amostras ambientais e culturas laboratoriais**. Dissertação (Mestrado em Ciências da Engenharia Hidráulica e Saneamento) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. 4. ed. São Paulo: Blucher, 2010.

NOVO, E. M. L. M. et al. Proposal for a remote sensing trophic state index based upon Thematic Mapper/Landsat images. **Rev. Ambient. Água**, vol. 8(3), 2013.

NUSCH, E. A. Comparison of different methods for chlorophyll and phaeopigments determination. **Archiv für Hydrobiologie**, v. 14, p.14-36, 1980.

OYAMA, Y.; MATSUSHITA, B.; FUKUSHIMA, T. Distinguishing surface cyanobacterial blooms and aquatic macrophytes using Landsat/TM and ETM+ shortwave infrared bands. **Remote Sensing of Environment**, vol. 157, p. 35–47, 2015.

PETERSON, K.T.; SAGAN, V.; SIDIKE, P.; COX, A. L.; MARTINEZ, M. Suspended Sediment Concentration Estimation from Landsat Imagery along the Lower Missouri and Middle Mississippi Rivers Using an Extreme Learning Machine. **Remote Sensing**, p.1-17, 2018

PRADO, Rachel Bardy. **Geotecnologias aplicadas à análise espaço temporal do uso e cobertura da terra e qualidade da água do reservatório de Barra Bonita, SP, como suporte à gestão de recursos hídricos**. 2004. Tese (Doutorado em Ciências da Engenharia Ambiental) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2004.

RANDOLPH, K. L. **Remote sensing of cyanobacteria in Case II waters using optically active pigments, chlorophyll a and phycocyanin**. 2007. Master of Science in the Department of Geography, Indiana University.

RITCHIE, J.C.; ZIMBA, P.V.; EVERITT, J.H. Remote Sensing Techniques to Assess Water Quality. **Photogrammetric Engineering & Remote Sensing**, vol. 69(6), p. 695–704, 2003.

ROIG, H. L. *et al.* Uso de câmeras de baixo custo acopladas a veículos aéreos leves no estudo do aporte de sedimentos no Lago Paranoá. **Anais XVI Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Foz do Iguaçu, 2013.

ROUSE, J.; JR., HAAS, R. H., SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the Great Plains with ERTS. **NASA Special Publication**, vol. 351, p. 309–317, 1974.

RUDORFF, C. M. **Estudo da composição das águas da Planície Amazônica por meio de dados de reflectância do sensor Hyperion e de espectrômetro de campo visando à compreensão da variação temporal dos seus constituintes opticamente ativos**. 2006. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2006.

RUNDQUIST D. C. et al. Remote Measurement of Algal Chlorophyll in Surface Waters: The Case for the First Derivative of Reflectance Near 690 nm. **Photogrammetric Engineering & Remote Sensing**, vol. 62, n° 2, p. 195-200, 1996.

SANTOS, A.C.A. **Heterogeneidade espacial e variabilidade temporal de dois reservatórios com diferentes graus de trofia, no Estado de São Paulo**. Dissertação (Mestrado em Ciências da Engenharia Ambiental) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2003.

SANTOS, F.M.; VITTI, D.M.C.; GUIMARÃES, T.T.; SANTOS, B.B.; MAUAD, F.F. **Determinação e análise de variáveis de qualidade da água da represa do broa – itirapina/sp**. Anais do XV Simpósio do Programa de Pós-Graduação em Ciências da Engenharia Ambiental. São Carlos, 2016.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010.

SILVA, H. A. N.; ROSATO, A.; ALTILIO, R.; PANELLA, M. Water quality prediction based on wavelet neural networks and remote sensing. 2018 International Joint Conference on Neural Networks (IJCNN), IEEE, 2018, pp. 1–6.

SONG, K.; LI, L.; WANG, Z.; LIU, D.; ZHANG, B.; XU, J.; DU, J.; LI, L.; LI, S.; WANG, Y. Retrieval of total suspended matter (TSM) and chlorophyll-a (Chl-a) concentration from remote-sensing data for drinking water resources. **Environ Monit Assess**, p.1449-1470, 2012.

SPERLING, M. V. **Introdução à qualidade das águas e ao tratamento de esgotos**. 3. ed. Belo Horizonte: UFMG, 2005.

