



**UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOCIÊNCIAS APLICADAS**

ILANNA DE SOUZA RÊGO

**VARIABILIDADE DAS PROPRIEDADES ÓTICAS
APARENTES DE ÁGUAS CONTINENTAIS POR MEIO DE
SENSORES HIPERESPECTRAIS PARA O
MONITORAMENTO DA QUALIDADE DAS ÁGUAS**

Dissertação de Mestrado nº115

Área de Concentração: Geoprocessamento e Análise Ambiental

Brasília – DF
2017

ILANNA DE SOUZA RÊGO

**VARIABILIDADE DAS PROPRIEDADES ÓTICAS
APARENTES DE ÁGUAS CONTINENTAIS POR MEIO DE
SENSORES HIPERESPECTRAIS PARA O
MONITORAMENTO DA QUALIDADE DAS ÁGUAS**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Geociências Aplicadas do Instituto de Geociências da Universidade de Brasília, como requisito parcial para a obtenção do grau de Mestre em Geociências Aplicadas, cuja área de concentração é Geoprocessamento e Análise Ambiental.

Prof. Dr. Henrique Llacer Roig

Orientador

Prof. Dr. Jean Michel-Martinez

Coorientador

Brasília – DF

2017

FICHA CATALOGRÁFICA

REGO, Ilanna de Souza

Variabilidade das propriedades óticas aparentes de águas continentais por meio de sensores hiperespectrais para o monitoramento da qualidade das águas. Ilanna de Souza Rêgo. Orientação: Henrique Llacer Roig. Coorientação: Jean-Michel Martinez – Brasília, 2017.

104p.

Dissertação de Mestrado nº 115 - Universidade de Brasília / Instituto de Geociências, 2017.

1. Sensoriamento Remoto; 2. Qualidade da água; 3. Sedimento em suspensão; 4. Reflectância; 5. Monitoramento de águas continentais.

REFERÊNCIA BIBLIOGRÁFICA

Rêgo, I.S. Variabilidade das propriedades óticas aparentes de águas continentais por meio de sensores hiperespectrais para o monitoramento da qualidade das águas. 2017. 104p. Dissertação de Mestrado – Instituto de Geociências, Universidade de Brasília, Brasília – Distrito Federal.

CESSÃO DE DIREITOS

NOME DO AUTOR: Ilanna de Souza Rêgo

TÍTULO DA DISSERTAÇÃO: Variabilidade das propriedades óticas aparentes de águas continentais por meio de sensores hiperespectrais para o monitoramento da qualidade das águas.

GRAU: Mestre ANO: 2017

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

Ilanna de Souza Rêgo

Ilanna_rego@hotmail.com

ILANNA DE SOUZA RÊGO

**VARIABILIDADE DAS PROPRIEDADES ÓTICAS
APARENTES DE ÁGUAS CONTINENTAIS POR MEIO DE
SENSORES HIPERESPECTRAIS PARA O
MONITORAMENTO DA QUALIDADE DAS ÁGUAS**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Geociências Aplicadas do Instituto de Geociências da Universidade de Brasília, como requisito parcial para a obtenção do grau de Mestre em Geociências Aplicadas, cuja área de concentração é Geoprocessamento e Análise Ambiental.

Aprovado em 29 de maio de 2017.

BANCA EXAMINADORA

Prof. Dr. Henrique Llacer Roig (Orientador – UNB)

Prof. Dra. Rejane Ennes Cicereli (UNB)

Prof. Dr. Nilton Nobuhiro Imai (UNESP)

AGRADECIMENTOS

Primeiramente, agradecer a minha família e parentes. Agradecer a minha mãe, que mesmo distante esteve sempre presente, ao seu esposo e meus irmãos, a minha tia Irani e a minha tia Helena, que me apoiaram ao longo de toda essa jornada.

Na sequência, quero agradecer a toda equipe no Instituto de Geociências da Universidade de Brasília, pois aqui eu fui muito bem acolhida. Em especial, aos professores Henrique Roig, Jean- Michel Martinez, Gustavo Baptista e Rejane Ennes que conquistaram meu carinho e admiração pela humildade e bom-humor que carregam, e por compartilharem muito mais que conhecimento... Amizade acima de tudo!

Em seguida, quero agradecer a toda equipe do Laboratório de Sensoriamento Remoto e Análises Espaciais (LSRAE), onde eu fiz grandes amigos (Marceli, Diogo, Bruno, Emanuel, Henrique... uma lista enorme de pessoas), alguns tão importantes que espero levar para toda a vida, em especial Caroline Chahini, Kellin Shimidt, Derlayne Roque e Khalil Ganen (MEUS AMORES)... Vocês simplesmente tornaram a minha vida mais colorida! Agradecer também as meninas da equipe de apoio (Dona Socorro e Fatinha), aos técnicos (Alô, alô, Serão!) e as secretárias... Enfim, a todos que participaram da minha história nesses últimos anos.

Por fim, agradecer aos parceiros como o *Institut de Recherche pour le Développement* (IRD), a Agência Espacial Francesa (CNES) pelo apoio de projetos TOSCA (SAMSAT 1 e SAMSAT 2), a FINEP e o CNPq pelo financiamento dos vários projetos, a Universidade de Brasília (UNB), a Universidade Federal do Ceará (UFC), a Fundação Cearense Meteorologia e Recursos Hídricos (FUNCEME), da Universidade Federal do Amazonas (UFAM), a Agencia Nacional de Águas (ANA), a CPRM e o Serviço Hidrometeorológico da Bolívia (SENAMHI)

RESUMO

O monitoramento da qualidade da água é importante para avaliar e compreender as consequências das atividades humanas nos ecossistemas aquáticos. Nesse contexto, o sensoriamento remoto está sendo uma fonte de dados para o monitoramento de parâmetros de qualidade da água em rios e lagos. O objetivo deste trabalho é compreender a variabilidade das propriedades ópticas da água em diferentes corpos d'água e avaliar a possibilidade da existência de um modelo de inversão universal para estimar a concentração de sedimentos em suspensão (CSS) a partir de dados de reflectância de sensoriamento remoto (Rrs) em bacias hidrográficas em contextos hidroclimáticos contrastados, cinco da América do Sul (incluindo os rios Amazonas, Maroni Madeira, Solimões, Purus, Paranoá, Paranapanema, São Francisco e Açudes do Nordeste) e uma da África (Lago Bagré). Para tal, foi realizado o adensamento de dados de campo e laboratório em uma base de dados (radiométricos e de sólido em suspensão), seguida da padronização, organização e armazenamento dos dados e, posteriormente, análises de regressão para diversos comprimentos de onda. Foram analisados um total de 723 pontos, sendo que 476 apresentaram CSS de 0 a 100mg/L e 247 pontos de 100 a 500mg/L. Para estes pontos foram testados os modelos linear e de potência para oito comprimentos de onda (500nm, 650nm, 740nm, 783nm, 800nm, 865nm, 900nm, 940nm) e quatro razões de bandas (865/650nm, 800/650nm, 940/650nm, 940/865nm), escolhidos com base no comportamento espectral da água e na faixa central de bandas dos sensores SENTINEL-2, MODIS E LANDSAT-8, a fim de avaliar qual é o melhor comprimento de onda e modelo para obter CSS a partir de dados de reflectância de sensoriamento remoto. Com base nos testes de normalidade, observou-se que o modelo linear é o mais indicado para avaliar CSS e reflectância para $CSS < 100\text{mg/L}$, enquanto que o modelo de potência é mais indicado para $CSS > 100\text{mg/L}$. A partir disso, os modelos foram aplicados por meio do software R gerando gráficos de dispersão, coeficientes dos modelos (lineares e angulares) e valores da Raiz do Erro Médio Quadrático (RMSE% - considerado aceitável quando inferior a 30%). Com base nos valores de RMSE% e nos coeficientes lineares e angulares gerados pelos modelos, observou-se que para $CSS < 100\text{mg/L}$ a utilização de modelos lineares específicos para cada corpo d'água utilizando bandas no infravermelho (em geral, 865nm) são mais adequados, ao passo que para $CSS > 100\text{mg/L}$ um modelo de potência global para a razão de bandas entre infravermelho/vermelho (em geral, 865/650nm), pode ser aplicado em qualquer um dos corpos d'água com $CSS > 100\text{mg/L}$ de maneira eficiente. Após a seleção dos melhores comprimentos de onda, com base nos valores de RMSE%, foi possível avaliar a potencialidade dos sensores SENTINEL-2, MODIS E LANDSAT-8. Verificou-se que para $CSS < 100\text{mg/L}$ o uso dos três sensores é adequado para a recuperação de CSS. Entretanto, para $CSS > 100\text{mg/L}$ o SENTINEL-2 e o LANDSAT-8, demonstram maior potencial que o MODIS. Devido às suas altas resoluções (espectral, radiométrica, temporal e espacial), o SENTINEL-2 apresenta maior potencial para a obtenção de CSS frente ao MODIS e LANDSAT-8, em ambos os casos.

Palavras-chave: Qualidade da água, Sensoriamento Remoto, Sólido em suspensão.

ABSTRACT

Monitoring water quality is important in assessing and understanding the consequences of human activities on aquatic ecosystems. In this context, remote sensing is increasingly being used for the monitoring of water quality parameters in rivers and lakes. The main goal of this work is to understand the variability of the optical properties of water in different water bodies and to evaluate the possibility of the existence of a universal inversion model to estimate suspended sediment concentration (CSS) from remote sensing reflectance data (Rrs) in watersheds in contrasting hydroclimatic contexts, five from South America (including the Amazonas, Maroni Madeira, Solimões, Purus, Paranoá, Paranapanema and São Francisco rivers, and Northeastern reservoirs) and one from Africa (Bagré Lake). For this purpose, the data were densified in field and laboratory, in a database (radiometric and solid in suspension), standardized, organized, stored, and later, analyzed using linear regression for different wavelengths. A total of 723 points were analyzed, 476 had CSS from 0 to 100mg / L and 247 points from 100 to 500mg / L. For these points the linear and power models for eight wavelengths (500nm, 650nm, 740nm, 783nm, 800nm, 865nm, 900nm, 940nm, 940nm) were tested and four band ratios (865 / 650nm, 800 / 650nm, 940 / 650nm, 940 / 865nm), chosen based on the spectral behavior of the water and the central bands of the SENTINEL-2, MODIS and LANDSAT-8 sensors, in order to evaluate the best wavelength and model to obtain CSS from remote sensing reflectance data. Based on the normality tests, it was observed that the linear model is the most suitable for assessing CSS and reflectance for CSS <100mg / L, while the power model is more suitable for CSS > 100mg / L. Based on this, the models were applied through the R software generating dispersion graphs, coefficients of the models (linear and angular) and root mean square error values (RMSE% - considered acceptable when less than 30%). Based on the RMSE% values and the linear and angular coefficients generated by the models, it was observed that for CSS <100mg / L the use of specific linear models for each water body using infrared bands (in general 865nm) are more appropriate, while for CSS > 100mg / L a global power model for the infrared / red band ratio (usually 865 / 650nm), can be applied to any of the water bodies with CSS > 100mg / L in a more efficient way. After selecting the best wavelengths, based on the RMSE% values, it was possible to evaluate the potentiality of the sensors: SENTINEL-2, MODIS and LANDSAT-8. It was verified that for CSS <100mg / L the use of the three sensors is suitable for the recovery of CSS. However, for CSS > 100mg / L, SENTINEL-2 and LANDSAT-8 show greater potential than MODIS. Due to its high resolution (spectral, radiometric, temporal and spatial), SENTINEL-2 has a higher potential for obtaining CSS compared to MODIS and LANDSAT-8, in both cases.

Key words: Water quality, Remote Sensing, Solid in suspension.

SUMÁRIO

CAPÍTULO 1 – APRESENTAÇÃO	10
1.1 INTRODUÇÃO	10
1.2 OBJETIVOS	12
1.2.1 Objetivo Geral	12
1.2.2 Objetivos Específicos	12
CAPÍTULO 2 – FUNDAMENTOS DE SENSORIAMENTO REMOTO DE SISTEMAS AQUÁTICOS	13
2.1 CONTEXTO HISTÓRICO	13
2.2 COMPORTAMENTO ESPECTRAL E PROPRIEDADES ÓPTICAS DA ÁGUA	14
2.2.1 Grandezas Radiométricas	15
2.2.2 Propriedades Ópticas Inerentes	15
2.2.3 Propriedades Ópticas Aparentes	17
2.3 COMPONENTES OPTICAMENTE ATIVOS	19
2.3.1 Pigmentos Fotossinteticamente Ativos	21
2.3.2 Matéria Orgânica Dissolvida	21
2.3.3 Sedimentos em Suspensão	22
2.4 MONITORAMENTO DE QUALIDADE DA ÁGUA	26
CAPÍTULO 3 - MATERIAL E MÉTODOS	29
3.1 ÁREAS DE ESTUDO	29
3.2 AQUISIÇÃO, PROCESSAMENTO E ANÁLISE DE DADOS	32
3.2.1 Levantamento de dados	34
3.2.1.1 Campo	34
3.2.1.1.1 Radiometria	34
3.2.1.1.2 Coleta de água	36
3.2.1.2 Laboratório	36
3.3 ORGANIZAÇÃO DA BASE DE DADOS	37
3.4 ANÁLISE DE DADOS	39
CAPÍTULO 4 – RESULTADOS E DISCUSSÃO	41
4.1 RESULTADOS	41
4.1.1 Banco de dados consistido	41
4.1.1 Escolha do modelo por faixa de concentração	42
4.1.1.1 Dados com concentração entre 0 e 100mg/L	43
4.1.1.2 Dados com concentração entre 100 e 500mg/L	46
4.1.2 Aplicação e comportamento geral dos modelos	48
4.1.2.1 Concentrações entre 0 e 100mg/L	49
4.1.2.1.1 Análise Individual	50
4.1.2.2 Concentrações entre 100 e 500mg/L	56
4.1.2.2.1 Análise Individual	57
4.1.3 Coeficientes Angulares e Lineares	60

4.2 DISCUSSÃO	63
4.2.1 Avaliação de bandas e razões de bandas	64
4.2.2 Potencialidade de sensores orbitais	66
4.2.3 Variação dos coeficientes lineares e angulares	69
4.2.4 Variação da raiz do erro médio quadrático (RMSE%) entre amostras	78
CAPÍTULO 5 - CONCLUSÕES	81
CONSIDERAÇÕES FINAIS	83
REFERÊNCIAS BIBLIOGRÁFICAS	84
APÊNDICE	90

CAPÍTULO 1 – APRESENTAÇÃO

1.1 INTRODUÇÃO

A qualidade das águas está associada a uma variabilidade de processos tanto naturais quanto antrópicos, no qual podemos citar: modificação da produtividade primária; processo de transferências biogeoquímicas entre água e o substrato, modificações no padrão de cobertura da terra das bacias que contribuintes para os corpos hídricos. Este último afeta diretamente a concentração de sólido em suspensão (CSS) transportada na coluna d'água. Por tanto, avaliar a contribuição de sedimentos trazidos pelos rios é de suma importância para a compreensão da dinâmica natural dos corpos d'água e na construção de subsídios à gestão de recursos hídricos, pois grandes concentrações de sedimentos podem gerar desequilíbrios ambientais severos (KIRK 1994; ANDRADE *et al.*, 2007).

As informações hidrológicas são indispensáveis para promover o aproveitamento dos recursos hídricos em bases sustentáveis. A falta de informações hidrológicas aumenta a incerteza no processo de tomada de decisão e acarreta em resultados negativos no uso e aproveitamento dos recursos hídricos (TUCCI, 2001). A maioria dos estudos hidrológicos é realizada pela coleta de dados em estações fixas de monitoramento ou por coleta de dados em plataformas flutuantes. Este fato gera altos custos e restringe a malha de amostragem espacial diminuindo as possibilidades de uma avaliação mais precisa e bem distribuída (JENSEN, 2009; KAMPEL, 2005).

Neste cenário, o Sensoriamento Remoto (SR) surge como uma ferramenta importante para estudos hidrológicos, pois facilita o entendimento da situação ambiental em estudo, tanto na área de contribuição, como no próprio corpo hídrico (SOUZA, 2003). No caso dos corpos hídricos, possibilita mapear as distribuições das características ópticas da água e gera subsídios para o monitoramento espaço-temporal da variabilidade dos fluxos de sedimentos fornecendo informações sobre o comportamento dos sedimentos com precisão e a baixo custo (JENSEN, 2009).

Tendo em vista que o planejamento, gerenciamento e monitoramento de recursos naturais necessita de dados constantemente atualizados algumas universidades do Brasil, em parceria com a Agência Nacional de Águas – ANA e o *Institut de Recherche pour Le Développement* – IRD, têm investido seus esforços e trabalhado no desenvolvimento de metodologias de pesquisa com vista à criação de novas técnicas e tecnologias para o

monitoramento da qualidade das águas continentais brasileiras, visando o monitoramento automatizado de parâmetros hidrológicos por meio da avaliação de componentes opticamente ativos (importantes na determinação da cor da água) como, por exemplo, sedimentos (MARTINEZ *et al.*, 2015; PINTO *et al.*, 2014; VILLAR *et al.*, 2013 **a e b**; VILLAR *et al.*, 2012 **a e b**; MENEZES, 2013) e clorofila-a (PISCOYA *et al.*, 2013). Além destes grupos de pesquisa, outras instituições brasileiras vêm atuando no Brasil com vistas ao entendimento do comportamento espectral de águas interiores como a UNESP (por exemplo: ALCÂNTARA, CURTARELLI & STECH, 2016; BERNARDO & ALCÂNTARA, 2017; BERNARDO *et al.*, 2017; RODRIGUES *et al.*, 2016) e o INPE (por exemplo: MORELLI, KAMPEL & NOVO, 2010; MONTANHER *et al.*, 2014; CURTARELLI, ALCÂNTARA & STECH, 2015; BARBOSA *et al.*, 2014).

No Brasil, vários projetos (REGEST, AQUASENSE, SAMSAT, MEGHYBAM, OEG, IHESA e pela CPRM.) realizaram levantamento de dados de campo tanto de sólidos em suspensão como de radiometria a fim de investigar a qualidade da água. Destes, o projeto com a maior quantidade de dados é o AQUASENSE que trata do “Desenvolvimento de Técnicas de sensoriamento remoto para o monitoramento da qualidade das águas continentais em rios, reservatórios e lagos do Brasil”. Trata-se de um projeto financiado pela FINEP e conta com a participação de várias instituições de pesquisa (Universidade de Brasília, da Universidade Federal do Ceará, da Fundação Cearense Meteorologia e Recursos Hídricos, da Universidade Federal do Amazonas, Agência Nacional de Águas e o *Institut de Recherche pour Le Développement*) e visa, dentre outras coisas, a construção de um banco de dados radiométricos de águas continentais brasileiras.

O projeto AQUASENSE possui de um grande volume de dados radiométricos de campo e de CSS oriundos das várias campanhas de campo realizada pelos seus integrantes. Todos os dados foram coletados utilizando a mesma sistemática e os mesmos tipos de radiômetros, tendo com principal objetivo o monitoramento dos fluxos sedimentares em rios, lagos e reservatórios. Considerando a existência desta grande base de dados (tanto do AQUASENSE quanto de outros projetos como REGEST, SAMSAT, MEGHYBAM, OEG, IHESA e pela CPRM), abre-se a possibilidade de entender melhor o comportamento espectral entre diversos corpos d’água em diferentes regiões.

Acredita-se que há um modelo empírico “universal” de inversão (concentração/radiometria) para todas as bacias analisadas. Espera-se, por tanto, futuramente ampliar o uso desta ferramenta a todos os tipos de corpos d’água (sem restrições de tamanho,

localização ou tipo de água). Para verificar a consistência dessa hipótese necessitou-se, inicialmente, organizar todos os dados radiométricos e de qualidade de água existentes em um único banco de dado, incluindo todo o processo de uniformização, consistência dos dados e crítica dos resultados, de modo a facilitar o monitoramento da variação de concentração de sedimento em suspensão por satélite no Brasil.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Verificar se há um único modelo de inversão para concentração de sólidos em suspensão a partir de dados de reflectância e se há a possibilidade de aplicar um modelo global em diferentes bacias em contextos hidroclimáticos contrastados.

1.2.2 Objetivos Específicos

- Verificar qual o(s) comprimento(s) de onda mais adequado(s) para uma inversão robusta de sedimento em suspensão para os corpos d'água em estudo;
- Propor modelos de inversão reflectância e CSS para as bacias estudadas e um global para todas as bacias.
- Verificar qual o melhor modelo de inversão para cada bacia e para cada faixa de concentração (verificar como varia de uma bacia a outra);
- Disponibilizar uma base de dados radiométricos hiperespectrais (já adquiridos);

CAPÍTULO 2 – FUNDAMENTOS DE SENSORIAMENTO REMOTO DE SISTEMAS AQUÁTICOS PARA ESTUDOS DE SÓLIDOS EM SUSPENSÃO

2.1 CONTEXTO HISTÓRICO

Por volta das décadas de 60 e 70, o SR passou a ter destaque como ferramenta para avaliar as variabilidades das características das águas do mar, com base nas alterações dos valores de radiância da superfície da água nos canais visível e infravermelho do espectro eletromagnético (MOBASHERI & HAMID, 2004). Neste contexto, surgiu um novo ramo da oceanografia, a Oceanografia por Satélites ou a Oceanografia Espacial, baseada nos conceitos da Hidrologia Óptica. A Oceanografia Espacial teve como marco inicial a publicação dos livros: “*Optical aspects of oceanography*” (JERLOV, 1974), seguido por: “*The remote sensing of spectral radiance from below the ocean surface*” (AUSTIN, 1974), e “*Marine Optics*” (JERLOV, 1976). Com o passar dos anos essa técnica foi expandida para o estudo de águas continentais.

O principal objetivo do uso de SR da cor da água é a obtenção de informações sobre tipos e quantidades de substâncias na água a partir da variação da cor. Várias pesquisas envolvendo água e SR têm sido desenvolvidas a partir de dados de sensores orbitais. O primeiro satélite lançado com o objetivo de estudar a cor da água foi o Nimbus-7, em 1978, equipado com o sensor CZCS (*Coastal Zone Color Scanner*). Devido à importância dos estudos realizados com as imagens adquiridas por este satélite, surgiram novos sensores com capacidade para medir a cor dos oceanos, como por exemplo: os sensores *Sea-viewing Wide Field-of-view Sensor* (SeaWiFS), *Moderate Resolution Imaging Spectroradiometer* (MODIS), e *Medium Resolution Imaging Spectrometer* (MERIS) e Ocean Color Imager (OCI). (SOUZA,2003).

Apesar dos dados de SR serem eficientes para mapear parâmetros associado à cor das águas, muitos fatores (características dos instrumentos de SR, os seus custos, a disponibilidade de software de processamento, o período de revisita e a baixa resolução espacial dos sensores) ainda limitam esta aplicação. Com o avanço das tecnologias e do conhecimento humano, novos sensores continuam a ser construídos visando melhorar a qualidade e a velocidade da aquisição de dados (SOUZA, 2003; MORAES, 2013). Com a popularização de sensores orbitais, o uso de SR para análise de processos e parâmetros na superfície dos corpos d’água está ganhando cada vez mais adeptos, uma vez que dados de

satélite apresentam cobertura sinóptica de grandes áreas da superfície da Terra (MONTES-HUGO *et al.*,2008; RAJEESH E DWARAKISH, 2015).

Existem diversas aplicações desses sensores, dentre elas destaca-se a avaliação da concentração de sedimentos por meio de caracterização da “cor” das águas para a determinação de sedimentos em suspensão em águas costeiras os trabalhos de DURAND *et al.*,2002; LIU *et al.*,2002; BOWERS *et al.*,2004; MILLER & MCKEE, 2004; BOLDRIN *et al.*,2005; NEZLIN *et al.*,2005; LIHAN *et al.*,2009; WANG & LU, 2010; e têm sido estendidos para estudos de águas continentais no Brasil (MARTINEZ *et al.*,2009; VILLAR *et al.*,2012 a e b; VILLAR *et al.*,2013; PISCOYA *et al.*,2013; PINTO *et al.*,2014; RODRIGUES *et al.*, 2016; ALCÂNTARA *et al.*, 2016; BERNARDO & ALCANTARA, 2017) já demonstram a possibilidade de relacionar o conteúdo de sedimentos e a cor de rios, lagos e reservatório.

2.2 COMPORTAMENTO ESPECTRAL E PROPRIEDADES ÓPTICAS DA ÁGUA

As águas naturais encontradas nos corpos hídricos superficiais representam uma mistura complexa de materiais e podem ser classificadas opticamente em dois tipos: a) caso I (águas profundas), como em oceano aberto, em que fitoplâncton é o principal responsável pelas variações ópticas em relação à concentração de outras substâncias; b) caso II (águas rasas), águas costeiras, estuarinas, rios, lagos e reservatórios, onde além do fitoplâncton e existem outras substâncias opticamente ativas (matéria orgânica dissolvida e sedimentos em suspensão) que podem afetar a coloração da água (MOREL & PRIEUR, 1977).

Ao analisar o espectro de reflectância de uma amostra de água, é possível perceber que os alvos contidos na amostra apresentam respostas específicas (em determinados comprimentos de onda), a esta resposta dá-se o nome de “assinatura ou comportamento espectral” (MOBLEY, 1994). Geralmente, o estudo de comportamento espectral de alvos é feito por meio de métodos experimentais de laboratório e campo (NOVO, 2001, NASCIMENTO *et al.*,2011). Em laboratório, sob condições controladas, as respostas espectrais são função direta das características físico-químicas do alvo. Em campo, o resultado também contará com fatores externos (ex.: condições de tempo, atmosfera e iluminação, e geometria de aquisição). Deste modo, para um adequado entendimento do

comportamento espectral da água, é necessário entender quais as propriedades ópticas que ela apresenta e como podem ser classificadas.

2.2.1 Grandezas Radiométricas

Ao atingir um objeto na superfície da Terra, a energia eletromagnética interage com o material que o constitui, podendo ser refletida, absorvida ou transmitida pelo objeto de maneira parcial ou total. Assim, a capacidade de um objeto absorver, refletir e transmitir a radiação eletromagnética é denominada, respectivamente, de absorvância, reflectância e transmitância (JENSEN, 2009). Portanto, ao analisar o espectro de reflectância de uma amostra, é possível perceber que os alvos apresentam respostas específicas (em determinados comprimentos de onda). Assim, o SR da água envolve análise de qualidade e quantidade de radiação que deixa a superfície da água, possibilitando a extração de informações sobre o tipo e quantidade de substâncias presentes no corpo d'água. Estas análises são baseadas nas propriedades ópticas inerentes da água (POI) e aparentes (POA), e no comportamento espectral da própria água e dos constituintes opticamente ativos (COA) presentes na amostra.

2.2.2 Propriedades Ópticas Inerentes

Quando a energia eletromagnética interage com a água, e os COA, ela pode sofrer vários processos físicos, como absorção e espalhamento. A quantificação desses processos torna possível inferir informações sobre os componentes presentes nos corpos d'água (NOVO 2001; NASCIMENTO *et al.* 2011; BARBOSA, 2005). Esses processos dão origem aos coeficientes relativos às Propriedades Ópticas Inerentes (POI), como: o coeficiente de absorção, coeficiente de espalhamento por unidade de volume, o coeficiente de atenuação e o albedo de espalhamento simples (MOBLEY, 1994; KIRK, 1994; BARBOSA, 2005; VILLAR, 2013).

As POI dependem, exclusivamente, das características biofísicas do corpo da água, são independentes do campo de luz e facilmente definidas, porém difíceis de medir (MOBLEY, 1994). Considerando a interação da energia incidente $\Phi_{o(\lambda)}$, de um feixe monocromático (λ) em um pequeno volume de água (ΔV) observa-se que parte da energia é absorvida $\Phi_{a(\lambda)}$, parte é espalhada $\Phi_{b(\lambda)}$ com um ângulo ψ em relação à direção do raio incidente, parte é transmitida $\Phi_{t(\lambda)}$ a coluna d'água sem sofrer trocas e parte é espalhada (Figura 01).

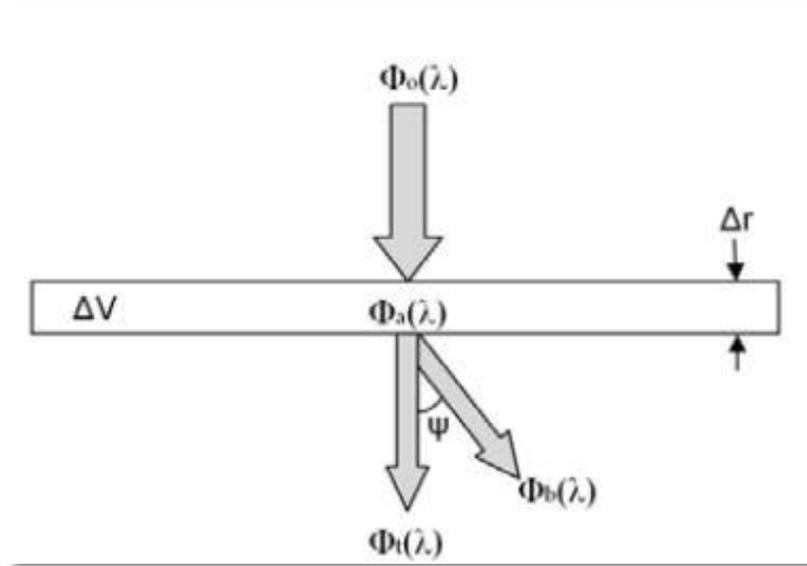


Figura 01: Interação de um raio de luz com o meio aquático. Fonte: adaptado de VILLAR, 2013

Assim, podemos expressar quantitativamente os fenômenos de absorvância ($A(\lambda)$), espalhamento ($B(\lambda)$), transmitância ($T(\lambda)$) e atenuância ($C(\lambda)$) por meio da equação 01(MOBLEY, 1994):

$$A(\lambda) + B(\lambda) + T(\lambda) = 1 \quad \text{Eq.(01)}$$

A absorção espectral ou Absorvância (A) representa a fração da potência incidente que é absorvida no volume da água determinando a taxa de decaimento do fluxo por unidade de fluxo incidente e por unidade de caminho óptico devido à absorção da energia eletromagnética pelos COA. Ela é obtida por meio da equação 02, onde ϕ_a é a energia absorvida e ϕ_0 é a energia incidente (MOBLEY, 1994):

$$A(\lambda) = \frac{\phi_a}{\phi_0} \quad \text{Eq. (02)}$$

O processo de espalhamento influencia na direção do fluxo incidente, assim, o coeficiente de espalhamento espectral ($B(\lambda)$) representa a fração da potência incidente que é espalhada no volume da água. Ele é obtido por meio da equação 03, onde ϕ_b é a energia espalhada e ϕ_0 é a energia incidente (MOBLEY, 1994):

$$B(\lambda) = \frac{\phi_b}{\phi_0} \quad \text{Eq. (03)}$$

A transmitância espectral ($T(\lambda)$) que é a fração que é transmitida. Ela é obtida por meio da equação 04, ϕ_t é a energia transmitida e ϕ_0 é a energia incidente (MOBLEY, 1994):

$$T(\lambda) = \frac{\phi_t}{\phi_0} \quad \text{Eq. (04)}$$

No caso do volume de água infinitesimal com uma espessura (Δr), os coeficientes de absorção e espalhamento são definidos pelas equações 05 e 06, onde ΔA é a variação da absorbância; ΔB é a variação do espalhamento e Δr é a espessura do corpo d'água (MOBLEY, 1994):

$$a(\lambda) = \frac{\Delta A}{\Delta r} \quad \text{Eq. (05)}$$

$$b(\lambda) = \frac{\Delta B}{\Delta r} \quad \text{Eq. (06)}$$

A soma da absorção e espalhamento é chamada de atenuância que é expressa pelo coeficiente de atenuação ($C(\lambda)$) e representa a perda total de luz devido à combinação dos processos de espalhamento e absorção, onde A e B dependem do comprimento de onda e dos COA presentes na água (KIRK, 1994; MOBLEY, 1994) conforme equação 07:

$$C(\lambda) = a(\lambda) + b(\lambda) = \frac{\Delta A}{\Delta r} + \frac{\Delta B}{\Delta r} = \frac{\Delta C}{\Delta r} \quad \text{Eq. (07)}$$

Deste modo, o entendimento deste processo é fundamental para uma correta análise das propriedades dos corpos hídricos.

2.2.3 Propriedades Ópticas Aparentes

As Propriedades Ópticas Aparentes (POA) são aquelas que dependem das características do corpo d'água, da quantidade e da geometria do campo de luz, como por exemplo: a reflectância. Elas mostram suficiente estabilidade e regularidade, e podem ser utilizadas como descritores das propriedades da água. As POA de um mesmo alvo podem variar rapidamente sob influencia das condições ambientais como a cobertura de nuvens (MOBLEY, 1994; KIRK, 1994). Essas propriedades são facilmente medidas em campo, são fáceis de correlacionar com outros parâmetros e mostram feições suficientes para a descrição

de um corpo d'água, como: distribuição angular, coeficiente vertical de atenuação da luz e reflectância - de sensoriamento remoto e de irradiância/ volumétrica (MOBLEY, 1994; NASCIMENTO *et al.* 2011).

O estudo da reflectância dos alvos conta com duas principais grandezas: radiância e irradiância. A irradiância ($W.m^{-2}$) é a quantidade de energia eletromagnética incidente por unidade de área e de tempo sobre uma determinada superfície, pode ser ascendente e descendente dependendo da orientação do feixe. Já a Radiância ($W.m^{-2}. Sr^{-1}$) é a quantidade de fluxo radiante por unidade de ângulo sólido emitido por unidade de área, numa dada direção (KIRK, 1994).

A distribuição angular do fluxo de luz depende de duas propriedades: cosseno médio da irradiância descendente (E_d) e o cosseno médio da irradiância incidente (E_{d_0}). A razão entre E_d/E_{d_0} traduz o comportamento da distribuição do fluxo.

Já o coeficiente vertical de atenuação vertical difuso (K) representa a taxa de perda da irradiância (E) com a profundidade (z) e pode ser classificado em: ascendente (K_u) e descendente (K_d). Esses coeficientes variam em função do comprimento de onda e são obtidos, respectivamente, a partir da atenuação da irradiação ascendente (E_d) e descendente (E_u). O K_d é usado em modelos de penetração de luz na coluna d'água, estimar transparência e cálculos de índice de produtividade primária (MOBLEY, 1994; BARBOSA, 2005), de acordo com as equações 08 e 09:

$$K_d = \frac{dE_d}{dz}$$

Eq. (8)

$$K_u = \frac{dE_u}{dz}$$

Eq. (9)

Ao receber a irradiância do Sol e da atmosfera, os corpos d'água interagem com a energia eletromagnética surgindo alguns componentes radiométricos desta interação. As cores percebidas pelos sensores podem ser quantificadas por medidas de variações de radiância, de acordo com a equação 10:

$$L_t = L_d + L_u + L_v + L_b$$

Eq. (10)

Onde: L_t representa a radiância total ascendente saindo de um corpo d'água para um sensor remoto; L_d é uma função da radiância de espalhamento atmosférico; L_u da radiância de superfície da água; L_v a radiância volumétrica de subsuperfície e L_b da radiância de fundo.

Quando há interesse na identificação de constituintes opticamente ativos (COAs) a componente que fornece informações úteis é a radiância volumétrica (L_v) (KIRK, 1994).

A cor da água de qualquer profundidade é definida pelas variações de reflectância da superfície, obtida pela equação 11. A reflectância de irradiância (ou reflectância volumétrica) é o elo entre a radiância medida pelo sensor remoto e as propriedades da água. Trata-se da razão entre a irradiâncias ascendente (E_u) e a irradiância descendente (E_d). Ela independe das variações de ambientais como: iluminação, superfície da água e condições atmosféricas (DEKKER, 1993; MOBLEY, 1994).

$$R = \frac{E_u}{E_d} \quad \text{Eq. (11)}$$

A reflectância de sensoriamento remoto (R_{rs}), também conhecida como reflectância estimada, é obtida pela razão entre a radiância e a irradiância (. Os valores de R_{rs} são obtidos por meio da seguinte equação 12 (MOBLEY, 1994):

$$R_{rs} = \frac{L_u - (f * L_d)}{E_d} \quad \text{Eq. (12)}$$

Onde: L_u é a radiância ascendente da superfície da água; L_d é a radiância da atmosfera que é usada para corrigir os efeitos de espalhamento da radiação eletromagnética na interface ar-água; E_d é a irradiância descendente sobre a água de superfície; f é um fator proporcional que depende das condições ambientais e geralmente é usado o valor de 0,028.

Assim, com base nestas equações e com o uso de radiômetros/espectroradiômetros podemos identificar as relações radiométrica que permitiram identificar os componentes opticamente ativos.

2.3 COMPONENTES OPTICAMENTE ATIVOS

A energia eletromagnética que interage com um alvo é afetada pela natureza do objeto e do meio em que ela se propaga, o que justifica os comportamentos espectrais totalmente distintos da água dependendo do estado físico - sólido, líquido e gasoso (Figura 02), e dos componentes associados à água (material particulado ou dissolvido). Neste contexto, um dos maiores desafios no SR em águas interiores e costeiras é a separação espectral da água e seus componentes associados, que dão cor à água (NOVO 2001; NASCIMENTO *et al.* 2011)

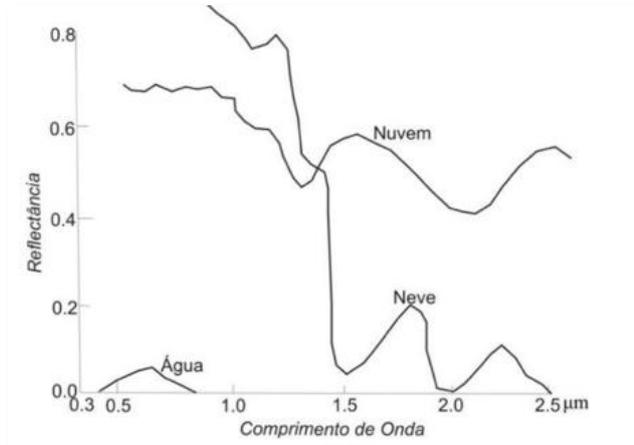


Figura 02: Comportamento espectral da água pura em de acordo com o estado físico. Fonte: Novo, 1992.

Na água “pura”, o comportamento espectral é caracterizado por baixos valores de radiância no intervalo de energia eletromagnética que vai de 400 nm até 700 nm, com o mínimo de absorção e espalhamento na região do azul (400 nm -500 nm). Porém, as águas naturais não são “puras”, mas sim uma mistura de água “pura” com diferentes compostos em suspensão ou dissolução (DEKKER, 1993; MOBLEY, 1994). Portanto, tem-se que a maior parte da radiação refletida corresponde às informações dos componentes opticamente ativos (COA) que estão presentes no corpo d’água que podem ser partículas inorgânicas e orgânicas em suspensão; componentes orgânicos em solução e pigmentos fotossintetizantes (Figura 03).

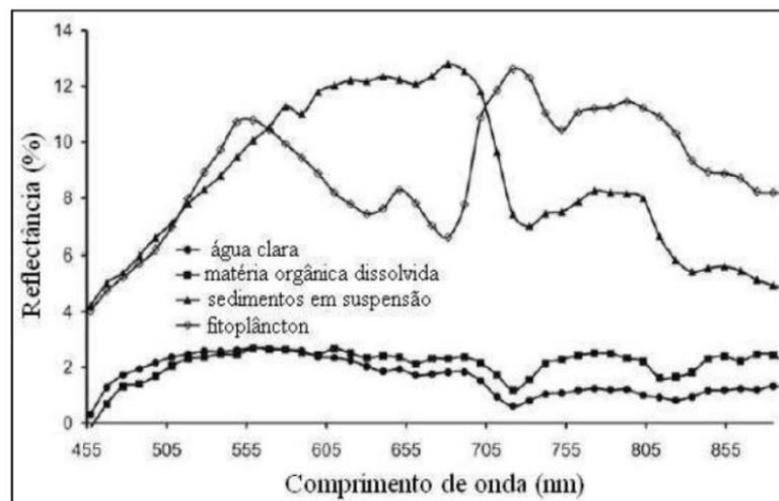


Figura 03: Comportamento espectral dos diferentes COA na água. Fonte: RUDORFF *et. al.*, 2007

Esta diferença entre a composição dos COA presentes na água se deve as propriedades ópticas inerentes de absorção e o espalhamento da radiação eletromagnética. As regiões de absorção e espalhamento no espectro das amostras estudadas irão determinar a curva de reflectância e a concentração desses elementos irá determinar a magnitude dessas feições na curva final (WOODRUF, 1999; NOVO, 2001; RUDORFF *et. al.*, 2007). A seguir serão apresentados COA que interferem nas cores das águas.

2.3.1 Pigmentos Fotossinteticamente Ativos

O fitoplâncton é capaz de sintetizar matéria orgânica a partir da fotossíntese (fotoautotróficos). Esses organismos são os principais responsáveis pela produção primária das células provocando mudanças no comportamento espectral da água, em geral, os pigmentos fotossintetizantes aproveitam a radiação da faixa do azul (400 a 500 nm) e do vermelho (600 a 700 nm) para o processo de fotossíntese (RUDORFF *et. al.*, 2007).

Dessa forma, águas com fitoplâncton apresentam maior absorção nessas faixas do que na região espectral do verde (500 a 600 nm), acarretando assim um decréscimo na quantidade de energia refletida nos comprimentos de onda do azul (400nm – 500nm) e do vermelho (675nm), pois os organismos fotoautotróficos utilizam a faixa do azul e do vermelho no processo de fotossíntese (JENSEN, 2009; MENESES, 2012).

2.3.2 Matéria Orgânica Dissolvida

A concentração de matéria orgânica dissolvida (MOD) é a fração que passa através do filtro de 0,45 μm e está relacionada com a atividade fotossintética ou de materiais continentais carregados para o corpo hídrico (como folhas de árvore levadas pela chuva, por exemplo). Trata-se de uma mistura de moléculas compostas de carbono (como carboidratos, aminoácidos, substâncias húmicas e flúvicas, colóides, dentre outros) proveniente da secreção, excreção e decomposição de organismos terrestres e aquáticos (WOODRUF, 1999; NOVO, 2001; RUDORFF, 2006).

Em altas concentrações, essas substâncias podem acarretar em mudança da cor da água tornando-a mais escura. Por exemplo, compostos húmicos na coluna d'água geralmente confere tonalidades amareladas em consequência da absorção da radiação na faixa espectral compreendida entre 390 e 550 nm. Em geral, o aumento da concentração de MOD resulta em

uma diminuição leve no valor de reflectância nos comprimentos de onda menores que 600 nm (região espectral do azul e verde) e variações pouco significativas nos valores de reflectância em comprimento de onda maiores de 600 nm (JENSEN, 2009; MENESES, 2012).

2.3.3 Sedimento em Suspensão

A produção e o transporte de sedimento em corpos hídricos é um processo natural responsável por transformações geomorfológicas, como a alimentação de praias e a formação de bancos de areia nos rios, por exemplo. Entretanto, o processo de produção e deposição pode ser influenciado negativamente pela atividade antrópica, uma vez que o excesso de sedimento em suspensão pode afetar a qualidade da água e gerar consequências no equilíbrio ambiental de vários processos na coluna d'água (SIVIERO & COIADO, 1999; PAIVA, 2003).

Em geral, os sedimentos em suspensão são provenientes da agricultura, desgaste do solo, erosão e intemperismo de rochas. Concentram-se em corpos d'água continentais (rios, lagos, estuários, entre outros) e em regiões costeiras influenciando, principalmente, no efeito de espalhamento da radiação na superfície dos corpos d'água. (JENSEN, 2009). Pois favorece o espalhamento da luz na superfície das águas e o aumento da reflectância na região do visível (vermelho) e infravermelho (RUDORFF, 2006), dificultando a penetração na água podendo acarretar em uma redução na atividade fotossintética e até mesmo na morte de indivíduos fotossintetizantes, aumentando a atividade de degradação da matéria orgânica acumulada na coluna d'água pelos organismos decompositores (que liberam toxinas nesse processo) e uma redução de oxigênio dissolvido nas camadas mais profundas. Isso prejudica os organismos aeróbios (como peixes e mamíferos) que podem morrer e aumentar ainda mais a quantidade de matéria orgânica no ambiente (ANDRADE *et al.* 2007).

Segundo Mobley, 2004, o parâmetro de Sólidos Totais em Suspensão é o conjunto de partículas em suspensão que ficam retidas no filtro de 45 μ m e podem apresentar partículas orgânicas e inorgânicas, entretanto os sedimentos em suspensão dominam essa fração. A influência da concentração de sólidos em suspensão (CSS) na resposta espectral da água é uma função da quantidade e das características do material na água, pois o aumento da CSS gera aumento da reflectância do volume da água e o deslocamento do máximo de reflectância em direção a comprimentos de onda mais longos (PISCOYA *et al.* 2013, MENESES, 2012).

A presença de sedimentos em suspensão na água aumenta a reflectância em todos os comprimentos de onda, como é possível perceber na figura 04, principalmente na faixa entre 500 e 700nm. Além disso, quanto maior a concentração de sedimentos, maior é a reflectância em comprimentos de onda maiores, como na faixa do infravermelho. Assim, segundo Jensen, 2009, a faixa do vermelho é ideal para obter informações a respeito do tipo de sedimento, enquanto a faixa do infravermelho é mais adequada para obter informações sobre a quantidade de sedimentos em suspensão. Entretanto, essa associação pode ser variável de acordo com as condições ambientais do corpo d'água em estudo (MENESES, 2013).