STEP – Science Toolbox Exploitation Platform. **Sen2Cor**. Disponível em: <<http://step.esa.int/main/third-party-plugins-2/sen2cor/>>. Acesso em: 15 fev. 2019.

SVÁB E. et al. Characterizing the spectral reflectance of algae in lake Waters with high suspended sediment concentrations. **International Journal of Remote Sensing**, vol. 26, nº 5, p. 919-928, 2005.

TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, vol. 8, n. 2, p. 127–150, 1979.

TUNDISI, J. G.; et al. The response of Carlos Botelho (Lobo, Broa) Reservoir to the passage of cold fronts as reflected by physical, chemical, and biological variables. **Brazilian Journal of Biology**, v. 64, p. 177-186, 2004.

TUNDISI, J.G.; MATSUMURA-TUNDISI, T. The ecology of UHE Carlos Botelho (Lobo-Broa Reservoir) and its watershed, São Paulo, Brazil **Freshwater Reviews**, vol. 6, p. 75-91, 2013.

TUNDISI, J. G.; MATSUMURA-TUNDISI, T.; RODRIGUES, S. M. **Gerenciamento e recuperação das bacias hidrográficas dos rios Itaqueri e do Lobo e da UHE Carlos Botelho (Lobo-Broa)**. São Carlos: IIE, 2003.

TUNDISI, J.G.; MATSUMURA-TUNDISI, T.; TUNDISI, J.E.M. Reservoirs and human well being: New challenges for evaluating impacts and benefits in the neotropics. **Brazilian Journal of Biology**, vol. 68, p. 1133–1135, 2008.

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

TYRRELL, J. **The effect of water temperature on in-stream sediment concentration and transport rate**. Thesis (Master). Michigan Technological University, 2015.

USGS - UNITED STATES GEOLOGICAL SURVEY. **Landsat 8 (L8) Data Users Handbook**. Disponível em: <<https://landsat.usgs.gov/landsat-8-l8-data-users-handbook>>. Acesso em: 29 set. 2017.

VERONEZ, M.R.; KUPSSINSKU, L.S.; GUIMARAES, T.T; KOSTE, E.C.; SILVA, J.M.S.; SOUZA, L.V.S.; OLIVERIO, W.F.M.; JARDIM, R.S.; KOCH, I.É; SOUZA, J.G.S.; GONZAGA JR., L.; MAUAD, F.F.; INOCENCIO, L.C.; BORDIN, F. Proposal of a Method to Determine the Correlation between Total Suspended Solids and Dissolved Organic Matter in Water Bodies from Spectral Imaging and Artificial Neural Networks. **Sensors**, v.18, n.159 p.1-15, 2018.

VILELA, M. A. M. A. **Metodologia para monitoramento da qualidade da água de reservatórios utilizando sensoriamento remoto**. 2010. Dissertação (Mestrado em Engenharia Civil) – Faculdade de Engenharia Civil, Universidade Federal de Uberlândia, Uberlândia, 2010.

VILLAR, R. E. et al. Reconstrução de uma série histórica de descarga de sedimentos usando imagens de satélite MODIS nos rios da Amazônia peruana. **Anais...** XV Simpósio Brasileiro de Sensoriamento Remoto (SBSR), Curitiba, PR, Brasil, abr.-mai. 2011, p. 5356-5363.

WANG, J.; TIAN, Q. Estimation of total suspended solids concentration by hyperspectral remote sensing in Liaodong Bay. **Indian J. Mar. Sci.** 2015, 44, 8, 1137-1144.

WATANABE, F.S.Y. et al. Estimation of Chlorophyll-a Concentration and the Trophic State of the Barra Bonita Hydroelectric Reservoir Using OLI/Landsat-8 Images. **Int. J. Environ. Res. Public Health**, vol.12, 2015.

ZIMBA P. V.; GITELSON, A. Remote estimation of chlorophyll concentration in hyper-eutrophic aquatic systems: Model tuning and accuracy optimization. **Aquaculture**, vol. 256, p. 272–286, 2006.