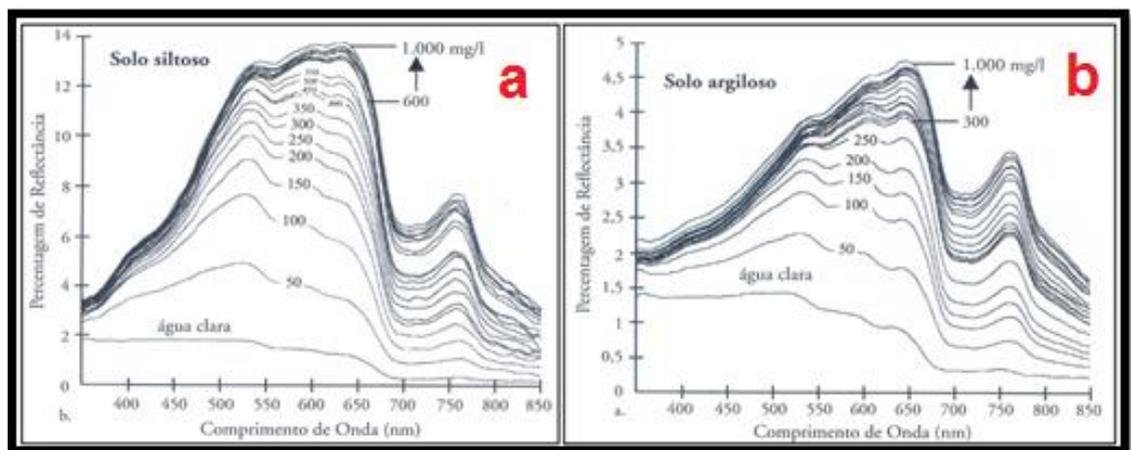


Figura 04: Comparação entre águas claras e águas com sedimentos siltosos (a) e argilosos(b). Fonte: Jensen, 2009

Devido à importância do conhecimento da CSS para análise de qualidade da água, o comportamento espectral de sólidos em suspensão tem motivado diversos pesquisadores que estudam essa relação entre sólidos em suspensão e reflectância de sensoriamento remoto. No mundo (Como por exemplo: BINDING *et al.*, 2005; CAI, TANG & LI, 2015; CHEN *et al.*, 2015; CHEN, HU & KARGER, 2007; DOXARAN *et al.*, 2002; DURAND, 2002; MOBASHERI & HAMID, 2004; ROBERT *et al.*, 2016; TARRANT *et al.*, 2010; WANG *et al.*, 2010 **a** e **b**; WU *et al.*, 2008). No Brasil, onde vários pesquisadores se dedicam a este tipo de estudo no país (como por exemplo: ALCÂNTARA, CURTARELLI & STECH, 2016; BERNARDO & ALCÂNTARA, 2017; MARTINEZ *et al.*, 2009; PINTO *et al.*, 2014; PISCOYA *et al.*, 2013 E 2014; VILLAR *et al.*, 2012 e 2013).

BINDING *et al.*, (2005) ;usaram a reflectância de banda única (665 nm) em comprimentos de onda visíveis para a derivação de concentrações de sedimentos em

suspensão no Mar da Irlanda. Observaram um relacionamento forte entre a reflectância da e sedimentos em suspensão. Os autores destacam a necessidade de uma compreensão completa das propriedades de espalhamento das partículas, a fim de estimar com precisão as concentrações de MSS a partir de medições de reflectância.

CHEN *et al.*, 2015; avaliaram o desempenho do modelo de recuperação TSS (Sólidos Totais em Suspensão) baseado dados MODIS para desenvolver o modelo de concentrações de TSS de amplo alcance. Usando dados de espectro de campo e TSS (5.8-577.2 mg / L) coletados do estuário e costa da China. Aplicaram seis modelos de recuperação de TSS em formas de banda única (B1 ou B2), Diferença das duas bandas, índice de sedimentos, taxa de banda e log-ratio pela técnica de mínimos quadrados. Os resultados mostraram que o modelo quadrático de log-ratio é da melhor precisão e que os valores da razão logarítmica aumentaram com o aumento de TSS.

DOXARAN *et al.*, 2002; investigaram a determinação da composição da água a partir de dados de satélite de "cor do oceano", em comprimentos de onda visíveis e de infravermelho próximo (NIR), em águas altamente turbulentas no estuário de Gironde, para uma faixa de concentração entre 35-2000 mg/L. As relações empíricas são estabelecidas entre a reflectância de detecção remota (Rrs) nas bandas SPOT-HRV e medições *in situ*. Eles observaram que a reflectância de sensoriamento remoto aumenta com a concentração de sólidos em suspensão com uma precisão superior a $\pm 35\%$.

ROBERT *et al.*, 2016; estudaram o reservatório do Lago Bagré, em Burkina Faso, relacionando dados MODIS nas bandas do vermelho e do infravermelho próximo para monitorar turbidez e sólidos em suspensão. Verificaram que a relação NIR / R é considerada a mais adequada para recuperar grandes concentrações de sólidos em suspensão e alta turbidez a partir de medições radiométricas *in situ* e a reflectância do satélite de MODIS.

TARRANT *et al.*, 2010; consideraram a possibilidade de usar dados MODIS e MERIS, para monitorar os níveis de sólidos em suspensão em lagos e reservatórios pequenos e intermediários em quatro lagos do sudoeste dos Estados Unidos: Lago Roosevelt, Lago Saguario, Lago Bartlett e Lago Pleasant. Na análise de regressão do conjunto de dados completo identificou uma relação linear entre os valores sólido em suspensão de campo e os dados MODIS e MERIS. Sugerindo que esses sensores de satélite têm o potencial de controlar eficazmente sólidos em suspensão em lagos e reservatórios

WANG *et al.*, (2010b), investigaram o potencial de estimar o sólidos em suspensão de grandes rios usando dados MODIS nos cursos médio e baixo do rio Yangtze. Eles verificaram

que a diferença de reflectância da água entre as Bandas 2 e 5 forneceu uma estimativa de concentração de sólidos em suspensão é relativamente precisa com 29,7% de erro quadrático médio relativo. Os erros foram menores para maiores valores de concentração de sólidos em suspensão. Assim, constataram que o MODIS apresenta um potencial que poderia ser empregado para estimar a concentração de sólidos em suspensão com frequência para grandes sistemas de rio turvo.

BERNARDO & ALCÂNTARA, 2017; compararam dois conjuntos de dados de reflectância a fim de avaliar qual o mais adequado para a recuperação de concentração de sólidos totais em suspensão: um de imagem corrigida atmosférica de Operational Land Imager (OLI) / Landsat-8 e Rrs superfície amostras recolhidas *in situ*. As estimativas de sólidos totais em suspensão foram feitas utilizando o modelo empírico, e os resultados demonstram que os métodos não estatísticos fornecem os erros mais baixos para estimar a concentração de sólidos totais em suspensão se comparados às imagens corrigidas.

PINTO *et al.*, 2014; monitoraram o fluxo de entrada de sedimentos no braço do Rio Indaiá no reservatório de Três Marias, MG, com base em dados das imagens MODIS. Os resultados apontaram uma forte relação entre os dados de reflectância e a descarga sólida calculada no Rio Indaiá. O percentual de registros válidos estimados nas imagens MODIS atendeu aos requisitos de monitoramento do fluxo de sedimentos enquanto as estimativas de reflectância da água mostraram grande potencial em relacionar as respostas espectrais das imagens de satélites com a variação da descarga sólida de sedimento no braço do Rio Indaiá.

VILLAR *et al.*, (2013a) utilizaram dados MODIS, medidas de campo da concentração de sedimentos em suspensão, radiometria espectral e granulometria para analisar os processos de transporte de sedimentos em suspensão ao longo do tronco principal do rio Madeira. Observaram que a relação entre as bandas vermelho e infravermelho próxima independem da sazonalidade das condições ambientais. Os pesquisadores desenvolveram um modelo de recuperação de concentração de sedimentos em suspensão a partir dos dados do satélite usando uma técnica de reescalonamento do bootstrap. Os dados do satélite calculados para analisar o padrão de concentração de sedimentos em suspensão temporariamente e espacialmente ao longo de todo o rio Madeira, o que forneceu evidências de sedimentação significativa e resuspensão.

VILLAR, R. A.E (2013,b) em estudo na bacia amazônica verificaram que a principal desvantagem da utilização de sensores ópticos nesta região é a grande quantidade de nuvens, mas este problema pode ser solucionado com a utilização de imagens de alta resolução

temporal. Realizando a estimativa de sólidos em suspensão via sensoriamento remoto a partir dos dados MODIS, identificaram um erro médio quadrático entre 30 e 40%. Já com a utilização da radiometria de campo, este erro diminui cerca de 23%.

Estas pesquisas demonstram o potencial e a eficiência do uso de sensores remotos para o monitoramento de sedimentos e sólidos totais em suspensão na água em diferentes regiões do planeta, com diferentes condições ambientais, a partir das propriedades ópticas da água e de seus componentes opticamente ativos. Hooper (1997) reporta que a eficiência do monitoramento hidrológico é função do número de parâmetros, da frequência e da distribuição espacial das medições na bacia. Isso gera altos custos e abrange uma amostragem espacial mínima, diminuindo a possibilidade de uma avaliação mais precisa. GEMS (2013) em um estudo de revisão em escala global, estimou que três quartos do planeta não tem um monitoramento da qualidade das águas adequado e que este cenário não será alcançado em um futuro próximo.

2.4. MONITORAMENTO DE QUALIDADE DE ÁGUA

A gestão dos recursos hídricos requer um acompanhamento sistemático da qualidade da água. Os corpos hídricos devem ser amplamente monitorados no espaço e no tempo. Pois, a capacidade de um órgão gestor de recursos hídricos para tomar decisões está associada ao conhecimento do estado do meio ambiente (SILVA, 2007). Assim, o planejamento, o gerenciamento e o monitoramento de recursos hídricos necessitam de dados constantemente atualizados.

No Brasil, a ANA lançou o Programa Nacional de Avaliação da Qualidade das Águas (PNQA). Com o intuito de solucionar problemas que influenciam diretamente na gestão dos recursos hídricos do país como, por exemplo, a existência de lacunas geográficas e temporais de dados; a falta de padronização e de informações sobre a realização de coletas e análises laboratoriais. Nesse sentido, a ANA firmou acordos de cooperação técnica com os 27 estados visando oferecer a sociedade conhecimento sobre a qualidade da água e subsidiar tomada de decisões relacionadas aos recursos hídricos (ANA, 2013).

Atualmente, a ANA é responsável pelo gerenciamento e planejamento de cerca de 4.530 estações divididas em 1.828 estações fluviométrica; 2.701 estações pluviométricas. Os dados coletados são utilizados para realizar estudos que subsidiam a definição de políticas públicas e a tomada de decisões. A ANA vem desenvolvendo esforços para aumentar a rede

de medições de qualidade de água à Rede Hidrometeorológica Nacional. Nesse cenário, a ANA lançou a Rede Nacional de Monitoramento de Qualidade das Águas (RNQA), com aproximadamente 5.000 pontos de coleta, que visa aumentar a quantidade de informações sobre as condições das águas superficiais do País (ANA, 2013).

Nesse contexto, o monitoramento da qualidade de águas naturais acompanha alterações das características da água. A análise laboratorial consiste em examinar amostras de água para determinação de aspectos e parâmetros de qualidade da água como: físicos, químicos, biológicos e geológicos do corpo hídrico (BERTHOLDO *et al.* 2013). Estas análises são baseadas nas normas da Resolução CONAMA 357/2005 que dispõe sobre a classificação dos corpos hídricos, estabelece condições e padrões de lançamento de efluentes, bem como define cinco classes para as águas doces onde cada classe apresenta um conjunto de condições e padrões de água necessários ao atendimento dos usos (CONAMA, 2005). Entretanto, essa abordagem mais tradicional demanda um alto custo de operação e não contempla amplas regiões do país. Nesse contexto, o sensoriamento remoto se insere como uma ferramenta adicional na aquisição de informações sobre os recursos hídricos, facilitando a coleta de dados, possibilitando o monitoramento da variabilidade das características da água fornecendo informações com precisão e a baixo custo (JENSEN, 2009).

Neste sentido, pesquisadores brasileiros já utilizam sensoriamento remoto como ferramenta de auxílio no monitoramento de qualidade de águas continentais (rios e reservatórios). Há uma série de trabalhos (MARTINEZ *et al.*, 2009; PINTO *et al.*, 2014; PISCOYA *et al.*, 2013 E 2014; VILLAR *et al.*, 2012 e 2013) desenvolvidos por grupos de pesquisadores que utilizam radiômetros de campo do mesmo modelo e marca (RAMSES-TriOS), porém sem protocolo unificado de aquisição, tratamento, organização e armazenamento.

Sabe-se que o uso de sensoriamento remoto para obter parâmetros das águas superficiais continentais facilita o monitoramento da qualidade das águas e pode complementar os dados adquiridos pela rede de estações de monitoramento das águas continentais brasileiras, além de ampliar a espacialização de amostras em lagos, reservatórios e rios. Entretanto, ao utilizar essas técnicas é necessário estabelecer um padrão de coleta, avaliação e organização dos dados. Assim, para amostrar dados de confiança e garantir que as informações de campo (do alvo e do ambiente) sejam armazenadas de forma segura e eficiente é aconselhado seguir os protocolos que irão padronizar e facilitar a manipulação de dados adquiridos pelos mais diversos profissionais das mais diversas áreas de estudo.

Nesse sentido, a elaboração de protocolos (de campo, de laboratório e de processamento, organização e armazenamento dos dados), pode contribuir para a construção de uma base de dados consolidada torna-se uma importante ferramenta de monitoramento e gestão dos recursos hídricos em nível nacional, subsidiando a tomada de decisão de órgãos ambientais e facilitando pesquisas científicas.

CAPÍTULO 3 – MATERIAL E MÉTODOS

Neste capítulo serão apresentadas as áreas de estudo e as etapas seguidas para o desenvolvimento de toda a pesquisa. Todas as etapas foram desenvolvidas no Laboratório de Sensoriamento Remoto e Análise Ambiental do Instituto de Geociências da Universidade de Brasília e os dados foram coletados por diversos pesquisadores ligados aos projetos REGEST, AQUASENSE, SAMSAT, MEGHYBAM, OEG, IHESA e pela CPRM.

3.1 ÁREA DE ESTUDO

Como informado anteriormente neste trabalho iremos utilizar um conjunto de dados levantados pela por equipes de pesquisa vinculadas aos projetos supracitados em várias bacias hidrográficas da América do Sul (Brasil, Peru, Bolívia e Guiana Francesa - Figura 05 a e b) e do Oeste da África (Burkina Faso). A seguir esta uma apresentação sintética das bacias estudadas.

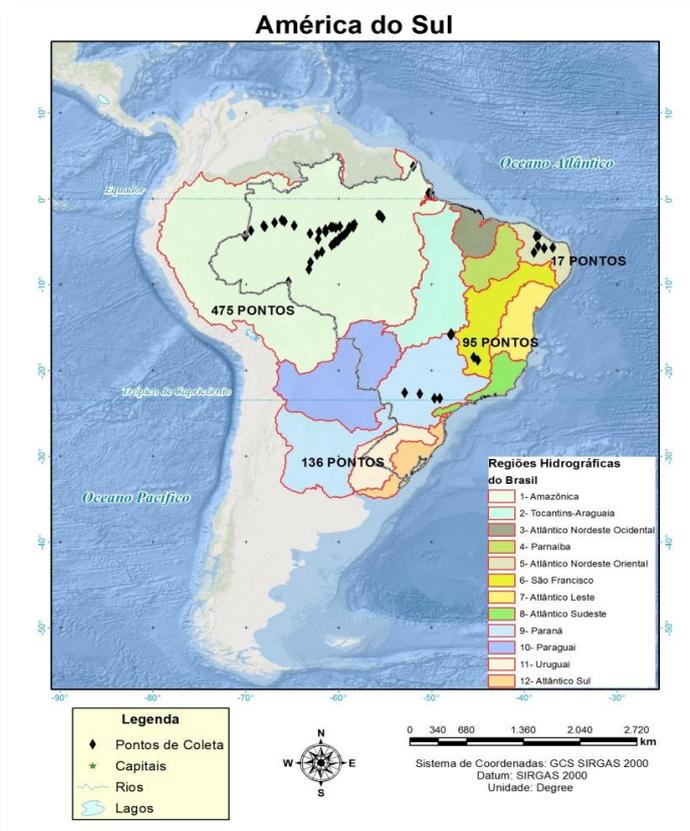


Figura 05a: Mapa de distribuição dos pontos de coleta radiométricos e de qualidade de água na América do Sul.

O Brasil é o maior país da América do Sul e posição privilegiada no mundo com relação à disponibilidade hídrica. Ocupando quase metade da superfície do continente, sendo recoberto pelas principais bacias hidrográficas que são: Amazonas, Paraná, Tocantins, e São Francisco. Para facilitar o planejamento e o gerenciamento destes recursos o Plano Nacional de Recursos Hídricos realizou uma divisão do país em 12 regiões hidrográficas de acordo com as principais bacias hidrográficas brasileiras (ANA, 2007).

A região Hidrográfica Amazônica abrange os estados do Acre, Rondônia, Roraima, Amapá, Amazonas, parte do Mato Grosso e Pará. Nela encontramos a Bacia Amazônica, considerada a maior bacia hidrográfica do planeta. Esta, se estende por mais de $6 \times 10^6 \text{ km}^2$ desaguando no Oceano Atlântico com vazão média de $206.000 \text{ m}^3/\text{s}$, o que representa cerca de 15% das águas continentais que chegam aos oceanos (CALLÈDE *et al.* 2010). As campanhas realizadas concentram-se nos rios Solimões (101 amostras), Madeira (145 amostras), Purus (32 amostras) e Amazonas (118 amostras).

Nessa região, também se encontra a bacia do rio Maroni que ocupa a parte ocidental da Guiana Francesa e faz fronteira com o Suriname. O rio tem cerca de 400km de comprimento e drena uma área de aproximadamente 60.000 km^2 . O canal principal é formado pela junção de dois rios: rio Lítania e rio Marouini. Seus principais afluentes da margem direita são Tampock, Inini e Abounami; e na margem esquerda o rio Tapanahoni (NÉGREL & LACHASSAGNE, 2000). No rio Maroni foram coletadas 52 amostras, totalizando, assim, 475 pontos na Região Hidrográfica Amazônica.

A Região Hidrográfica do Paraná tem grande importância para as regiões Sul, Sudeste e Centro-Oeste do Brasil, pois além de conter um grande número de usinas hidroelétricas é responsável pela irrigação de uma grande área agrícola (ANA, 2007). Os estudos nesta Bacia estão restritos a poucos pontos ao longo dos reservatórios do rio Paranapanema (40 amostras) e no Lago Paranoá (96 amostras), totalizando 136 pontos.

A Região Hidrográfica do São Francisco (RSF) recebe este nome, pois tem como principal bacia a do rio São Francisco que nasce em Minas Gerais a 1.800 m de altitude e percorre uma extensão aproximada de 2.700 km, atravessando vários estados até desembocar no Oceano Atlântico Sul, na divisa entre os Estados de Sergipe e Alagoas, nordeste do Brasil. Trata-se da bacia mais extensa exclusivamente brasileira. O RSF é de médio o grande porte e possui relevância ecológica, econômica e social para a região, sendo dividido em Alto, Médio, Submédio e Baixo São Francisco (MEDEIROS *et al.* 2014). Para esta região foram coletadas 95 amostras no reservatório de Três Marias.

A Região Hidrográfica Atlântico Nordeste Oriental abrange os Estados do Ceará, Rio Grande do Norte, Paraíba, Pernambuco e Alagoas (ANA, 2007). As áreas estudadas estão restritas aos reservatórios do Castanhão, Orós, Pedras Brancas, Aracoiaba, Umari e Armando Ribeiro, totalizando 17 amostras.

O lago Bagré pertence ao rio Nakambe e está situado na bacia hidrográfica do rio Volta, no centro da região leste de Burkina Faso, África. O reservatório estudado é o segundo maior de Burkina Faso, abrange uma área média de 20.000ha, com um volume aproximado de 1,7 bilhões de m³. Estudos detalhados dessa região mostram uma variação de turbidez devido ao aumento de uso dos solos (cultivo e degradação) próximos ao reservatório (ROBERT *et al.* 2016). Nesse reservatório foram coletados 27 pontos.

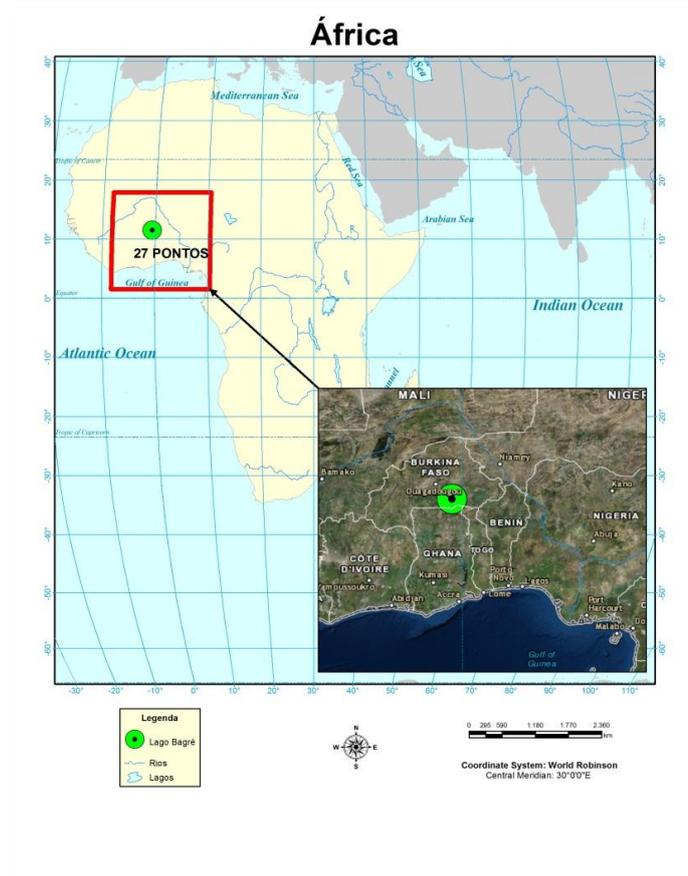


Figura 05b: Mapa de distribuição dos pontos de coleta radiométricos e de qualidade de água, Lago Bagré.

3.2 AQUISIÇÃO, PROCESSAMENTO E ANÁLISE DE DADOS

A quantificação dos fluxos de sedimentos em suspensão na água é importante para várias disciplinas ambientais. Assim, para alcançar os objetivos propostos o trabalho foi desenvolvido em quatro grandes etapas: 1) Campo - envolvendo coleta de água e de dados radiométricos, já realizados por outros pesquisadores (Tabela 01); 2) Laboratório - envolvendo medição de concentração de sólidos em suspensão; 3) Construção do banco de dados, envolvendo: exportação, pré-tratamento, interpolação, organização e armazenamento de dados; e por fim, 4) Análise dos dados. A Figura 06 apresenta um fluxo dos trabalhos desenvolvidos.

Tabela 01: Quantificação de pontos por bacia e pesquisadores que colaboraram com dados.

TRABALHOS	REGIÃO	Nº DE PONTOS	CSS Mín.	CSS Máx.
Espinoza & Roig 2015, Olivetti et al. 2016	Paranoá	96	0.2	32.2
Piscoya et al. 2016	Paranapanema	40	0.5	35.2
Piscoya não publicado, Menezes 2013	São Francisco	95	0.2	302.7
Espinoza et al 2013, Martinez et al. 2015	Madeira	145	25.2	971.8
Martinez et al. 2015, Pinet et al. 2017	Solimões	101	1.6	432.4
Martinez et al. 2015	Amazonas	118	2.4	282.0
Martinelli 2015, Martinelli et al. 2017	Purus	32	3.6	90.5
Gallay 2017	Maroni	52	18.0	53.9
Robert et al. 2016, Pinet 2017	Bagré	27	51.0	596.7
Ventura 2013	Açudes do Nordeste	17	2.2	29.6
-	TOTAL	723	-	-

Todas estas etapas envolvem a coleta e o processamento dos dados de reflectância (coletados em campo) e os de concentração de sólidos em suspensão (medidos em laboratório). Os dados obtidos por esta equipe foram compilados e totalizam 723 pontos de coleta de radiometria e concentração de sedimento em suspensão em bacias com diferentes características ambientais (Figura 06).

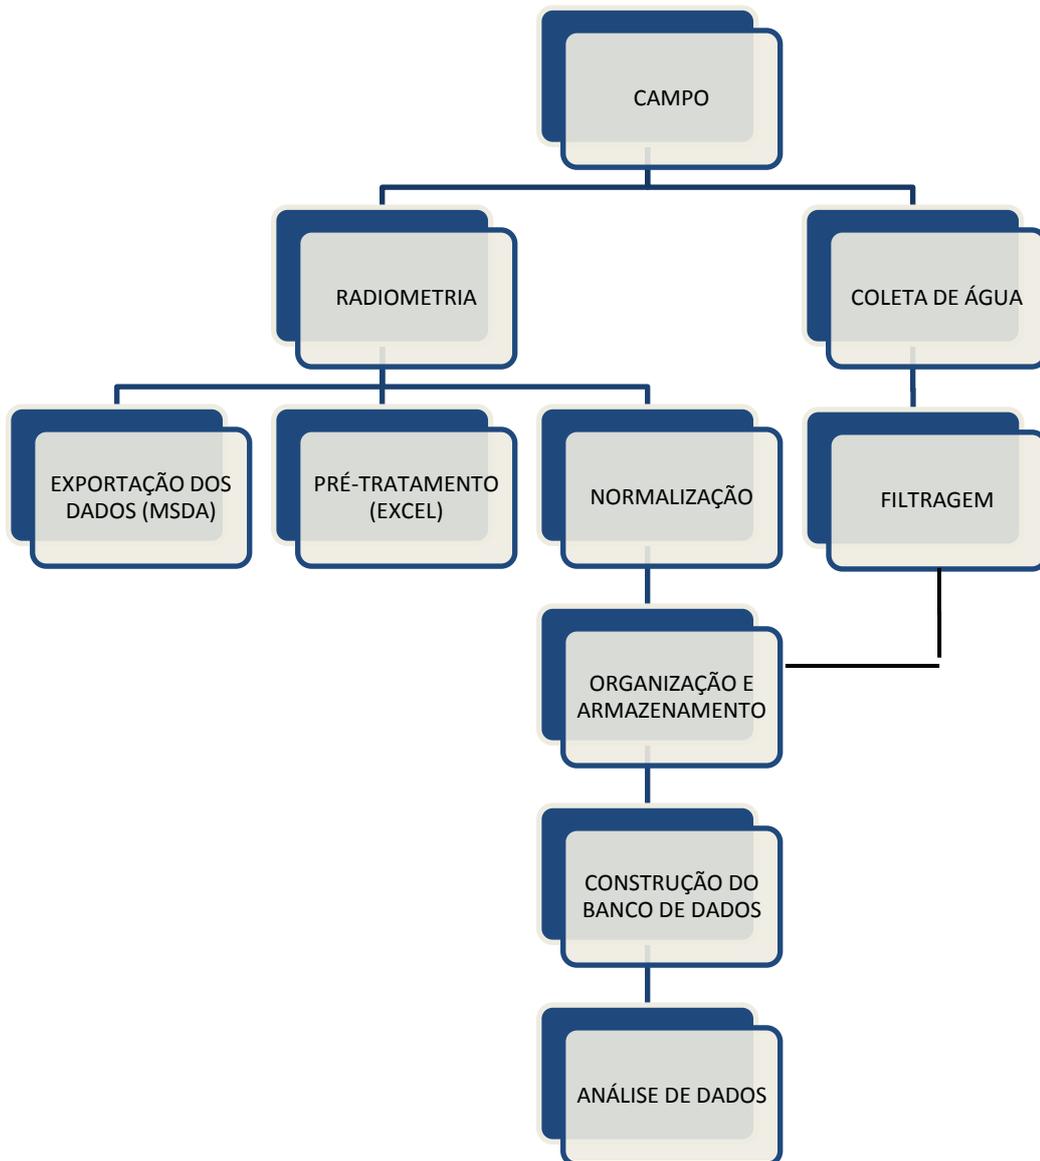


Figura 06: Fluxograma das atividades envolvidas no trabalho

3.2.1 Levantamentos de dados

Os dados de radiometria foram coletados seguindo um protocolo estabelecido e utilizado em todas as campanhas de campo realizadas pelos projetos citados anteriormente. Já para sedimentos em suspensão a metodologia variou de acordo com as condições hidrológica da região de modo garantir a representatividade e qualidade dos dados. Embora esta não tenha sido uma etapa realizada efetivamente nesta pesquisa, é importante conhecer o processo de coleta e processamento das amostras.

3.2.1.1 Campo

Os dados levantados em campo foram divididos em dois grupos: coleta do material em suspensão e aquisição das propriedades ópticas da água por meio de espectrorradiometria de campo. Sempre que possível, as amostragens foram realizadas, nos diferentes períodos do ciclo hidrológico, buscando o entendimento dos processos de transporte ao longo deste ciclo o que gerou boa representatividade da variabilidade da carga sedimentar em cada rio/reservatório amostrado.

3.2.1.1.1 Radiometria

O uso da radiometria de campo é importante para entender as variações das propriedades ópticas da água. A integração de dados de radiometria de campo com imagens de sensores orbitais possibilita uma visão sinóptica de fenômenos que ocorrem da superfície do corpo hídrico (BARBOSA, 2005; ALCÂNTARA, E., CURTARELLI, M., & STECH, 2016). Segundo Metthew *et al.*, 2011, os espectroradiômetros portáteis (como por exemplo, o RAMSES da TriOS) são muito utilizados para validar informações de sensores orbitais e de algoritmos empíricos. Nesta pesquisa, todas as coletas de espectradiometria foram realizada com os espectroradiômetros TriOS – RAMSES (Figura 07), que operam nas faixas espectrais do ultravioleta, visível e o infravermelho próximo (320-950 nm) com a seguinte geometria (Figura 08), conforme proposto Villar *et al.*, 2013.



Figura 07: Disposição dos sensores em campo. No centro o sensor de irradiância e ao lado o sensor de radiância.

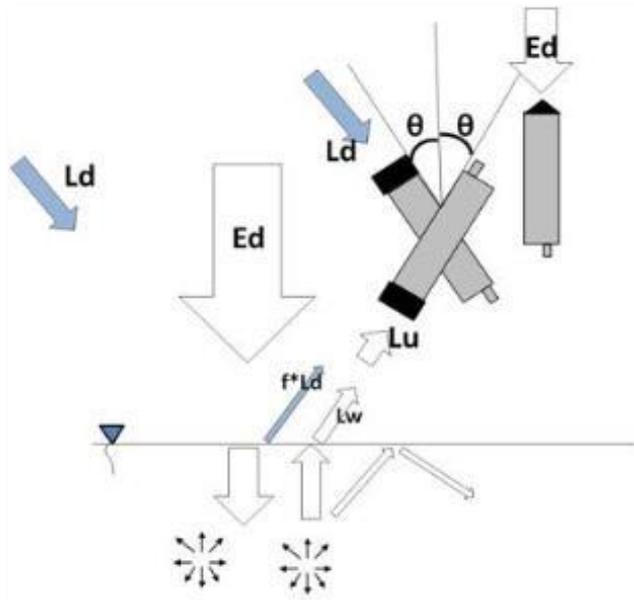


Figura 08: Disposição dos sensores em campo.

A reflectância de sensoriamento remoto é calculada usando três radiômetros diferentes: 1- Um sensor de radiância aponta para o céu (na vertical) que mede a intensidade da luz de subsidência (L_d); 2- Um sensor de radiância aponta para a água (com 30° com a vertical) que mede a intensidade da luz de ressurgência (L_u); 3- Um sensor de irradiância aponta para o céu (com 30° da vertical) que mede a intensidade da luz subsidência (E_d). Estes dados são coletados em campo e armazenados automaticamente em uma base de dados

Access gerada pelo software MSDA_XE, software este disponibilizado pela empresa fabricante dos sensores. Posteriormente, estes dados serão utilizados para o cálculo da reflectância de sensoriamento remoto (Eq.12).

3.2.1.1.2 Coleta de água

As amostras da mistura água/sedimentos na superfície dos corpos hídricos para análise de sólidos em suspensão (orgânicos e inorgânicos) foram coletadas usando garrafas de 500 ml ou 1 litro dependendo dos campos (Figura 09). A coleta era feita durante ou imediatamente após a medição radiométrica.



Figura 09: Coleta e condicionamento de amostra de água.

3.2.1.2 Laboratório

Embora esta não tenha sido uma etapa realizada pela mestrandia, é importante conhecer o processo de processamento das amostras. Para o caso da determinação da concentração de sólidos em suspensão, seja em laboratório ou embarcado, foram realizados segundo o procedimento padrão estabelecido por Carvalho *et al.*, (2000) e utilizado pela ANA. Foram utilizados: bomba de vácuo; provetas de vidro graduadas (1000mL); peseta; água destilada; filtros de acetato de celulose devidamente pesados (0,45 μ m), pinça; placas de Petri; papel de alumínio; etiquetas e mangueiras de condução da água pelo sistema de filtragem.

Para as determinações de concentração das amostras coletadas foram utilizadas membranas de malha 0,45 μ m e uma “rampa” de filtragem que variavam de três a seis recipientes com capacidade de 250mL (podendo passar até 1000 ml para águas com baixas

concentrações de material em suspensão), ambos da marca Millipore, ligados a um sistema de bomba de vácuo (Figuras 10).



Figura 10: sistema de filtragem de amostras de campo.

Antes de iniciar o processo de filtração as membranas foram aquecidas a 105°C por 1h e pesadas antes e após a filtragem para determinação do peso de SS filtrado, em seguida, foram armazenadas em placas de Petri e etiquetadas, A concentração foi obtida utilizando-se razão entre a massa de sedimento e o volume de água filtrado, dividindo-se a diferença do peso final (Pf) e iniciais (Pi) das membranas pelo volume da amostra. O resultado obtido descreve a razão entre a massa de sedimento e o volume da mistura Água-sedimento, de acordo com a seguinte equação (13):

$$\text{Concentração} \left(\frac{\text{mg}}{\text{L}} \right) = \frac{\text{Pf}(\text{mg}) - \text{Pi}(\text{mg})}{V(\text{L})} \quad \text{Eq. (13)}$$

Vale ressaltar que é de suma importância que os procedimentos adotados sejam os mesmos, visando diminuir as incertezas na etapa de comparação e junção dos dados.

3.3 ORGANIZAÇÃO DA BASE DE DADOS

Após toda a parte de aquisição os dados nos projetos originais eram guardados em planilhas **Excel**® individuais e armazenados pelos membros do grupo de pesquisa que os coletaram. Deste modo, o primeiro passo foi juntar todos os dados e iniciar o processo de organização e padronização para o processo de construção do banco de dados.

O primeiro passo do tratamento dos referidos dados radiométricos consiste da exportação dos arquivos Lu, Ld e Ed, separadamente, do software MSDA_XE para o **Excel®**. Estes dados passaram, inicialmente, por um processo de filtragem/pré-seleção com vista à retirada dos dados espúrios com muito ruído. Em seguida estes dados foram exportados para o programa R (Figura 11), um software livre (<http://www.r-project.org/>), para o ajuste das bandas espectrais foi realizado por interpolações (padronização dos comprimentos de ondas) e cálculos estatísticos, uma vez que os intervalos dos dados variam ligeiramente de um radiômetro para outros (Apêndice A).

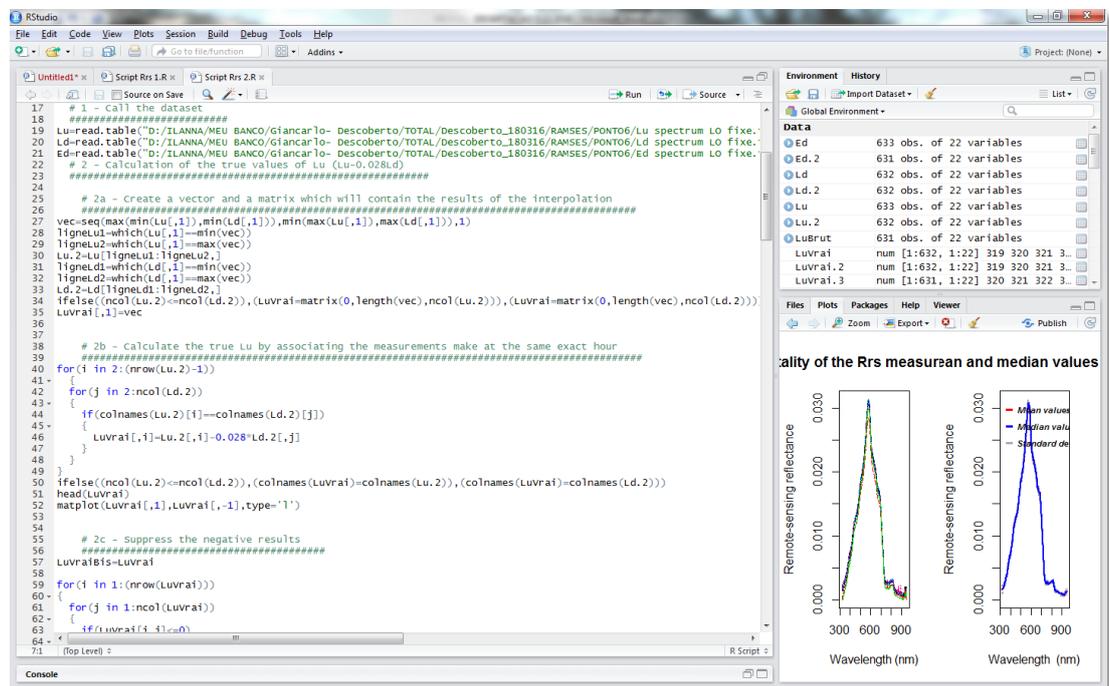


Figura 11: Interface do programa R durante o processamento dos dados.

No programa R, a primeira rotina (Apêndice B) converte os dados o valor radiométrico para cada banda (comprimento de onda específico). Na segunda fase, outra rotina (Apêndice B) realiza o cálculo de reflectância e das estatísticas básicas (Média e desvio padrão). Os dados foram normalizados de maneira que todos mantivessem a mesma resolução radiométrica desde 320 nanômetros (nm) até 950 nm, em intervalos de 1 nm.

Finalizada esta etapa, os dados retornaram para o programa **Excel®** para o armazenamento do dado normalizado. Em seguida, os dados serão analisados estatisticamente para a verificação das suas relações com a concentração dos sedimentos. Ao final deste processo o banco de dados passou a conter 723 pontos, Os pontos foram nomeados de acordo

com as siglas adotadas pelo pesquisador que os coletaram, com vista a não perder a sua fonte. Para cada ponto foi realizada a identificação do código do sensor utilizado para a coleta. Foi criada uma planilha para cada parâmetro (reflectância, CSS) dentro de uma pasta de trabalho referente à base de dados.

3.4 ANÁLISE DE DADOS

Inicialmente foi verificada a existência ou não de correlação linear entre as variáveis CSS e os dados radiométricos. Em seguida, partindo da hipótese de que os dados apresentam uma distribuição normal, foi realizado o teste de normalidade dos dados para verificar se as variáveis aleatórias realmente apresentam uma distribuição normal por meio de histograma. Por fim, foi realizada a análise dos resíduos para investigar se o modelo está adequado ou não para as variáveis analisadas.

Existindo correlação entre as duas variáveis foram realizados teste de regressão, consideramos dois tipos de modelos empíricos para relacionar a reflectância a concentração medida *in situ* :

- 1) LINEAR, dado pela equação 14 :

$$\text{CSS} = b + a * (\text{Rrs}) \quad \text{Eq.14}$$

Onde “b” é o coeficiente linear (ou intercepto, é o valor que y assume quando x for zero) e “a” é coeficiente angular (é a inclinação da reta, mede o aumento ou redução em y para cada aumento de uma unidade em x).

- 2) POTÊNCIA , dado em escala logarítmica pela equação 15 :

$$\text{CSS} = a * (\text{Rrs})^b \quad \text{Eq.15}$$

Onde o “b” passa a ser o coeficiente angular e o “a” passa a ser o coeficiente linear.

Para a determinação dos parâmetros das regressões entre CSS e Rrs, foram realizadas reamostragens (com 1000 interações) a partir de sorteios aleatórios repetidos dentro do conjunto de pontos de tamanho igual ao da amostra original com reposição da mesma por meio do método bootstrap. Neste método, as reamostragens de uma mesma amostra permitem

o aumento da representatividade estatística de amostras muito pequenas, gerando um valor médio dos coeficientes angulares e lineares, além do desvio-padrão para cada coeficiente, e um intervalo de confiança a 68%. Promovendo calculos de desvios-padrões mais confiáveis. O método não acrescenta nenhuma informação nova a amostra inicial, ele apenas emprega a média das reamostras para estimar como a média amostral de uma amostra inicial de tamanho N se comporta e avaliar como ela varia em decorrência de uma amostragem aleatória (EFRON & TIBSHIRANI, 1994).

Para cada conjunto reamostrado uma regressão é calculada, tendo ao final a média das 1000 regressões com os parâmetros ajustados. A dispersão dos pontos apresentada nos gráficos de distribuição gerados pelos modelos referem-se à média das 1000 reamostragens. Este método também permitiu o cálculo da Raiz do Erro médio Quadrático normalizado (RMSE%) para cada ponto de análise (todos os procedimentos foram executados no software de R). Embora não haja na literatura nada afirmando, o RMSE% é considerado (de maneira empírica) aceitável quando até 30% para análises sedimentométricas. Nesta pesquisa o RMSE% será usado como a base para as interpretações dos dados e resultados.

Foram realizados testes de regressão para diferentes comprimentos de ondas a fim de avaliar o comportamento espectral do sedimento em suspensão e perceber qual o melhor comprimento de onda para o estudo desse componente opticamente ativo nas diferentes regiões de estudo visando identificar o quanto o modelo consegue explicar os valores observados nos gráficos. Os testes de regressão foram aplicados na Amostra Global (contendo todos os pontos da mesma faixa de concentração) e de maneira individual (por bacia). Foram testados oito comprimentos de onda (500 nm, 650 nm, 740 nm, 783 nm, 800 nm, 865 nm, 900 nm, 940 nm) e quatro razões de bandas (865/650 nm, 800/650 nm, 940/650 nm, 940/865 nm).

A escolha dos comprimentos de onda e das razões de bandas se deu com base nos comprimentos de onda mais usados para análise de qualidade da água por sensoriamento remoto. Sabe-se que a obtenção de informações sobre os sólidos em suspensão na superfície da água via sensoriamento remoto é mais eficiente na faixa do infravermelho próximo, entre 700 a 900nm (RITCHIE *et al.*, 1976; LODHI *et al.*, 1998). Por isso a faixa do infravermelho é mais utilizada para obtenção da concentração de sólidos em suspensão. Além disso, tomou-se por base o centro de bandas das faixas do vermelho e infravermelho dos sensores orbitais Sentinel-2, Modis e Landsat 8, muito usados para análise de qualidade da água.

CAPÍTULO 4 - RESULTADOS E DISCUSSÃO

4.1 RESULTADOS

Para a realização deste trabalho foi utilizado um grande volume de dados (723 pontos) e análises. Portanto, optou-se por apresentar os principais resultados nesta sessão, pois não seria viável a disposição de todos os resultados neste documento. A intenção é mostrar coerência entre a ideia principal da pesquisa, os resultados e as conclusões. Os resultados serão apresentados na seguinte sequência: Escolha do modelo; Aplicação dos modelos; Coeficientes angulares e lineares.

4.1.1 Banco de dados consistido

O primeiro resultado deste trabalho foi à montagem de uma base de dados consistida. Onde todos os dados de radiometria estão dispostos de 1 em 1nm e estão passíveis de comparação entre os diferentes corpos d'água (Figura 12)

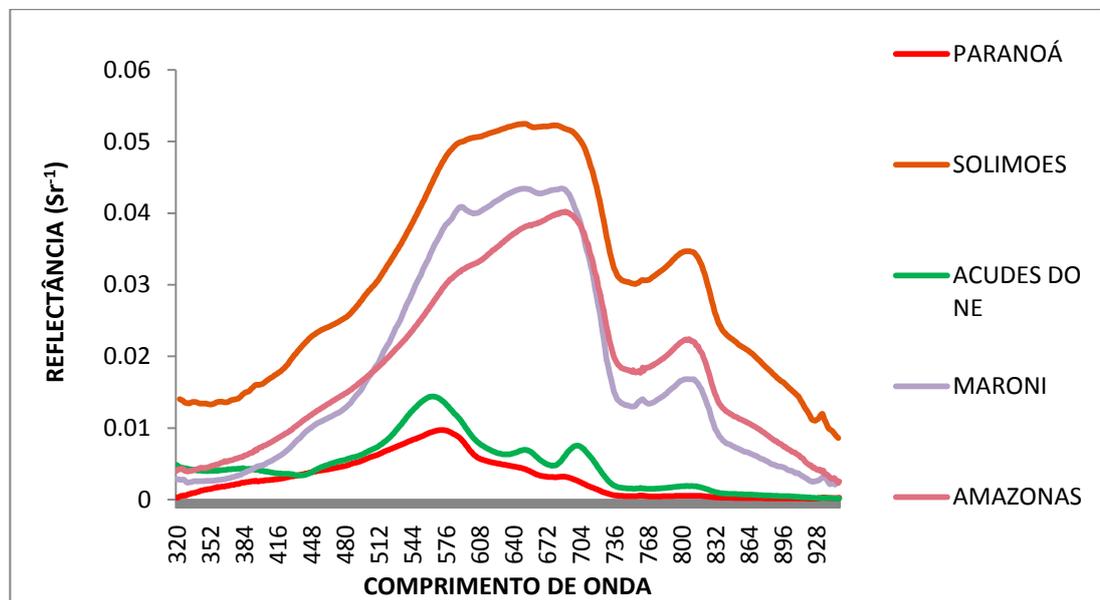


Figura 12: Exemplo de espectros de diferentes corpos d'água após a normalização dos dados de radiometria.