APÊNDICE A - DADOS COLETADOS COM A SONDA MULTIPARÂMETROS

Ponto	pH			Temperatura (°C)			Condutividade (µS/cm)			Turbidez (NTU)		
	Jan.	Maio	Jul.	Jan.	Maio	Jul.	Jan.	Maio	Jul.	Jan.	Maio	Jul.
1	7,55	5,75	6,72	26,71	17,89	18,36	15	13	23	8,2	5,6	3,9
2	6,18	5,18	6,05	26,65	19,19	18,88	16	15	26	7,1	6,2	4,5
3	5,82	5,15	6,07	26,35	19,37	19,06	17	17	27	7,3	7,3	5,3
4	5,74	5,09	6,14	26,35	19,34	17,79	19	17	38	6,8	5,9	2,8
5	5,58	5,00	6,15	26,34	20,03	18,97	20	15	30	7,3	4,5	3,6
6	5,12	5,07	6,07	26,48	19,85	19,45	19	17	26	7,1	6,4	2,7
7	5,55	5,08	6,08	26,50	19,93	19,29	18	17	26	6,2	5,5	3,1
8	5,44	5,13	6,04	26,63	20,16	19,16	19	17	27	4,8	4,3	3,7
9	5,48	5,09	6,10	26,75	20,27	18,83	19	16	27	4,3	4,5	4,2
10	5,42	5,20	6,01	26,71	20,22	19,21	17	17	25	4,7	4,1	3,0
11	5,28	5,15	6,00	26,73	20,31	19,33	19	17	25	5,4	4,3	2,7
12	5,22	5,14	5,98	26,90	20,33	19,18	18	17	25	4,4	4,2	4,3
13	5,24	5,09	6,05	26,80	20,57	19,30	19	16	25	5,3	4,7	2,7
14	5,58	5,05	6,08	26,95	20,79	19,21	17	17	24	3,7	4,4	2,0
15	5,28	5,16	6,09	27,10	20,92	19,32	17	16	24	3,9	4,1	1,8
16	5,51	5,04	6,08	27,23	21,29	19,41	16	17	24	5,3	4,2	1,8
17	5,43	5,05	6,23	27,39	21,12	19,65	17	17	24	5,2	4,4	1,6
18	6,13	5,28	6,27	28,85	21,15	19,77	15	16	24	3,2	4,6	1,4
19	6,44	5,86	6,27	29,30	21,40	20,02	17	16	24	3,2	4,3	1,2
20	6,32	5,58	6,24	28,50	21,32	19,96	13	17	24	3,4	3,7	1,3
21	5,92	5,19	6,26	29,03	21,37	19,87	17	17	24	3,3	3,4	1,6
22	5,88	5,04	6,29	28,43	21,18	19,98	17	17	24	3,2	4,8	1,0
23	5,65	4,90	6,34	27,35	21,35	20,11	18	17	23	3,2	4,6	1,2
24	6,06	4,94	6,26	28,97	21,30	20,03	17	18	24	3,5	3,6	1,1
25	6,06	4,81	6,30	29,25	21,08	20,23	17	17	24	3,2	3,5	1,1
26	5,93	4,92	6,34	28,70	21,09	20,39	17	14	24	3,7	3,6	0,6
27	5,95	4,87	6,33	29,52	20,98	20,46	16	16	24	3,4	4,3	0,9
28	5,97	4,88	6,34	28,58	20,85	20,57	16	16	24	3,7	4,0	1,2
29	6,12	4,78	6,41	29,34	21,10	20,55	17	17	23	3,6	3,7	1,1
30	6,05	4,98	6,34	29,40	20,86	20,56	17	17	23	3,7	3,8	1,1