4.1.2 Escolha do modelo por faixa de concentração

Antes de iniciarmos os testes estatísticos, em uma análise simples no Excel (Figura 13), foi possível perceber uma maior dispersão dos dados a partir de 100mg/L, provavelmente definida pela saturação da reflectância nos comprimentos de onda curtos (verde, vermelho) que resulta do equilíbrio dos processos de absorção e espalhamento, corroborando com MARTINEZ *et al.*, (2015).

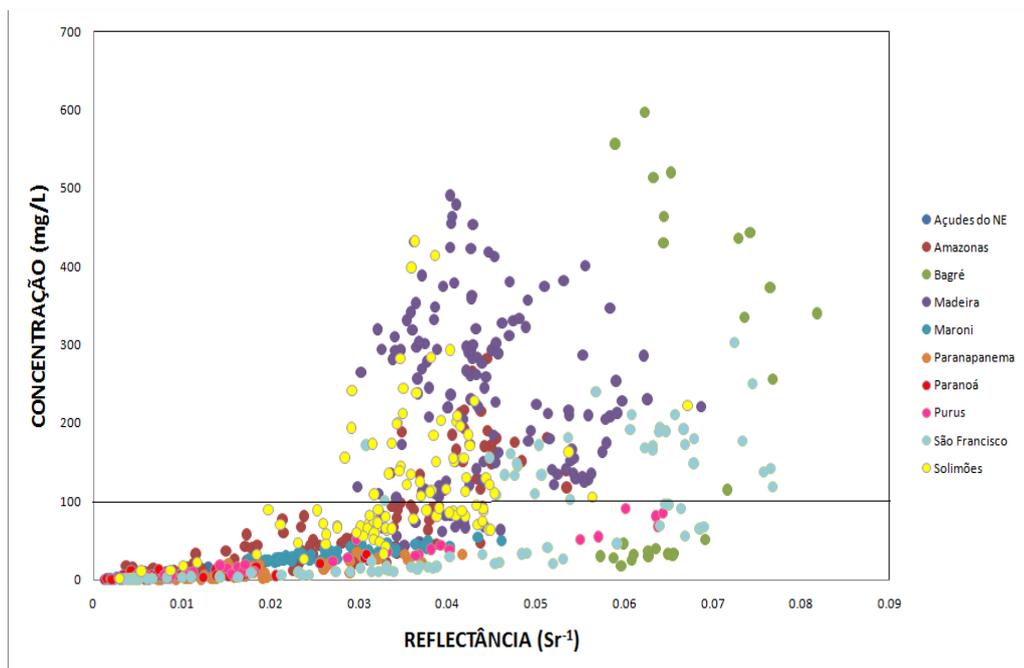


Figura 13: Distribuição dos dados na faixa de 650nm e verificação saturação do sinal a 100mg/L.

A partir disso, optou-se por realizar as análises em duas grandes faixas de concentração: uma de 0 a 100mg/L (contendo 476 pontos) e outra de 100 a 500mg/L (contendo 247 pontos). Os gráficos de dispersão mostram a correlação entre reflectância de sensoriamento remoto (eixo x) e concentração de sólidos em suspensão (eixo y) e foram gerados a fim de identificar qual o modelo mais adequado para a realização de uma inversão robusta. A grande variação de concentrações nos levou a considerar dois tipos de regressões e estudar as performances dos modelos estatísticos em função de diferentes classes de concentrações.

Foi feita uma análise linear e de potência (de acordo com as faixas de concentrações) para diversos comprimentos de onda que se aproximam de faixas centrais de bandas dos

sensores Sentinel-2, Landsat 8 e MODIS (500 nm, 650 nm, 740 nm, 783 nm, 800 nm, 865 nm, 900 nm, 940 nm) e razões de banda (865/650 nm, 800/650 nm, 940/650 nm, 940/865 nm), com a finalidade de avaliar o comportamento espectral dos sedimentos em suspensão ao longo do espectro para estes sensores orbitais. Cada script executado gerou como resultado 22 gráficos com seus respectivos Raiz do Erro Médio Quadrático (RMSE%) e intervalos de confiança, sendo 11 para análise linear e 11 para análise de potência.

Para decidir qual o melhor modelo para cada faixa de concentração de sedimento em suspensão (medida em laboratório por meio da filtragem) foram realizados testes para avaliar: a existência de correlação entre os dados, a normalidade e análise de resíduos. Devido ao grande volume de dados. Diante disso, optou-se por selecionar o modelo mais significativo de cada faixa de concentração em estudo para demonstração dessa etapa de pré-modelagem.

4.1.2.1 Dados com concentração entre 0 e 100mg/L

Para essa faixa de concentração o rio Maroni ganhou destaque, representando o modelo com menor valor de RMSE% no comprimento de onda de 800nm. Avaliando a existência de correlação linear entre as variáveis CSS e 800nm. Nota-se na Figura 14 que, além das variáveis apresentarem comportamento linear, as retas de regressão linear e potência descrevem bem o comportamento dos dados, com uma boa distribuição ao longo da normal.

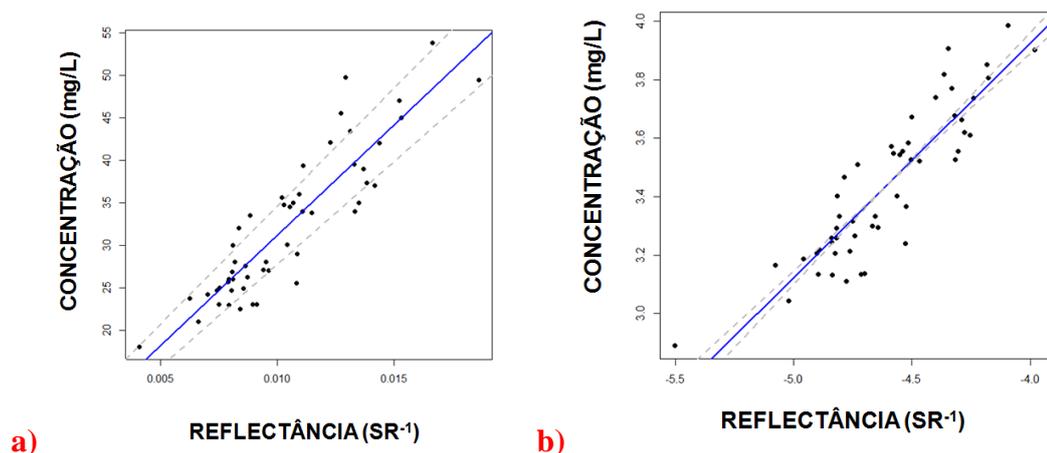


Figura 14: Gráficos de dispersão para os pontos do rio Maroni, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 800nm; b) Dispersão do modelo de potência para 800nm;

A correlação linear entre CSS e o 800nm foi de 0,8951 para o modelo linear e 0,8923 para o modelo de potência (considerando que os valores de correlação variam de -1 a +1 e que

quanto mais próximo dos extremos maior é a correlação). É importante ressaltar que há presença de um outlier na porção inferior esquerda do gráfico de dispersão, esse ponto tornou-se ainda mais discrepante no gráfico de dispersão relativo ao modelo de potência quando comparado ao modelo linear.

Avaliando a normalidade dos dados de CSS por meio do Histograma (Figura 15, **a** e **b**) é possível perceber que os dados não têm uma distribuição simétrica. Quando o modelo de potência é aplicado, ocorre uma suavização na distribuição dos dados e eles se ajustam melhor a uma distribuição normal. Este comportamento pode ocorrer porque o logaritmo é uma transformação que suaviza a distribuição tornando menos assimétrica (Figura 15 b)

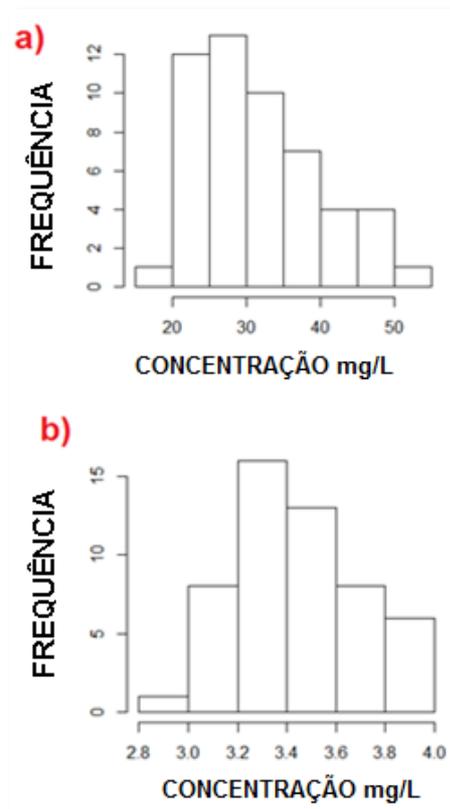


Figura 13: Histogramas da distribuição dos dados de CSS para o rio Maroni. a) histograma com o modelo linear e b) Histograma com o modelo de potência (em escala logarítmica).

Com base nestes resultados, avaliou-se que o ajuste do modelo linear para o modelo de potência não apresentou grandes ganhos, portanto, mesmo a distribuição dos dados não apresentando uma distribuição normal para o modelo linear apresentou melhor valor de correlação e um menor intervalo entre o outlier e a nuvem de pontos.

Para avaliar a adequabilidade do modelo linear foi realizada a análise dos resíduos apenas para o modelo selecionado. Observando a distribuição dos resíduos para o modelo linear tanto o histograma (Figura 16, a), como o gráfico de dispersão (Figura 16, b) e o boxplot (Figura 16, c) foi possível perceber que a aleatoriedade dos resíduos gira em torno da média (zero), apresentando uma média de -0,0667, assinalando que o modelo se adéqua para a representação destes dados.

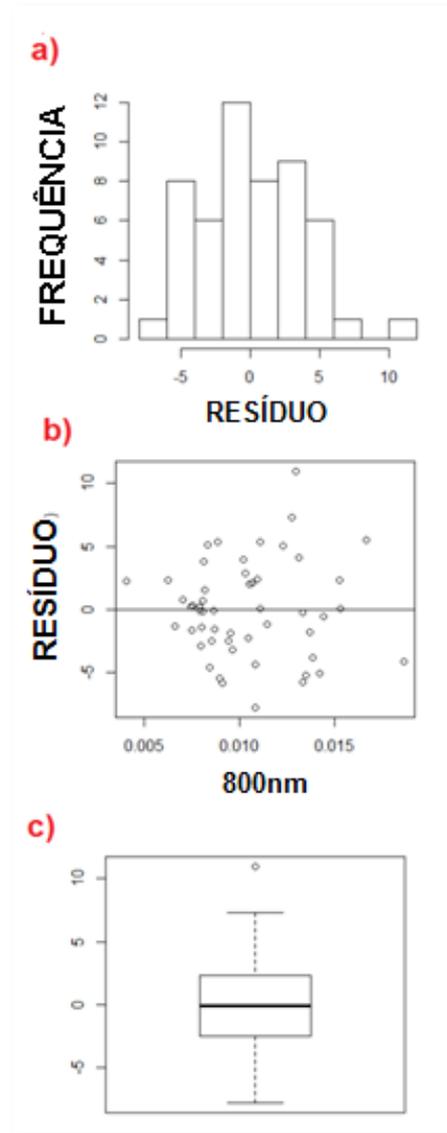


Figura 16: Análise dos resíduos para o rio Maroni. a) Histograma; b) Dispersão; c) Boxplot

Para este caso específico, a concentração do sólidos em suspensão é dada pela equação 16:

$$\text{CSS} = 2594,3(800\text{nm}) + 5,21 \quad \text{Eq. (16)}$$

4.1.2.2 Dados com concentração entre 100 e 500mg/L

Para essa faixa de concentração o Lago Bagré ganhou destaque, apresentando o melhor modelo para a razão entre os comprimentos de onda de 865/650nm. Avaliando a existência de correlação linear entre as variáveis CSS e 865/650nm, nota-se na Figura 17 que, além de as variáveis apresentarem o mesmo comportamento linear, o modelo de potência apresenta os dados bem distribuídos ao longo da normal.

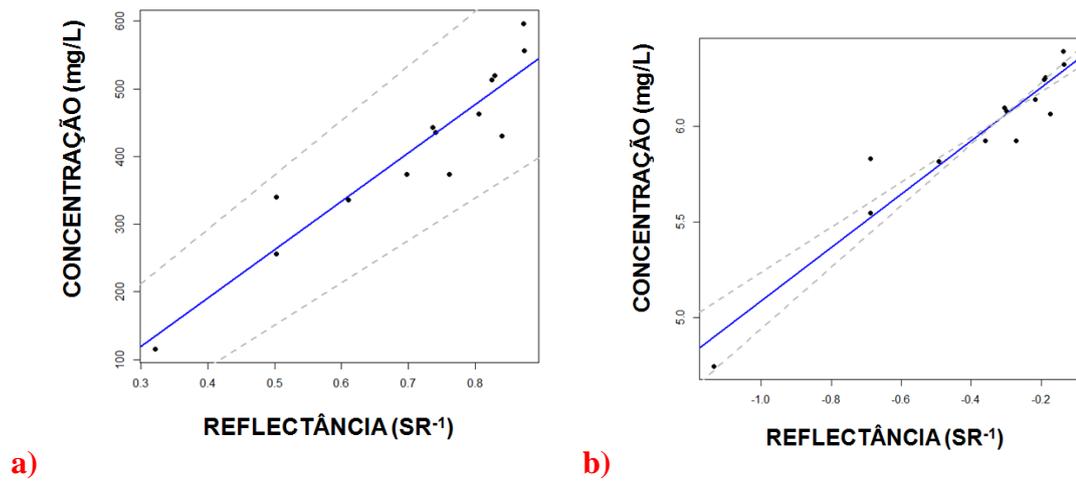


Figura 17: Gráficos de dispersão para os pontos do Lago Bagré, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 865/650nm; b) Dispersão do modelo potência a 865/650nm

A correlação linear entre CSS e o 865/650nm é de 0,9372 para o modelo linear e 0,9543 para o modelo de potência (considerando que os valores de correlação variam de -1 a +1 e que quanto mais próximo dos extremos, maior é a correlação).

Avaliando a normalidade dos dados de CSS por meio do Histograma (Figura 18) é possível perceber que os dados não têm uma distribuição simétrica. Quando o modelo de potência é aplicado, há uma suavizada na distribuição dos dados e eles se ajustam melhor a uma distribuição normal, entretanto há uma faixa de supressão de dados. Avaliando o conjunto de testes, nota-se que o modelo de potência ajustou melhor a distribuição normal e apresentou melhor valor de correlação quando comparado ao modelo linear.

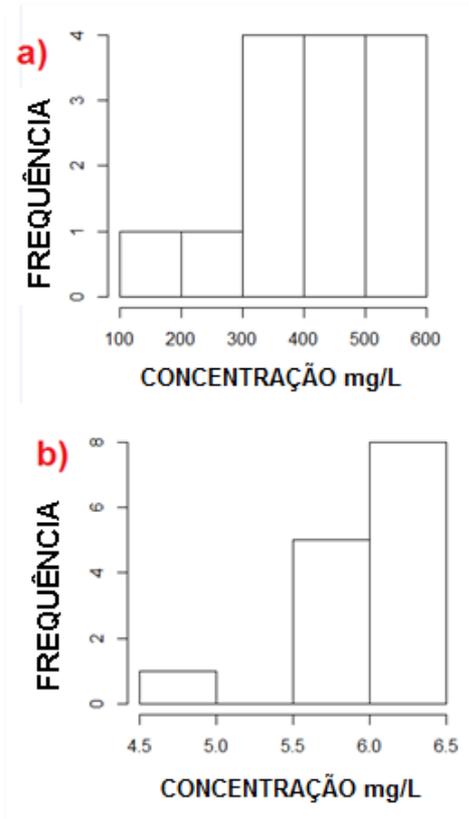


Figura 18: Histogramas da distribuição dos dados de CSS para o rio Lago Bagré. a) histograma com o modelo linear e b) Histograma com o modelo de potência (em escala logarítmica).

Para avaliar a adequabilidade do modelo de potência foi realizada a análise dos resíduos apenas para o modelo selecionado. Observando a distribuição dos resíduos para o modelo de potência tanto o histograma (Figura 19, a), como o gráfico de dispersão (Figura 19, b) e o boxplot (Figura 19, c) foi possível perceber que a aleatoriedade dos resíduos encontra-se também em torno da média (zero), apresentando uma média de $-0,0667$, assinalando que o modelo se adequa para a representação destes dados.

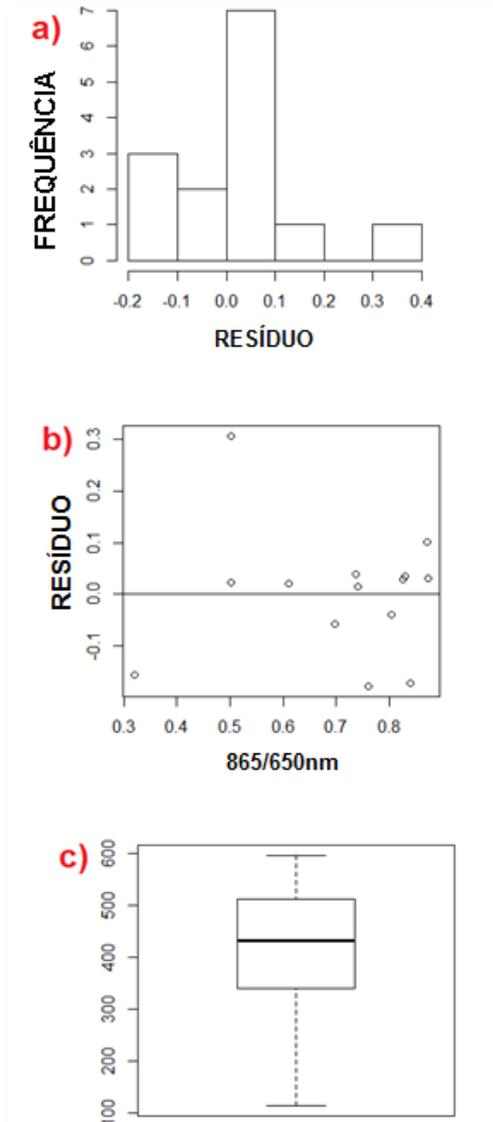


Figura 19: Análise dos resíduos do Lago Bagré. a) Histograma; b) Dispersão, Boxplot

Para este caso específico, a selecionada foi (Eq.17):

$$\text{CSS} = 651,55(865/650)^{0,21} \quad \text{Eq. (17)}$$

4.1.3 Aplicação e comportamento geral dos modelos

Para as análises estatísticas foram utilizados 723 (Tabela 02) pontos de coleta contendo informações de reflectância de campo e concentração de sólido em suspensão, obtida em laboratório. Primeiramente, os testes foram realizados de forma agrupada (em uma Amostra Global, contendo todos os pontos) e em seguida de forma individual (apenas os

pontos referentes à bacia analisada) por faixa de concentração, como serão mostrados a seguir.

4.1.3.1 Concentrações entre 0 e 100mg/L

Foi realizada a análise de todo o conjunto de dados com CSS inferior a 100mg/L (Figura 20), ao todo foram 476 pontos, sendo: 96 no Lago Paranoá, 40 no rio Paranapanema, 61 no rio São Francisco, 21 no rio Madeira, 54 no rio Solimões, 90 no rio Amazonas, 32 no rio Purus, 52 no rio Maroni, 13 no Lago Bagré e 17 nos açudes do Nordeste.

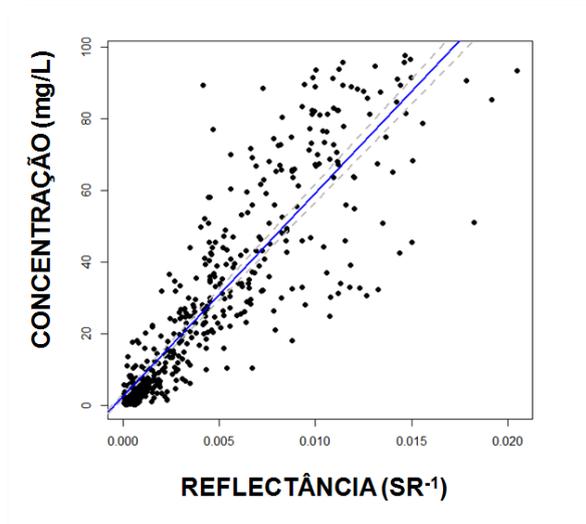


Figura 20: Gráficos de distribuição dos 476 pontos com CSS até 100mg/L para o modelo de regressão linear referente ao comprimento à faixa de 865nm com RMSE de 47%, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança.

De um modo geral, com a união de todos os pontos (Amostra Global) para os cálculos estatísticos gerou valores de RMSE elevados (acima de 47% para os comprimentos de onda e acima de 71% para as razões de banda). Avaliando os valores de RMSE% para as CSS inferiores a 100mg/L (Tabela 02) foi possível perceber que o rio Amazonas, Paranapanema, Lago Paranoá, Açudes do Nordeste e o conjunto total (com os 476 pontos) apresentaram RMSE superiores a 30% tanto para o modelo linear quanto para o modelo de potência.

Em contrapartida, todos os valores de RMSE do Lago Bagré, rio Madeira, rio Maroni e a maioria do rio Solimões foram inferiores a 30%. Em geral, a razão de banda não funcionou muito bem para concentrações inferiores a 100mg/L, com exceção do Lago Bagré, rios Madeira e Maroni. Na tabela abaixo, os valores das células em verde são considerados

aceitáveis (inferiores a 30%), enquanto que os valores das células em branco são considerados ruins (superiores a 30%).

Tabela 02: Valores de RSME% em porcentagem para o modelo linear por comprimento de onda para cada área de estudo para CSS até 100mg/L.