APÊNDICE B – DADOS ANALISADOS EM LABORATÓRIO

Ponto	Janeiro		Maio		Julho	
	SST	Cl-a	SST	Cl-a	SST	Cl-a
1	5,44	10,36	5,00	5,92	7,40	10,66
2	4,56	8,39	4,60	10,06	3,67	7,70
3	4,33	11,84	4,25	9,18	3,58	9,18
4	3,67	9,87	4,20	5,03	5,40	10,06
5	5,44	13,81	2,30	5,33	3,70	9,77
6	5,67	11,84	3,58	6,22	3,25	15,39
7	3,91	11,35	2,90	5,92	5,39	9,18
8	2,11	7,40	3,67	6,81	3,25	8,88
9	2,00	5,92	3,17	5,03	5,61	9,18
10	3,07	8,29	2,67	5,03	2,44	8,88
11	3,67	8,29	2,60	9,77	2,50	9,18
12	1,80	5,62	2,30	4,74	3,30	8,58
13	2,67	8,29	2,80	5,62	5,17	7,40
14	1,47	4,14	3,30	4,44	1,38	6,51
15	1,33	7,10	2,17	6,22	4,61	7,70
16	2,60	5,92	3,14	4,44	2,70	6,22
17	2,00	3,85	3,50	3,55	4,21	7,40
18	1,00	5,33	2,75	2,66	2,92	7,70
19	0,80	4,74	3,08	5,62	3,83	8,29
20	0,80	4,93	3,57	13,62	2,12	8,58
21	1,33	5,53	2,47	3,85	3,83	7,40
22	1,13	6,12	2,34	7,70	2,56	9,18
23	1,33	3,26	3,43	4,44	3,33	8,58
24	1,13	5,72	2,92	5,03	2,13	10,36
25	1,30	7,30	2,93	6,22	3,00	10,06
26	2,13	5,33	2,83	5,33	2,12	9,77
27	1,40	6,91	3,36	5,33	2,00	10,06
28	2,00	5,53	3,42	4,44	3,71	9,77
29	2,07	5,72	3,83	2,66	2,25	11,84
30	2,00	3,16	3,50	4,14	2,19	11,84

APÊNDICE C – RESULTADOS DAS ANÁLISES DE REGRESSÃO

Parâmetro	Tratamento	Conjunto	n	Variável	Ajuste	R ²
Clorofila-a	Nenhum	Janeiro	23	NDWI	Linear	0,39
				NRAVI	Quadrático	0,63
				B3/B4	Quadrático	0,59
				B3/B5	Quadrático	0,55
				B3/B6	Linear	0,44
				B4/B3	Quadrático	0,64
				B5/B3	Quadrático	0,62
				B6/B3	Linear	0,45
				B8/B3	Linear	0,39
	Nenhum	Maio/Julho	46	B12	Linear	0,34
				B12/B3	Quadrático	0,33
				B12/B4	Linear	0,31
	Exc. Outliers	Janeiro	23	NRAVI	Quadrático	0,53
				B3/B4	Quadrático	0,53
				B3/B5	Quadrático	0,47
				B3/B6	Linear	0,36
				B4/B3	Quadrático	0,50
				B5/B3	Quadrático	0,47
				B6/B3	Linear	0,35
				B7/B3	Quadrático	0,36
	Exc. Outliers	Julho	23	B11	Quadrático	0,37
				B3/B11	Quadrático	0,34
				B11/B3	Quadrático	0,36
				B11/B4	Quadrático	0,39
				B11/B12	Quadrático	0,32
	Exc. Outliers	Maio/Julho	42	B3	Linear	0,44
				B11	Linear	0,39
				B12	Linear	0,68
				B3/B12	Quadrático	0,59
				B4/B12	Quadrático	0,63
				B5/B12	Quadrático	0,58
				B7/B12	Quadrático	0,48
				B12/B3	Quadrático	0,64
				B12/B4	Linear	0,64
				B12/B5	Linear	0,60
				B12/B7	Quadrático	0,50
				B12/B8	Quadrático	0,38

Continuação Apêndice C

Parâmetro	Tratamento	Conjunto	n	Variável	Ajuste	R ²
Clorofila-a	Exc. Outliers	Todos	65	B3/B12	Quadrático	0,36
				B4/B12	Quadrático	0,33
				B12/B3	Linear	0,39
				B12/B4	Linear	0,34
				B12/B5	Linear	0,30
SST	Nenhum	Janeiro	23	NDWI	Quadrático	0,53
				NRAVI	Quadrático	0,50
				B3/B4	Quadrático	0,50
				B3/B5	Quadrático	0,59
				B3/B6	Quadrático	0,59
				B3/B7	Linear	0,40
				B3/B8	Quadrático	0,53
				B3/B8a	Quadrático	0,42
				B4/B3	Linear	0,48
				B5/B3	Quadrático	0,40
				B6/B3	Quadrático	0,59
				B7/B3	Linear	0,41
				B8/B3	Quadrático	0,51
				B12	Quadrático	0,45
	Exc. Outliers	Maio	23	B3/B5	Quadrático	0,33
				B5/B3	Quadrático	0,31

APÊNDICE D – RESULTADOS DAS REDES NEURAIS ARTIFICIAIS

Resultados das RNAs para clorofila-a

Conjunt o	Nº	Entrada da rede ¹	Topologia ²	Função de ativação ³	Ciclos	Treinamento		Validação	
						R ²	RMS E	R ²	RMS E
Janeiro	JaC1	C4	4-7-1	tang./tang .	500	0,7 9	1,57	0,8 4	1,59
	JaC2	C1	6-13-1	tang./tang .	500	0,8 6	1,10	0,7 5	2,96
Maio	MC 1	C4	4-5-1	tang./lin.	500	0,9 0	0,84	0,6 4	7,33
	MC 2	C4	4-7-1	tang./lin.	300	0,9 3	0,64	0,5 2	3,93
	MC 3	C1	6-15-1	tang./lin.	200	0,9 0	0,82	0,8 3	2,52
	MC 4	C1	6-10-1	tang./lin.	300	0,9 0	0,76	0,5 2	2,58
Julho	JuC 1	C4	4-5-1	tang./tang .	400	0,9 7	0,34	0,6 0	2,10
	JuC 2	C4	4-7-1	tang./tang .	100	0,9 6	0,38	0,7 2	2,80
	JuC 3	C1	6-10-1	tang./tang .	300	0,9 2	0,58	0,5 1	1,97
	JuC 4	C1	6-10-1	tang./lin.	500	0,9 7	0,34	0,7 1	5,38
Todos	TC1	C4 + ut	6-15-1	tang./tang .	500	0,6 7	1,57	0,6 5	1,60
	TC2	C3 + ut	12-7-1	sigm./lin.	500	0,6 6	1,62	0,7 6	1,69
	TC3	C3 + ut	12-7-1	tang./tang .	200	0,6 5	1,65	0,7 5	1,51
	TC4	C3 + ut	12-20-1	tang./lin.	300	0,6 4	1,67	0,7 8	1,27

Resultados das RNAs para SST

Conjunto	Nº	Entrada da rede ¹	Topologia ²	Função de ativação ³	Ciclos	Treinamento		Validação	
						R ²	RMSE	R ²	RMSE
Janeiro	JaS1	C4	4-5-1	tang./tang.	500	0,96	0,31	0,86	1,02
	JaS2	C1	6-10-1	tang./lin.	300	0,96	0,31	0,88	1,35
	JaS3	C1	6-10-1	sigm./lin.	300	0,88	0,53	0,74	0,98

	JaS4	C1	6-10-1	tang./tang.	500	0,88	0,53	0,81	0,49
Maio	MS1	C4	4-7-1	tang./lin.	500	0,90	0,21	0,71	0,84
	MS2	C1	6-10-1	tang./lin.	500	0,91	0,21	0,70	0,80
	MS3	C1	6-15-1	tang./lin.	300	0,87	0,25	0,68	1,08
Julho	JuS1	C4	4-5-1	tang./lin.	200	0,98	0,16	0,73	2,29
	JuS2	C1	6-10-1	tang./tang.	300	0,99	0,07	0,58	2,01
	JuS3	C1	6-10-1	tang./lin.	300	0,93	0,37	0,75	1,37
	JuS4	C1	6-15-1	tang./tang.	300	0,99	0,11	0,62	2,37
Todos	TS1	C4 + ut	6-10-1	tang./lin.	500	0,81	0,54	0,53	1,28
	TS2	C4 + ut	6-13-1	tang./lin.	500	0,79	0,58	0,62	1,13
	TS3	C3 + ut	12-7-1	tang./lin.	200	0,64	0,75	0,68	0,71
	TS4	C3 + ut	12-15-1	sigm./lin.	400	0,77	0,60	0,62	0,82
	TS5	C3 + ut	12-20-1	sigm./lin.	500	0,82	0,54	0,58	0,86

¹ C1: Conjunto 1; “+ ut”: variáveis umidade (u) e temperatura (t) foram incluídas como entrada da rede. ² Entrada-nº de neurônios na cama oculta-saída. ³ Camada oculta/camada de saída.