	AMAZONAS	BAGRE	MADEIRA	MARONI	PARANAPANEMA	PARANOÁ	PURUS	AÇUDES DO NE	SÃO FRANCISCO	SOLIMÕES	AMOSTRA GLOBAL
500	53,9	22.8	18.8	18.2	90.7	85.5	37.3	40.8	103	24.3	80.4
650	43,8	20.6	19.4	13.2	49	68.5	26.3	44.4	63.5	23	66.9
740	37,3	20.6	12.7	12.8	36.4	51.3	31.3	64.7	29.8	22.2	50.2
783	37,3	14.5	14.6	12.6	36.1	51.4	31.2	64.7	31.2	21.8	48.3
800	36,8	14.6	14.8	11.6	34.6	51.5	30.1	65.5	31.1	21.6	47.7
865	37,7	14.3	14.1	19.3	45.6	55.3	39.5	70.6	38.8	22.5	47
900	44,1	15.7	14.2	21.9	51.3	60.4	45.6	71.3	51.3	25.2	50.8
940	47	16.2	23	25.2	60.8	91.6	74.3	63.6	81.3	33.2	65.2
865/650	61,7	20.7	13.5	26.1	70.6	101	86.6	108	110	28.3	71.3
800/650	62,4	15.2	14.3	25.6	41.2	80.7	72.3	107	64.6	25.5	63.9
940/650	72,1	12.7	23.6	26.1	91.5	117	87.2	108	123	29.7	93.6
940/865	72,8	21.8	23.3	25.8	89	115	86.2	107	97.1	27.7	95.1

4.1.3.1.1 Análise Individual

Iniciando a análise individual, foi possível perceber que quanto maior o comprimento de onda, menor a dispersão no gráfico e menor o RMSE% no modelo linear e de potência para os pontos do rio Amazonas com concentrações inferiores a 100mg/L. Com relação aos comprimentos de onda testados para o rio Amazonas, o modelo linear quanto apresentou no comprimento de onda de 800nm o menor valor de RMSE (36.8%), entretanto todos resultados são superiores a 30%. O modelo para o comprimento de onda de 500nm apresentou o maior valor de RMSE (56.2%), sendo assim o pior modelo para este corpo d'água (Figura 21). Com relação os casos de razão entre bandas para o rio Amazonas, os modelos não gerou bom resultados de distribuição dos pontos, apresentando grande dispersão e saturação, além de valores de RMSE altos, a maioria entre 60 e 80%.

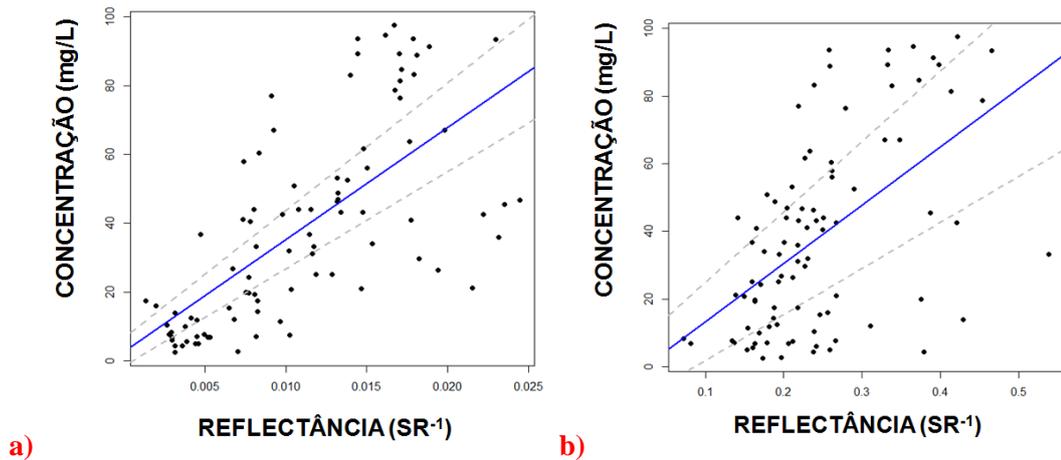


Figura 21: Gráficos de dispersão para os pontos do Amazonas, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 500nm; b) Dispersão do modelo linear para 800nm

No rio Madeira (Figura 22) o modelo que apresentou um menor valor de RMSE% foi comprimento de onda o 740nm (RMSE de 12,7%) e como pior, com maiores valores de RMSE, o 940nm (com RMSE de 23%).

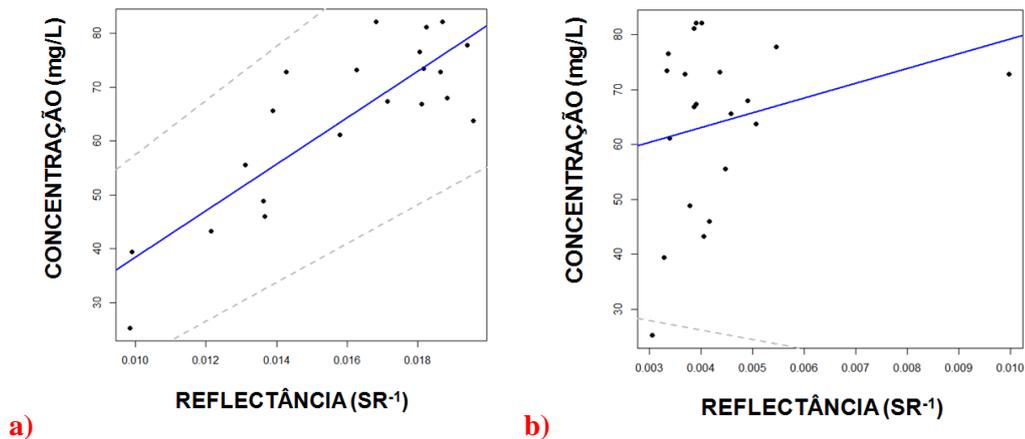


Figura 22: Gráficos de dispersão para os pontos do rio Madeira, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 740nm; b) Dispersão do modelo linear para 940nm .

No rio Maroni (Figura 23) os gráficos apresentam uma distribuição similar para os dois modelos em teste até 800nm, a partir de 865nm a diferença é muito visível e o modelo linear passa a representar melhor a distribuição dos pontos. O menor valor de RMSE% para o modelo foi o referente ao 800nm (com RMSE de 11,6% para o modelo linear) e o 940nm como pior resultado (com RMSE de 25,2%).

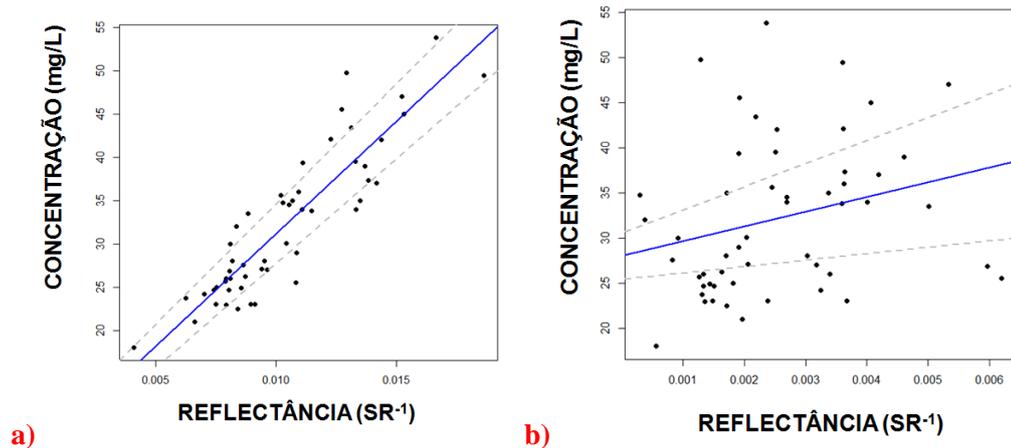


Figura 23: Gráficos de dispersão para os pontos do rio Maroni, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 800nm; b) Dispersão do modelo linear para 940nm

Para o Lago Bagré (Figura 24), os gráficos do modelo linear apresentam uma oscilação com relação ao RMSE%. Nos menores comprimentos de onda, como 500nm, o RMSE é maior. Em seguida, decresce a partir de 740nm e volta a aumentar a partir de 865nm. O modelo linear apresenta como melhor resultado o 865nm (com RMSE de 14,3%) e como pior resultado o 500nm (com RMSE de 22,8%).

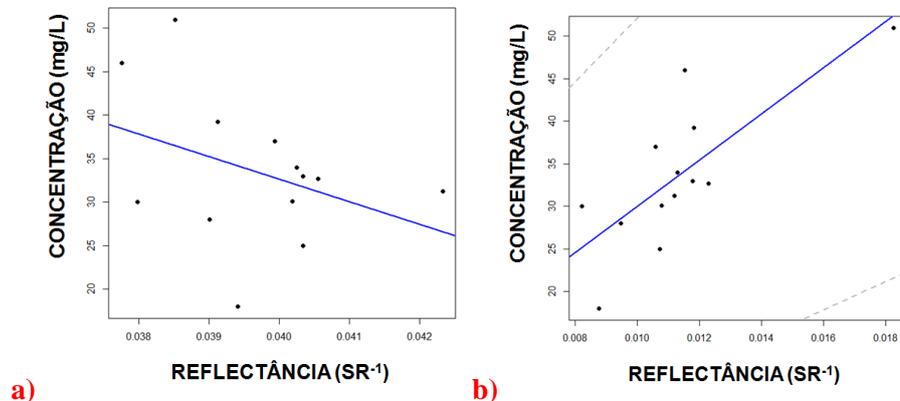


Figura 24: Gráficos de dispersão para os pontos do Lago Bagré, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 500nm; b) Dispersão do modelo linear para 865nm.

Para o rio Paranapanema (Figura 25), todos os modelos apresentaram RMSE acima de 30%, com menor erro no comprimento de onda o 800nm (com RMSE de 34,66%) e o 500nm como pior (com RMSE de 90,7%).

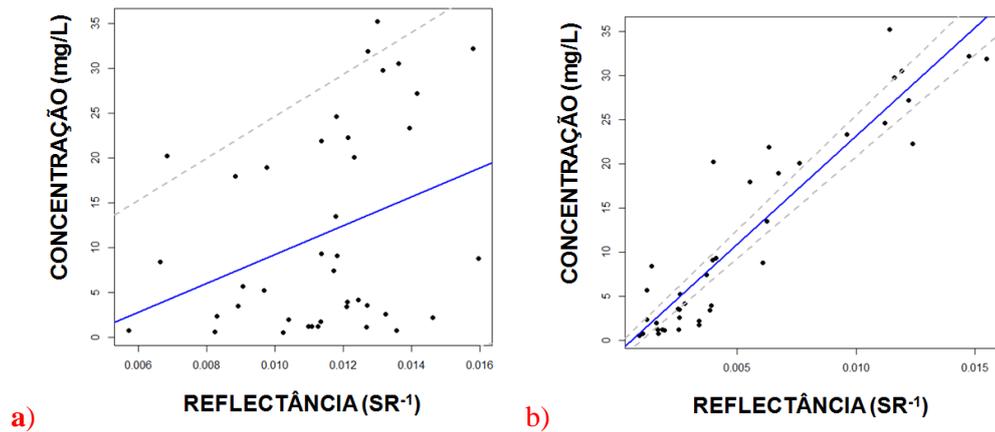


Figura 25: Gráficos de dispersão para os pontos do rio Paranapanema, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 500nm; b) Dispersão do modelo linear para 800nm .

Para o Lago Paranoá (Figura 26) os valores de RMSE são superiores a 50%, com menor erro para o modelo linear em 740nm para (RMSE de 51%) e o pior resultado o comprimento de 940nm (com RMSE de 91,6%).

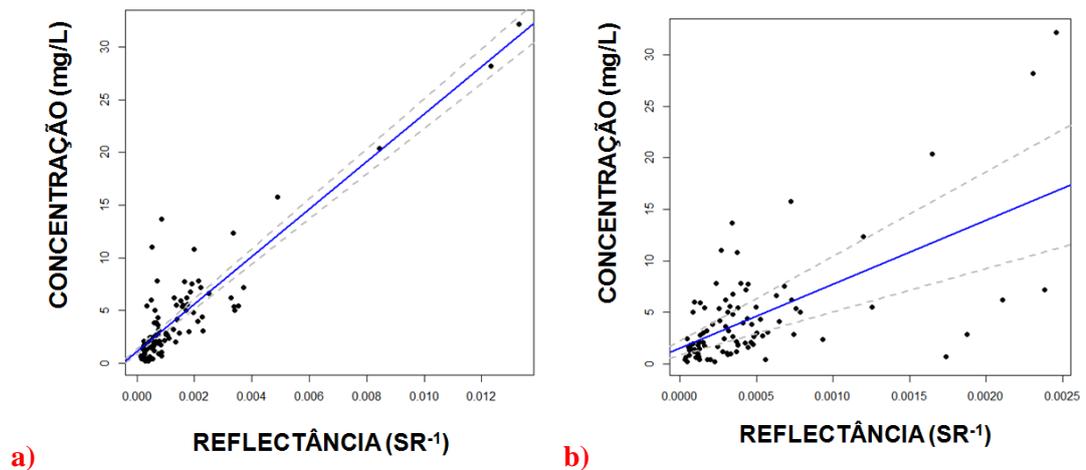


Figura 26: Gráficos de dispersão para os pontos do Lago Paranoá, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 740nm; b) Dispersão do modelo linear para 940nm.

Em geral, no rio Purus (Figura 27), o modelo linear apresentou a melhores performances para o comprimento de onda de 650nm (com RMSE de 26,3%) como melhor comprimento e o 940nm (com RMSE de 74,3) como o pior.

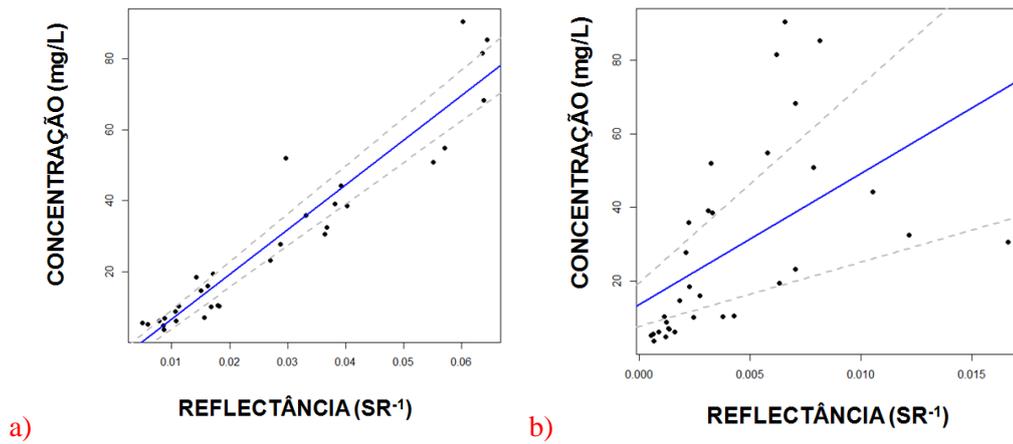


Figura 27: Gráficos de dispersão para os pontos do rio Purus, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 650nm; b) Dispersão do modelo linear para 940nm.

Para os açudes do Nordeste (Figura 28), o modelo linear apresentou valores de RMSE superiores a 40% em todos os comprimentos de onda, com o melhor resultado no comprimento de onda de 500nm (com RMSE de 40,8%) e 900nm como pior comprimento de onda (com RMSE de 71,3%).

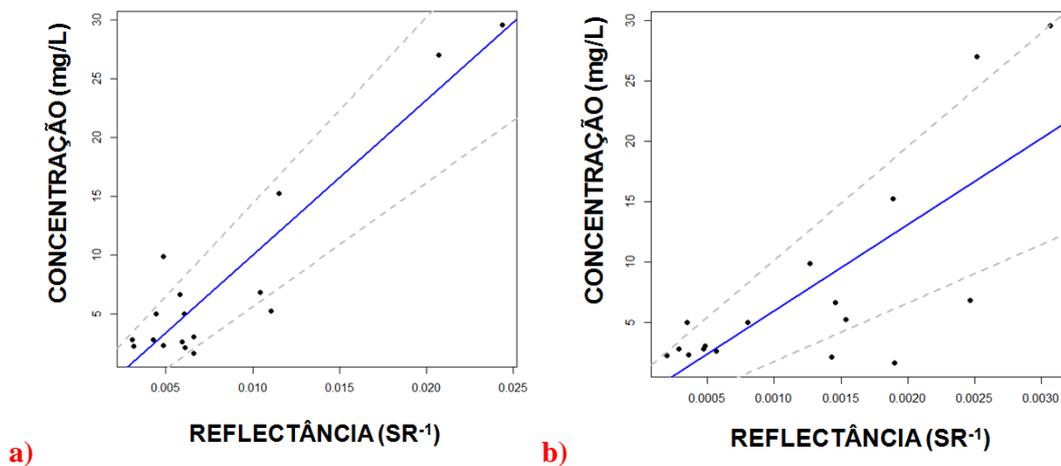


Figura 28: Gráficos de dispersão para os Açudes do Nordeste, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 500nm; b) Dispersão do modelo linear para 900nm.

Para o rio São Francisco (Figura 29) o melhor resultado é referente ao modelo do comprimento de 740nm (com RMSE de 29,8%) e os piores estão em 500nm (com RMSE de 103%).

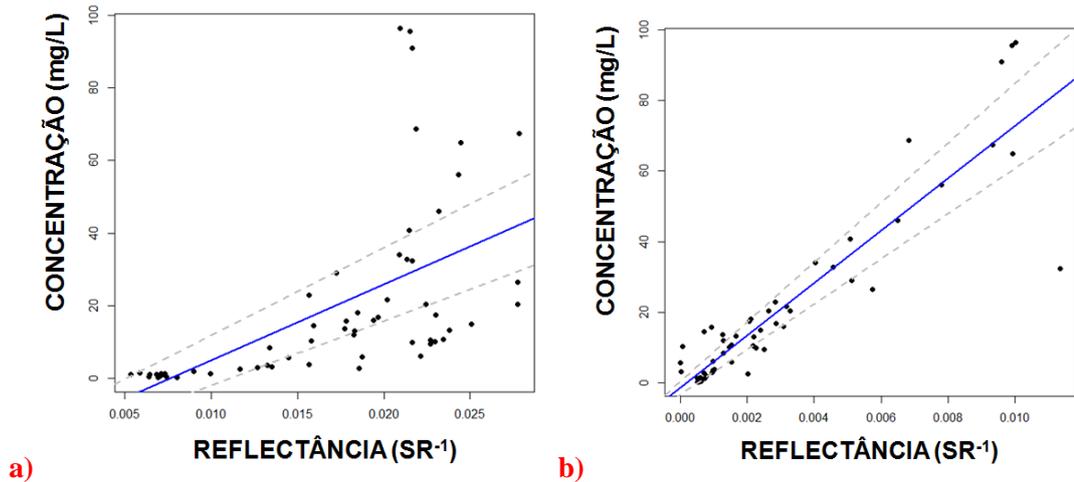


Figura 29: Gráficos de dispersão para rio São Francisco, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 500nm; b) Dispersão do modelo linear para 900nm.

De modo geral, a distribuição dos pontos no rio Solimões (Figura 30) apresentou os valores de RMSE inferiores a 30% em todos os testes, tanto para os comprimentos de onda quanto para as razões de bandas. O maior valor de RMSE foi para o 940nm (com RMSE de 33,2%), enquanto o menor valor de RMSE foi o encontrado para 800nm como o melhor (com RMSE de 21,6%).

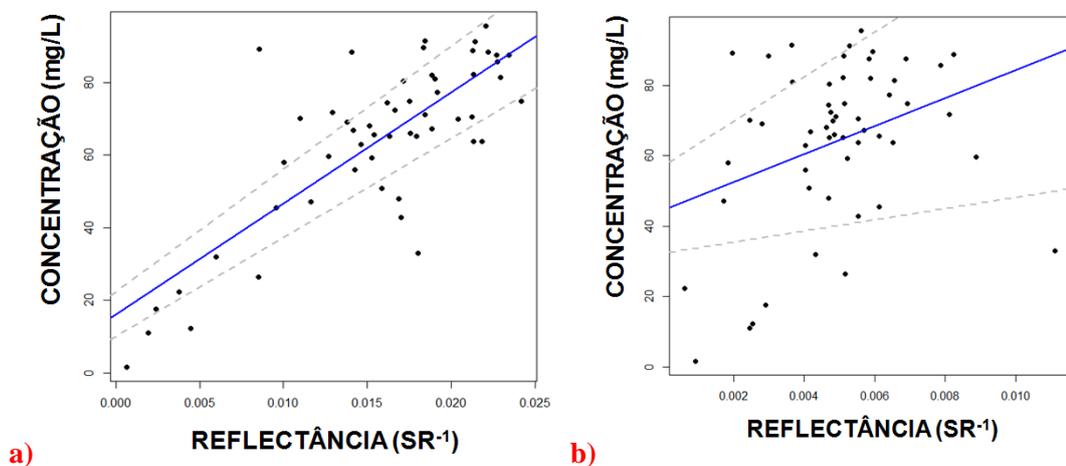


Figura 30: Gráficos de dispersão para os pontos do Solimões, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão do modelo linear para 800nm; b) Dispersão do modelo linear para 940nm.

4.1.3.2 Concentrações entre 100 e 500mg/L

Foi realizada a análise de todo o conjunto de dados com CSS entre 100mg/L e 500mg/L, ao todo foram 247 pontos, sendo: 34 no rio São Francisco, 124 no rio Madeira, 47 no rio Solimões, 28 no rio Amazonas e 14 no Lago Bagré.

Ao analisar a Amostra Global (contendo os 247 pontos) foi possível perceber muita dispersão nos modelos (Figura 31), com menores dispersões nas razões entre as bandas 865/650nm (com RMSE de 22%) e 800/650nm (com RMSE de 21, 8%). O modelo de potência selecionou o 900nm como melhor (com RMSE de 32,7%) e o 650nm como pior (com RMSE de 45,8%).

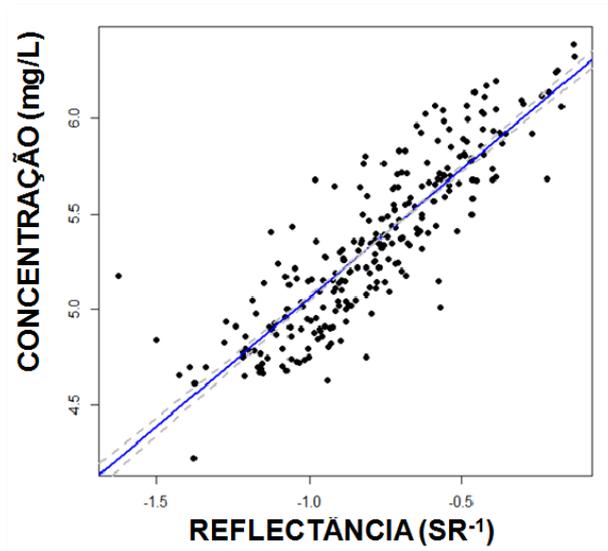


Figura 31: Gráfico de dispersão para o modelo de potência da Amostra Global de 100 a 500mg/L a 800/650nm, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança.

Avaliando os valores de RMSE% do modelo de potência para as CSS de 100mg/L a 500mg/L (Tabela 03) foi possível perceber que o rio Amazonas, Lago Bagre, e o rio São Francisco apresentaram todos os valores RMSE superiores a 30%. Em contrapartida, a maioria dos valores de RMSE do rio Madeira, rio Solimões e todos os pontos juntos foram inferiores a 30%, com exceção dos valores referentes às razões de banda 865/650 e 800/650, que foram inferiores a 30% para esses três campos.

Tabela 03: Valores de RSME em porcentagem para o modelo de potência por comprimento de onda para cada área de estudo com CSS entre 100 e 500mg/L.

	AMAZONAS RMSE%	BAGRE RMSE%	MADEIRA RMSE%	SÃO FRANCISCO RMSE%	SOLIMÕES RMSE%	AMOSTRA GLOBAL RMSE%
500	23.8	19.4	38.8	24	41.6	45.1
650	24.3	22.8	38.4	23.1	41.7	45.8
740	21.5	26.6	35.9	17.6	37.7	38.3
783	21.4	25.5	35.9	16.8	37.3	38.1
800	21.6	26.1	36.4	17.1	37.9	38.8
865	20.5	17.8	32.1	16.6	32.9	33.5
900	20.6	16.2	31.3	16.8	31.8	32.7
940	23.7	15.5	35.7	24.5	41.1	42.5
865/650	18.6	10.4	21.8	19.9	24.1	22
800/650	18.7	10.7	19.2	18.8	24.3	21.8
940/650	23.8	11.1	33.6	25.4	40.6	42.5
940/865	24.3	16	39	25.1	41.4	45.2

4.1.3.2.1 Análise Individual

Com relação aos dados do rio Amazonas (Figura 32), houve bastante dispersão da nuvem de pontos em torno da reta normal. Entretanto, ao aplicar a razão de bandas essa dispersão foi reduzida (especificamente para as razões de 865/650 com RMSE de 18,6% e 800/650 com RMSE de 18,7%). Outro detalhe é que os RMSE% das razões de banda são menores que os dos comprimentos de onda que foram testados. Para o modelo de potencia o melhor comprimento de onda foi o 865nm (com RMSE de 20,5%) e o pior comprimento de onda o 650nm (com RMSE de 24,3%).

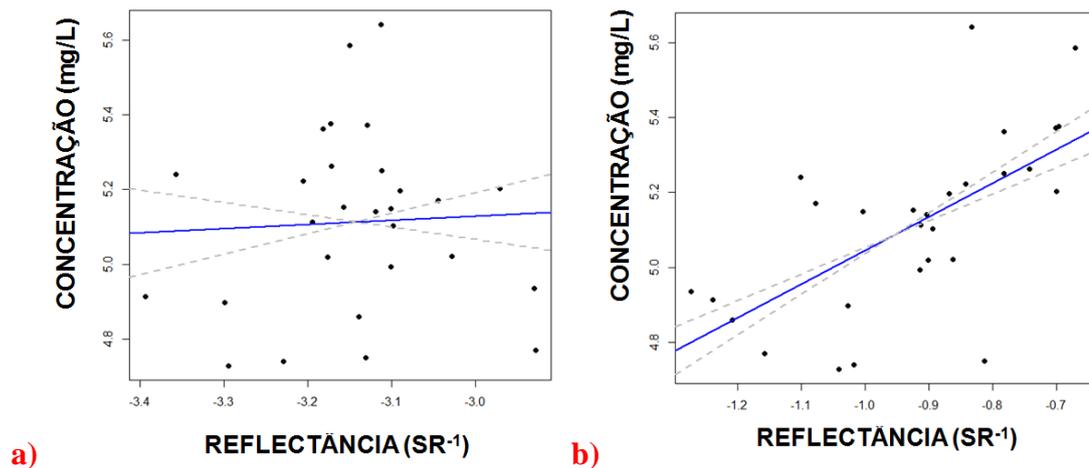


Figura 32: Gráficos de dispersão para os pontos do rio Amazonas, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança.: a) Dispersão para o modelo de potência para 650nm; b) Dispersão para o modelo de potência para 865/650nm

A distribuição dos pontos do Lago Bagré (Figura 33) mostra que modelo de potencia apresentou uma menor dispersão em torno da reta. Os valores de RMSE para esta área de estudo foram inferiores 30%. Com base nesse critério, o modelo de potencia selecionou como melhor comprimento de onda o 940nm (com RMSE de 15,5%) e como o pior o 740nm (com RMSE de 26,6% para o modelo de potência), com a melhor razão entre 865/650nm (apresentando RMSE de 10,4%)

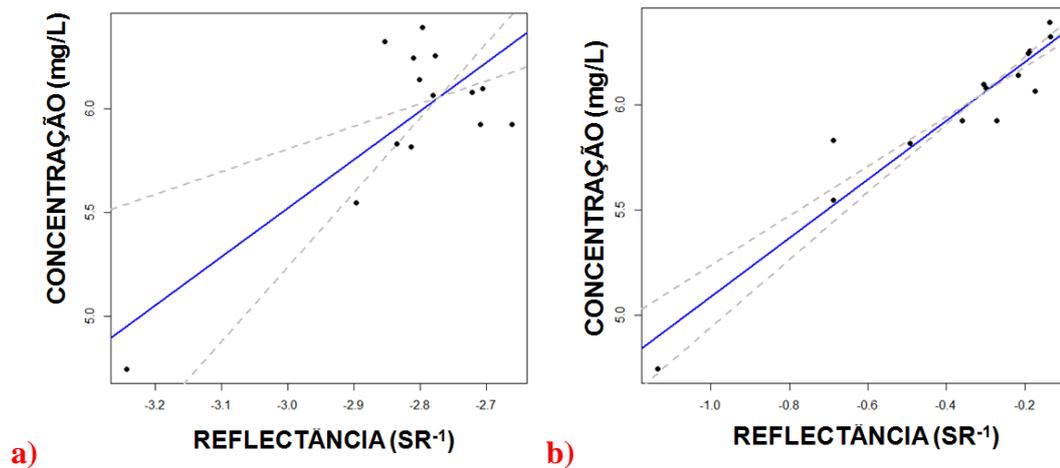


Figura 33: Gráficos de dispersão para os pontos do Lago Bagré, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão para o modelo de potência para 740 e b) Dispersão para o modelo de potência para 865/650nm.

Para o rio Madeira (Figura 34), os gráficos apresentaram bastante dispersão de um modo geral, com melhores resultados nas razões de banda. O modelo de potencia mostra o 900nm como melhor comprimento de onda (com RMSE de 31,3) e 500nm como pior (com RMSE de 38,8%). Nos testes de bandas, todos os RMSE foram superiores a 30%, em contrapartida, os valores decaíram em algumas razões de banda, como na razão entre 800/650nm (com RMSE de 19,6% para o modelo linear e 19,2% para o modelo de potencia).

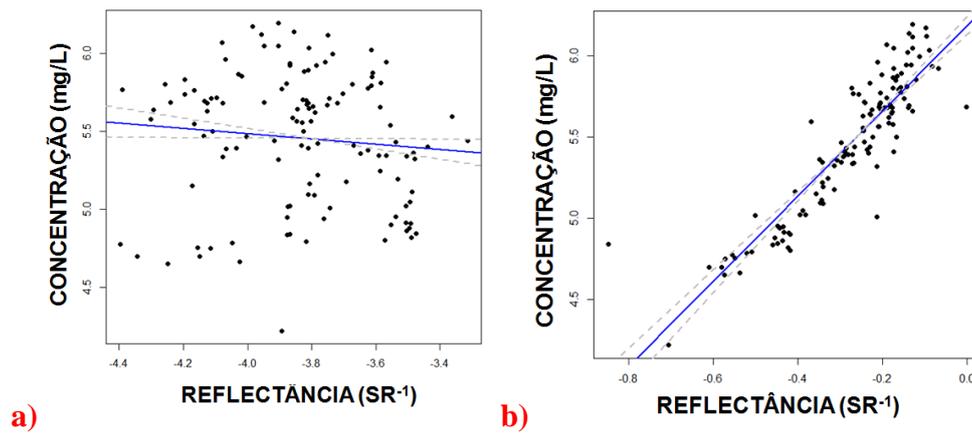


Figura 34: Gráficos de dispersão para os pontos do rio Madeira, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança: a) Dispersão para o modelo de potência para 500nm; b) Dispersão para o modelo de potência para 800/650nm

No rio São Francisco (Figura 35) os valores de RMSE% tanto para os testes de bandas quanto para as razões de banda foram inferiores a 30%. O modelo de potencia mostra como pior 900nm (com RMSE de 24,5%) e como melhor comprimento de onda o 865nm (com RMSE de 16,6%) e melhor razão entre 800/650nm (com RMSE de 18,8%).

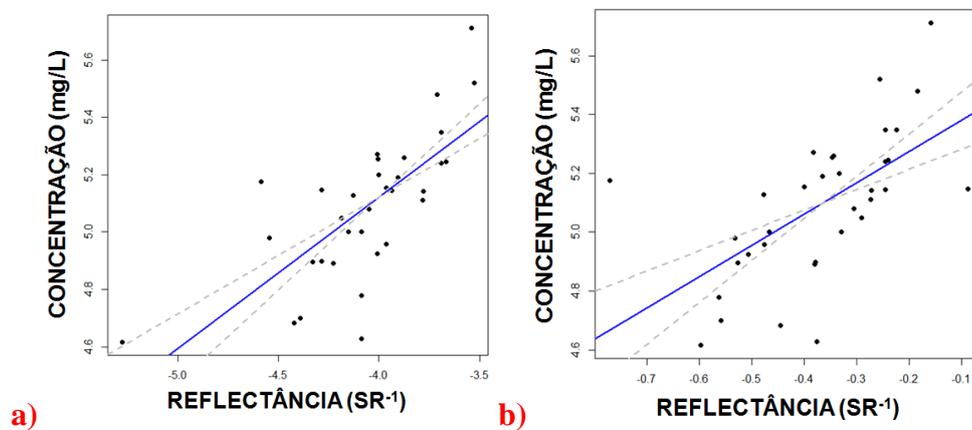


Figura 35: Gráficos de dispersão para os pontos do rio São Francisco, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão para o modelo de potência para 900nm e b) Dispersão para o modelo de potência para 800/650nm.

Para o rio Solimões (Figura 36) apresentou menor dispersão nos resultados da razão de bandas. Em geral, os valores de RMSE foram superiores a 30%, porém, ao aplicar a razão de bandas houve uma redução de valores (principalmente na razão entre 865/650, com RMSE de 24,1%). Quanto aos comprimentos de onda, o modelo de potência selecionou o 900nm como melhor (com RMSE de 24,3%) e 650nm como o pior (com RMSE de 41,7%).

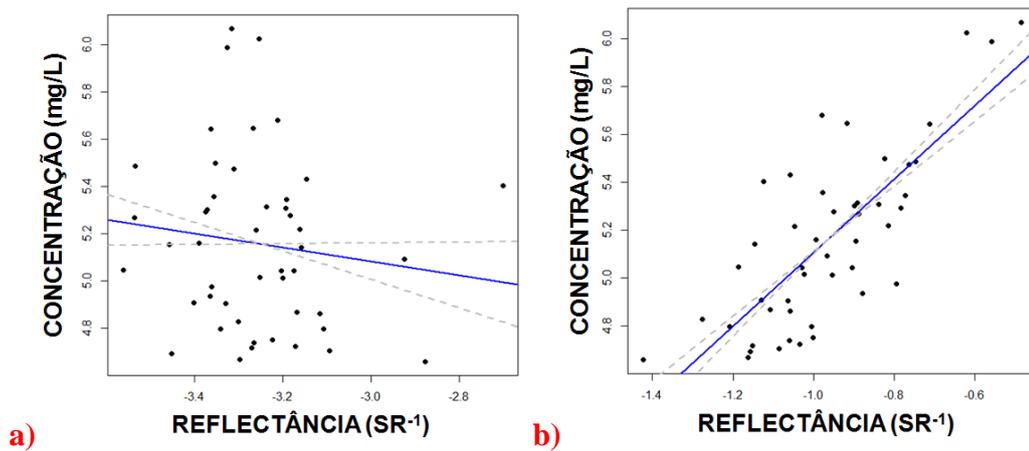


Figura 36: Gráficos de dispersão para o rio Solimões, onde a linha azul é a normal e a linha pontilhada o intervalo de confiança. a) Dispersão para o modelo de potência para 650; b) Dispersão para o modelo de potência para 865/650.

4.1.4 Coeficientes Angulares e Lineares

Tomando a hipótese de que os dados apresentam uma distribuição aproximadamente normal foram realizados testes de regressão. A regressão foi usada para prever o valor de y a partir do valor de x e estimar o quanto x influencia y .

Para concentrações entre 0 e 100mg/L, foram aplicados modelos linear (Tabela 04), para esse tipo de regressão foi usada a equação: $y = a + bx$. Em que “ b ” é o coeficiente linear (ou intercepto, é o valor que y assume quando x for zero) e “ a ” é coeficiente angular (é a inclinação da reta, mede o aumento ou redução em y para cada aumento de uma unidade em x).

Para concentrações entre 100 e 500mg/L, foram aplicados modelos de potência (Tabela 05) a um intervalo de confiança de 68%, dados estão disponíveis na tabela 06. Para a regressão de potência foi usada a equação: $y = ax^b$ (ou seja, $\ln(y) = \ln(a) + b\ln(x)$). No qual o “ b ” passa a ser o coeficiente angular e o “ a ” passa a ser o coeficiente linear.

Tabela 04: Coeficientes lineares e angulares para o modelo linear em amostra com concentrações entre 0 e 100mg/L.

	AMAZONAS		BAGRE		MADEIRA		MARONI		PARANAPANEMA		PARANOÁ		PURUS		AÇUDES DO NE		SÃO FRANCISCO		SOLIMÕES		TODOS JUNTOS	
	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b	a	b
500	3270.23	2.47	-2585	136.04	3678.5	-3.48	1984.8	8.67	1612.1	-6.95	1262.79	-4.05	2657.33	-8	1321.42	-3.25	2088.5	-15.95	2582	21.38	1989.12	2.79
650	1935.6	-3.72	1401.4	-54	2091.62	-16.62	1051.6	3.8	1044.6	-9	738.37	-0.76	1262.4	-6.12	1180	-2.81	1009.29	-10.58	1712.4	10.81	1219.2	0.27
740	3656.5	3.52	1848.9	-7.95	4326.46	-4.9	2955.6	5.69	2626.4	-1.61	2253.64	1.11	2627.8	1.12	3130.2	-1.69	2894.7	-3.53	3389.3	18.71	3260.5	1.74
783	3497.1	3.41	1769.2	-5.94	4241.46	-5.26	2841.8	6.23	2693.9	-1.38	2206.95	1.32	2540.1	1.42	3331	-1.48	2848.4	-3.03	3304.2	17.53	3197.2	1.71
800	3174.4	2.94	1666.1	-7.19	3912.75	-6.94	2594.3	5.21	2455.3	-1.43	1968.97	1.31	2291.6	1.54	2944.8	-1.41	2573.4	-3.1	3058.3	16.14	2903.2	1.4
865	5618.5	6.36	2720	2.79	6983.87	-1.77	3674.4	15.78	4996.3	-0.31	4178.58	1.47	4312	1.41	5754.8	-1.23	5418.4	-1.84	5292.8	21.25	5660.8	2.69
900	6384.5	9.72	3493.8	5.94	11094.75	-13.92	3682.1	20.14	6596.6	0.18	5700.66	1.33	5673.8	1.68	7141.2	-1.2	7432.9	-1.48	6329.2	26.19	7333.8	3.48
940	6070.9	16.89	3973.8	14.67	2685.95	52.4	1636.3	27.97	8243.1	0.77	6199.02	1.53	3559.9	13.53	7904.7	-0.78	10760	-2.09	3970.1	44.63	7634.1	8.39
865/650	172.36	-3.94	223.9	-6.76	435.3	-41.75	14.44	29.74	150.13	-4.37	56.92	-0.46	47.88	18.2	-4.11	8.33	207.58	-6.56	226.51	7.82	206.6	-7.07
800/650	95.34	-7.75	151.29	-25.44	273.18	-63.93	27.24	21.6	107.63	-13.6	47.8	-4.28	142.84	-26.86	5.43	5.84	217.98	-34.61	193.09	-30	130.66	-16.93
940/650	50.12	30.18	245.11	14.95	25.59	61.04	-11.06	33.25	94.6	5.67	-0.12	4.36	-25.38	32.64	1.9	7.41	-106.1	28.26	-165.1	92.08	86.82	18.49
940/865	-3.91	41.52	-39.03	49.95	-15.52	71.31	-4.14	34.58	-20.67	23.64	-1.3	5.52	-8.48	35.08	4.64	4.43	-49.25	54.67	-14.19	76.21	-7.62	33.91

Tabela 05: Coeficientes lineares e angulares para o modelo de potência em amostra com concentrações entre 100 e 500mg/L.

	AMAZONAS		BAGRE		MADEIRA		SÃO FRANCISCO		SOLIMÕES		TODOS JUNTOS	
	a	b	a	b	a	b	a	b	a	b	a	b
500	566.80	0.32	0.42	-2.02	122.41	-0.17	735.73	0.38	52.73	-0.31	641.59	0.29
650	235.10	0.11	1.34	-2.13	68.63	-0.39	642.77	0.48	67	-0.29	319.2	0.14
740	2416.32	0.73	280399.83	2.34	5161.39	0.89	1593.55	0.68	6189.15	0.94	3092.19	0.77
783	2670.44	0.77	193971.72	2.26	4904.56	0.88	1646.1	0.7	7247.73	0.99	3063.34	0.77
800	2697.28	0.79	208930.72	2.33	4539.85	0.87	1641.72	0.72	6459.29	0.99	2822.55	0.77
865	1958.63	0.61	46909.33	1.58	6829.21	0.88	1558.59	0.6	14196.07	1.04	4094.88	0.77
900	1685.81	0.54	31948.67	1.36	5593.98	0.78	1387.76	0.53	10235.92	0.9	3834.36	0.7
940	320.54	0.15	54554.64	1.26	1237.77	0.36	299.59	0.14	447.19	0.19	861.07	0.31
865/650	379.93	0.9	651.55	1.39	654.92	1.45	307.02	0.68	766.36	1.54	609.84	1.35
800/650	298.87	1.53	421.47	2.35	485.72	2.62	241.44	1.06	478.78	2.47	432.77	2.33
940/650	198.34	0.13	1515.98	1.08	503.84	0.49	174.96	0.05	267.33	0.25	365.89	0.37
940/865	160.77	-0.08	15471.94	4.17	248.03	0.07	155.08	-0.09	147.52	-0.23	175.31	-0.24

4.2 DISCUSSÃO

Como mostrado anteriormente nos resultados, o modelo linear explica melhor o comportamento de sólidos em suspensão para os corpos d'água com CSS inferiores a 100mg/L, enquanto que o modelo de potência explica melhor o comportamento espectral de alvos com CSS superiores a 100mg/L, isso se deve provavelmente ao efeito de saturação para concentrações altas que induz processos não lineares e corrobora com o estudo de Binding *et al.*, (2005), que também relataram uma relação linear para concentrações baixas (no caso $CSS < 200\text{mg/L}$) e uma relação de potência para altas concentrações (superiores a 200mg/L).

Contudo, analisando essa diferença de RMSE% entre bacias, é possível perceber variações de erro significativas para um mesmo comprimento de onda como, por exemplo, para o modelo linear da fixa de 0 a 100mg/L em 800nm, onde o rio Solimões apresentou um RMSE% de 21,6%, enquanto o rio Maroni apresentou um RMSE de apenas 11,6%. Essas diferenças podem estar relacionadas com as condições ambientais de onde os rios/reservatórios estão inseridos e as características do próprio sedimento. Corroborando com Cui *et al.*, 2013, quando afirmou que as diferenças apresentadas entre o modelo linear e de potência para as bandas do vermelho e do infravermelho podem ser atribuídas às características dos sedimentos como granulometria e mineralogia. Porém, as diferenças observadas entre as regiões são difíceis de serem interpretadas em detalhe, uma vez que são poucas áreas que apresentam um número de coletas semelhantes em termos de distribuição hidrológicas ou de número de pontos de amostragens. Um RMSE menor poderia ser causado por um número de pontos reduzidos ou de situações hidrológicas muito semelhantes o que poderia limitar a variabilidade amostrada. Nesse sentido as medições realizadas nos campos dos rios Solimões, Amazonas, Madeira, Purus ou São Francisco parecem ser mais robustas pelo número de campanhas e pela distribuição ao longo do ciclo hidrológico. Em comparação, o Lago Bagré foi apenas visitado uma vez. Essas limitações são inerentes a qualquer trabalho de campo, porém não nos impedem a compreensão dos resultados apresentados anteriormente.

A seguir, discutimos os resultados para alcançar uma visão clara do potencial dos dados radiométricos para monitorar a concentração de sedimentos em rios *in situ* ou por imagens. Em particular vamos avaliar se seria possível um modelo de inversão único e qual é

o potencial dos novos sensores de satélite (Sentinel-2, Landsat-8) para observar as águas interiores.

4.2.1 Avaliação de bandas e razões de bandas

Analisando os dados das concentrações inferiores a 100mg/L (Tabela 06), é possível inferir que os modelos lineares utilizando as bandas espectrais da faixa do infravermelho próximo apresentam as melhores performances para a grande maioria dos campos como, por exemplo: Bagré com o RMSE de 14,3% em 865nm; Madeira com 12,7% em 740nm; Maroni com 11,6% em 800nm; São Francisco com 29,8% em 740nm e Solimões com 21,6% em 800nm. Observando essa distribuição, o comprimento de onda de 800nm foi o mais útil entre os campos, sendo o melhor comprimento para recuperação de CSS em 4 das 10 amostras.

Tabela 06: Resumo dos comprimentos de onda que geraram os menores valores de RMSE% em cada campo.

	RIO/RESERVATÓRIO	MELHOR BANDA	MELHOR RAZÃO
		LINEAR	
De 0 A 100mg/L	Rio Amazonas	800 (36.8%)	865/650 (66.4%)
	Lago Bagré	865 (14.3%)	940/650 (12.7%)
	Rio Madeira	740 (12.7%)	865/650 (13.5%)
	Rio Maroni	800 (11.6%)	800/650 (25.6%)
	Rio Paranapanema	800 (34.6%)	800/650 (41.2%)
	Rio Paranoá	740 (51.3%)	800/650 (80.7%)
	Rio Purus	650 (26.3%)	800/650 (72.3%)
	Reservatórios no Nordeste	500 (40.8%)	800/650 e 940/865 (107%)
	Rio São Francisco	740 (29.8%)	800/650 (64.6%)
	Rio Solimões	800 (21.6%)	800/650 (25.5%)
	Amostra global	865 (47.0%)	865/650 (71.3%)
		POTÊNCIA	
De 100 a 500mg/L	Rio Amazonas	865 (20.5%)	865/650 (18.6%)
	Lago Bagré	940 (15.5%)	865/650 (10.4%)
	Rio Madeira	900 (31.3%)	800/650 (19.2%)
	Rio São Francisco	865 (16.6%)	800/650 (18.8%)
	Rio Solimões	900 (31.8%)	865/650 (24.1%)
		Amostra global	900 (32.7%)

Para o estudo de sedimentos em suspensão com concentrações entre 100 e 500mg/L o modelo de potência foi o que melhor explicou o comportamento de CSS. Para essas faixas de maiores concentrações observou-se que os valores de RMSE% menores estão associados a

comprimentos de onda maiores (infravermelho, em torno de 865nm e 900nm). Como, por exemplo, os rios Amazonas e São Francisco a 865nm, os rios Madeira e Solimões a 900nm e Lago Bagré a 940nm (Tabela 06). Esse deslocamento da refletância para comprimentos de onda mais longos se dá devido ao aumento de concentração de sólido em suspensão que gera um maior espalhamento na energia eletromagnética e acarreta em perda de sensibilidade da refletância em função da concentração para comprimentos de ondas mais curtos devido a uma saturação da refletância (Wang *et al.*, 2010a e b).

No caso das CSS compreendidas entre 100 e 500mg/L, de maneira geral, os modelos de potência apresentaram valores de RMSE melhores que dos modelos lineares. Assim, para os modelos de potência, o Lago Bagré (RMSE de 15,5% em 900nm), os rios Amazonas (RMSE de 20,5% em 865nm) e São Francisco (RMSE de 16,6% em 865nm) apresentaram os RMSE menores (inferiores a 30%) para as bandas do infravermelho.

Nessa faixa de CSS, três dos cinco campos apresentaram menores erros para a razão 865nm/650nm (Lago Bagré com RMSE de 10,4%, rio Amazonas com RMSE de 18,6% e Solimões com RMSE de 24,1%) e os outros para razão 800nm/650nm (rios Madeira com RMSE de 19,2% e São Francisco com RMSE de 18,8% e Amostra Global com RMSE de 21,8%). Vale destacar que os valores de RSME% foram menores utilizando as razões de bandas do que utilizando bandas únicas no infravermelho, essa normalização ajuda na diminuição da dispersão dos dados.

Esse resultado foi similar ao da pesquisa de Chen *et al.*, (2015). Eles aplicaram seis testes (bandas B1, banda B2, razões de bandas, diferenças entre bandas - lineares, índice de sedimentos e log da razão de bandas- potência) para simulação da obtenção de sedimento em suspensão pelo sensor MODIS. Os autores observaram que a razão de bandas para o modelo de potência foi o mais preciso quando aplicado na “amostra global” (com CSS variando de 5,8 a 577,2 mg/L). Segundo os autores isso se deve a saturação do sinal a partir de concentrações superiores a 160 -200mg/L.

Com base na literatura, a obtenção de informações sobre os sólidos em suspensão na superfície da água via sensoriamento remoto é mais eficiente na faixa do infravermelho próximo, entre 700 a 900nm (RITCHIE *et al.*, 1976; LODHI *et al.*, 1998). Por isso a faixa do infravermelho é mais utilizada para obtenção da concentração de sólidos em suspensão. Segundo Matthews *et al.*, (2011), os comprimentos de onda mais utilizados para o estudo de características da água estão entre 400 e 1000nm (do visível ao infravermelho próximo). Este

fato é consistente com os dados observados na tabela 06. Entretanto, ainda segundo os autores, ainda não há um acordo com relação à quais são as melhores bandas ou razões de bandas para estimar CSS. Em geral, o uso da relação de bandas normaliza (reduz) os efeitos de espalhamento associados à granulometria do sedimento.

Os dados dessa pesquisa evidenciam que comprimentos de onda do infravermelho próximo foram os mais indicados para o estudo de baixas concentrações (aqui consideradas as $CSS < 100 \text{mg/L}$), indo de acordo com estudos similares (WU & CUI., 2008). Para altas concentrações (superiores a 100mg/L) a razão de bandas entre infravermelho e vermelho demonstrou uma maior eficiência na recuperação de dados de CSS do que as bandas únicas (Tabela 06) quando comparado aos resultados obtidos para concentrações inferiores a 100mg/L , isso condiz com outras pesquisas como as de Villar *et al.* 2013 e Robert *et al.*, 2016.

4.2.2 Potencialidade de sensores orbitais

Com relação à avaliação do sensor que melhor se adéqua aos objetivos propostos para a análise realizada, foi feita uma simulação das bandas espectrais com vista à determinação da concentração de sedimentos em suspensão a partir de dados de sensoriamento remoto orbital de três diferentes sensores: Landsat-8, MODIS e Sentinel-2. Essa simulação consistiu em verificar qual a melhor banda para cada corpo d'água em estudo com base nos menores valores de RMSE% e comparar com o centro de bandas dos três sensores orbitais.

A Figura 37 apresenta os comprimentos de onda abrangidos por diferentes sensores, dentre os quais estão inclusos o Landsat-8, o MODIS e o Sentinel-2. Essa figura por si só já fornece um bom panorama em relação os comprimentos de onda que se mostrarão mais adequados para fornecer o diagnóstico mais preciso quanto ao sensor apresenta-se mais eficiente para estudos dessa natureza.

O MODIS (*Moderate Resolution Imaging Spectroradiometer*) possui baixa resolução espacial, normalmente entre 250 e 1000 metros, o que a princípio pode ser considerado um fator limitante para o desenvolvimento de análises dessa natureza, apesar de o sensor apresentar características espectrais compatíveis com o objetivo do estudo em questão. No entanto algumas ressalvas merecem ser feitas, a começar pelo tempo de revisita quase diário, caracterizando sua resolução temporal como muito elevada.

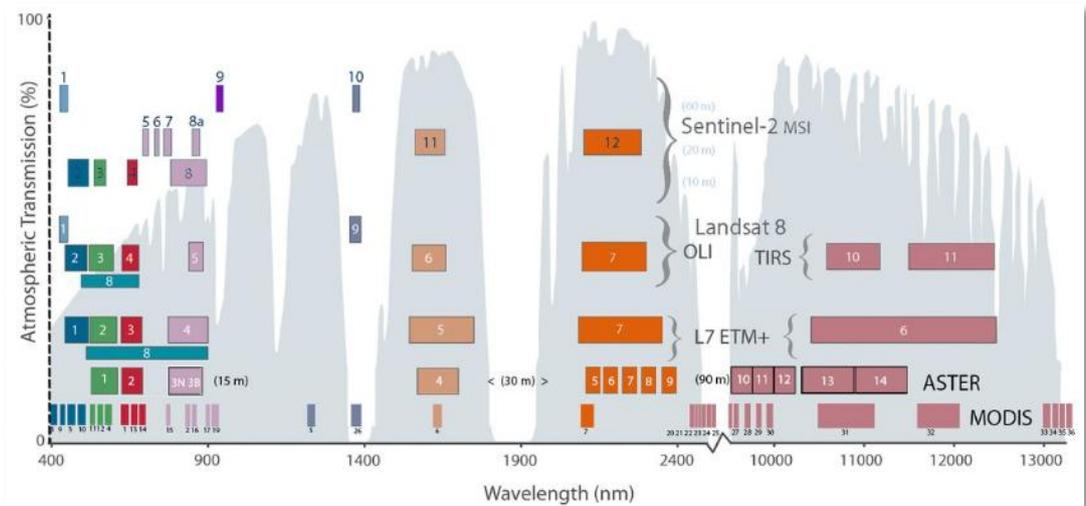


Figura 37: Comparação entre comprimentos de onda abrangidos por diferentes sensores, com destaque para o Landsat-8, MODIS e Sentinel-2. Fonte: NASA.

Alguns autores, tais como Miller e Mckee (2004), Chen *et al.*, (2007) e Doxaran *et al.*, (2009) obtiveram sucesso ao utilizarem o MODIS para monitorar a CSS. Robert *et al.*, (2016) utilizaram dados MODIS combinados com dados de reflectância obtidos em campo em uma região do oeste africano para avaliar a CSS. Os autores identificaram que a razão de bandas IV/V melhor se ajustou tanto aos dados de satélite como os dados obtidos por meio de saídas de campo.

Com relação ao sistema Landsat, a maioria dos trabalhos utiliza o sensor TM do Landsat-5 para avaliar a variação da CSS, não havendo muitos trabalhos que utilizam ainda o sensor OLI do Landsat-8. No entanto, o estudo desenvolvido por Cai, Tang & Li., (2015), no qual os autores investigaram a variação espacial da CSS nas águas da costa leste da China se deu a partir do uso de dados de ambos os sensores TM e OLI combinados com medidas realizadas em campo. O estudo utilizou dados derivados da banda do infravermelho próximo e demonstrou haver uma diferença significativa da CSS da área estudada, onde concluíram que os dados de sensoriamento remoto derivados dos sensores TM e OLI podem ser aplicados para investigar variações da CSS.

Bernardo *et al.*, (2016) avaliaram três diferentes sensores para verificar qual apresentou melhor ajuste para estimar a CSS na reservatório Barra Bonita, no estado de São Paulo. Dentre os sensores avaliados incluem o MODIS e o OLI. Enquanto os dados derivados do primeiro foram investigados devido a sua cobertura diária, o segundo foi utilizado devido à sua melhor resolução espacial, fato esse que favoreceu na obtenção de melhores resultados.

O Sentinel-2 possui 13 bandas na região do visível e do infravermelho. De acordo com dados do ESA (2017) a resolução espacial do sensor varia em função das bandas, sendo de 10 metros para 4 bandas, dentre as quais inclui a banda do vermelho, seis bandas com 20 metros, incluindo a banda correspondente ao infravermelho próximo, e três bandas com 60 metros de resolução.

Observando a figura 37 e baseando-se na simulação desenvolvida foi possível constatar que o sensor que melhor se ajusta à recuperação de MPS via sensoriamento remoto é aquele que apresenta comprimentos de onda próximo ao identificado como melhor (com base nos valores de RMSE%, tabela 06). Se for levado em consideração o comprimento de onda central correspondente às bandas do azul, verde, vermelho e infravermelho para os referidos sensores tem-se os valores apresentados na tabela 07.

Tabela 07: Centro de bandas para os sensores testados.

	SENTINEL 2	LANDSAT 8	MODIS 250-500 metros
AZUL	490nm	480nm	485nm
VERDE	560nm	560nm	570nm
VERMELHO	665nm	655nm	660nm
INFRAVERMELHO PRÓXIMO	705nm	865nm	840nm
	740nm		
	783nm		
	842nm		
	865nm		

É importante destacar que o Landsat-8 possui 11 bandas, sendo que uma delas abrange o vermelho e outra o infravermelho próximo. O mesmo ocorre com o MODIS, porém, este apresenta um total de sete bandas nos modos de resolução a 250 metros e 500 metros. Já com relação ao Sentinel-2, das 12 bandas que apresenta 1 abrange o vermelho e 5 o infravermelho próximo.

Para concentrações inferiores a 100mg/L, a maior parte dos campos apresentou melhores respostas nas faixas do infravermelho próximo (740nm; 800nm e 865nm), com a exceção do conjunto de pontos referente aos reservatórios do Nordeste, que obteve melhores respostas no verde (500nm), provavelmente devido a pigmentos fotossintetizantes em suspensão. Os rios Amazonas (RMSE% de 36,8%), Maroni (RMSE% de 11,6%), Paranapanema (RMSE% de 34,6%) e Solimões (RMSE% de 21,6%) apresentaram os menores valores de RMSE% para a faixa de 800nm. Acredita-se que qualquer um dos três

sensores pode ser utilizado com eficiência para o estudo destes corpos d'água nesse faixa de concentração.

Ainda nessa faixa de concentração, os rios Madeira (RMSE% de 12,7%), São Francisco (RMSE% de 29,8%) e Lago Paranoá (RMSE% de 51,3%) apresentaram menores valores de RMSE% para a faixa de 740nm, neste caso o uso do Sentinel- 2 parece ser o mais indicado. Já o Lago Bagré (RMSE% de 13,3%) e a amostra global (RMSE% de 47,0%) apresentaram menores valores de RMSE na faixa do 865nm. Neste caso há duas opções, pois tanto o Sentinel-2 Como o Landsat-8 apresentam centros de banda no infravermelho próximo.

Já para as áreas que apresentam concentrações entre 100mg/L e 500mg/L, o Sentinel-2 surge com uma melhor ferramenta frente ao MODIS e ao Landsat-8 para o estudo o Lago Bagré (com RMSE de 15,5% na faixa do 940nm), rio Madeira (com RMSE de 31,3% na faixa do 900nm), rio Solimões (com RMSE de 31,8% na faixa do 900nm), amostra global (com RMSE de 32,7% na faixa do 900nm). Já para os rios Amazonas (com RMSE de 20,5% na faixa do 865nm) e rio São Francisco (com RMSE de 16,6% na faixa do 865nm) tanto o Sentinel – 2 como o Landsat-8 podem ser utilizados como ferramenta de obtenção de CSS via sensoriamento remoto orbital.

Baseado no que foi apresentado anteriormente, é possível inferir que o Sentinel-2 mostra-se potencialmente mais adequado para avaliar a concentração de sólidos em suspensão de águas interiores com alta turbidez uma vez que em elevadas concentrações o Sentinel-2 se destacou por melhor identificar a presença de sólidos em suspensão em 60% dos rios avaliados no faixa de 100 a 500 mg/L. Dois fatores são fundamentais para validar essa afirmação: a resolução espacial e temporal do sensor. O Sentinel-2 possui tempo de revisita de 5 dias (juntando os dois satélites sentinel 2A e 2B), contra 16 do Landsat-8. Isso faz com que ele seja considerado um sensor de alta resolução temporal, dado o baixo intervalo entre a data de passagem do sensor em um mesmo ponto. Além disso, sua resolução espacial é melhor que o MODIS e o OLI.

4.2.3 Variação dos coeficientes lineares e angulares

Avaliando as variações entre os coeficientes lineares e angulares entres rios/reservatórios (Tabela 08) é possível entender o quanto uma equação é diferente da outra e o quanto as equações individuais de aproximam ou se distanciam da equação global. Assim,

juntamente com as informações relativas ao RMSE%, é possível identificar se o uso de um único modelo pode ser aplicado em áreas com o mesmo nível de concentração ou não. Devido ao grande volume de dados serão discutidos apenas os resultados referentes às bandas que apresentaram melhores resultados de RMSE% (650nm, 740nm, 865nm e a razão entre as bandas 865nm/650nm) vistas nas seções anteriores.

Tabela 08: Valores de coeficientes angulares e lineares para 650nm, 740nm, 865nm, 865/650nm no faixa de 0 a 100mg/L

		650	740	865	865/650
AMAZONAS	a	1935.6	3656.4	5618.5	172.4
	b	-3.7	3.5	6.4	-3.9
BAGRE	a	1401.4	1848.9	2719.9	223.9
	b	-54	-7.9	2.8	-6.8
MADEIRA	a	2091.6	4326.5	6983.9	435.3
	b	-16.6	-4.9	-1.8	-41.8
MARONI	a	1051.6	2955.6	3674.4	14.44
	b	3.8	5.7	15.8	29.8
PARANAPANEMA	a	1044.6	2626.4	4996.3	150.1
	b	-9	-1.6	-0.3	-4.4
PARANOÁ	a	738.4	2253.6	4178.6	56.92
	b	-0.8	1.1	1.5	-0.5
PURUS	a	1262.4	2627.8	4312	47.9
	b	-6.1	1.1	1.4	18.2
AÇUDES DO NE	a	1180	3130.2	5754.8	-4.1
	b	-2.8	-1.7	-1.2	8.3
SÃO FRANCISCO	a	1009.3	2894.7	5418.4	207.6
	b	-10.6	-3.5	-1.9	-6.6
SOLIMÕES	a	1712.4	3389.3	5292.8	226.5
	b	10.8	18.7	21.2	7.8
AMOSTRA GLOBAL	a	1219.2	3260.5	5660.8	206.6
	b	0.3	1.7	2.7	-7.1

Levando em conta que a média do coeficiente angular (“a”) é representada por 100% e analisando a variação desse coeficiente na faixa de 0 a 100mg/L para o modelo linear em termos de porcentagem em relação à média de “a” (Tabela 09), é possível ver que para o comprimento de onda a 650 nm quase todos os corpos d’água analisados mostram valores de “a” próximo à média do coeficiente linear de todos os corpos d’água (1342,7), bem como ao “a” da equação global (1819,2). A variação foi de 55% do valor médio de “a” para o Lago Paranoá até 155,8% do valor da média para o rio Madeira. Em termos de porcentagem, houve agrupamentos como, por exemplo, os rios São Francisco (75,2%), Paranapanema (77,8%) e Maroni (78,3%) apresentaram valores inferiores à média de “a”. Já os rios Purus (94%), reservatórios do Nordeste (87,9%) e a amostra global (98,8%) apresentaram valores inferiores

à média de “a” em torno de -9,1% sendo os que mais se aproximaram da média dos valores de coeficiente linear. Já os rios Madeira (155,8%), Amazonas (144,2%), Solimões (127,5%) e Lago Bagré (104,4%) apresentaram valores superiores a média. Onde o lago Bagré (a=1401.4) foi o que mais se aproximou do valor médio de “a” (a=1342,7).

Para 740nm, a variação do coeficiente angular quando comparado ao valor médio para este comprimento de onda foi de 62,2% no Lago Bagré até 145,6% no rio Madeira. Os rios Maroni (99,5%), São Francisco (97,4%), Purus (88,5%), Paranapanema (88,4%); e os Lagos Bagré (62,2%) e Paranoá (75,9%) apresentaram valores de “a” inferiores à média do coeficiente linear para esse comprimento de onda. Enquanto que os rios Solimões (+114,1%), Amazonas (123,1%) e Madeira (145,6%); os açudes do Nordeste (105,4%) e amostra global (109,7%) apresentaram valores superiores ao da média. Onde os rios que mais se aproximaram da média (a=2970,9) foram São Francisco (a=2894.7) e Maroni (a=2955.6).

Para o comprimento de onda de 865nm, o coeficiente angular variou em torno da média de “a”. Este variou de 54,6% no Lago Bagré até 142,7% no rio Madeira. Os rios Maroni (75,1%) e Purus (88,1%); e os Lagos Bagré (54,6%) e Paranoá (85,4%) apresentaram valores de “a” inferiores a média. Já os rios Paranapanema (102,1%), Solimões (108,1%), São Francisco (110,7%), Amazonas (114,8%), Amostra Global (115,6%), os açudes do Nordeste (117,6%) e o rio Madeira (142,7%) apresentaram valores acima da média. Os rios que mais se aproximaram da média (a=4894,9) foram o Maroni (a=3674.4) e o Paranapanema (a=4996.3).

Avaliando a razão de bandas entre 865/650nm, o coeficiente angular apresentou a variação mais brusca em relação à média de “a” dentre os testes. Variou de - 2,7% nos reservatórios do Nordeste até 284,3% no rio Madeira. Os rios Maroni (9,4%), Purus (31,3%), Paranapanema (-1,9%), Lago Paranoá (-62,8%), e reservatórios do Nordeste apresentaram valores inferiores a média o coeficiente linear. Já os rios Amazonas (112,6%), Amostra Global (134,9%), São Francisco (135,6%), Bagré (146,2%), Solimões (147,9%) e Madeira apresentaram valores acima da média. Dentre as áreas de estudo para essa razão de bandas o rio que mais se aproximou do valor médio (a=153,1) foi o Paranapanema (a=150.1).

Tabela 09: Variações do parâmetro a para concentrações entre 0 e 100mg/L

a	Mínimo	Média	Máximo	GLOBAL
650nm	738,4	1342,7	2091,6	1219,2
740nm	1848,8	2970,9	4326,5	3260,5
865nm	2719,9	4894,9	6983,9	5660,8
865/650nm	-4,11	153,1	435,3	206,6

Com relação ao parâmetro coeficiente linear (“b”) para as concentrações de 0 a 100mg/L (Tabela 10), foi possível perceber que para o 650nm, o coeficiente angular variou de -121,5% no rio Solimões a 606,7% no Lago Bagré para este comprimento de onda. A maioria dos rios apresentou valores inferiores ao da média do coeficiente linear, dentre estes os rios Maroni (-42,7%), a Amostra Global (-3%), o Lago Paranoá (8,5%), os Açudes do Nordeste (31,6%), os rios Amazonas (41,8%) e Purus (68,8%). Enquanto os rios Paranapanema (101,1%), São Francisco (118,9%), Madeira (186,7%) e Lago Bagré (606,7%) apresentaram valores acima da média. O rio Paranapanema foi o que mais se aproximou da média ($b=-8,9$) para este comprimento de onda apresentando um valor de $b=-9$.

Para 740nm os valores foram ainda mais extremos, o coeficiente linear variou de -795% no Lago Bagré a 1871% no rio Solimões. Os rios Madeira (-490%), São Francisco (-353%), Paranapanema (-161%), açudes do Nordeste (-169%) e Lago bagre apresentaram coeficiente muito inferiores a média. Já o Lago Paranoá (111%) e os rios Purus (111%), Amostra Global (174%), Amazonas (352%), Maroni (569%) e rio Solimões apresentaram valores acima da média. Para este comprimento de onda, o rio Purus ($b=1.1$) e o Lago Paranoá ($b=1.1$) foram os que mais se aproximaram do valor médio do coeficiente linear ($b=1$).

Para o comprimento de 865nm os dados variaram de -41,8% no rio São Francisco até 483% no rio Solimões. Os maioria dos rios apresentou valores de coeficiente linear inferiores a média (levando em conta que a média é representada por 100%), são eles rio São Francisco, rio Madeira (-40,2%), açudes do Nordeste (-28%), rio Paranapanema (-7%), Purus (32%), Lago Paranoá (33,4%) e amostra global (61,1%). Já os rios Amazonas (144,5%), Maroni (358,6%) e rio Solimões (483%) apresentaram valores bem acima da média. Assim, o rio Amazonas ($b=6.4$) e a amostra global ($b=2.7$) chegaram mais próximo ao valor médio de “b” para esse comprimento de onda ($b=4,4$).

Para a razão de bandas, não foi possível realizar o cálculo em porcentagem, pois a média do coeficiente foi igual a zero, gerando resultado indeterminado.

Tabela 10: Variações do parâmetro b para concentrações entre 0 e 100mg/L

b	Mínimo	Média	Máximo	GLOBAL
650nm	-54	-8,9	10,8	0,27
740nm	-7,9	1	18,71	1,7
865nm	-1,8	4,4	21,2	2,7
865/650nm	-41,7	0	29,7	-7,1

A tabela 11 apresenta os dados referentes à faixa de 100 a 500mg/L, para os mesmos comprimentos de onda (650nm, 740nm, 865nm e a razão entre as bandas 865nm/650nm). A tabela 12 mostra as variações dos coeficientes lineares. Para 650nm, o coeficiente linear (“a”) variou de 0,7% no Lago Bagré a 316,8% no rio São Francisco. Levando em consideração que a média é representada por 100%, pode-se afirmar que o Lago Bagré e os rios Solimões (33%) e Madeira (33,8%) apresentaram coeficientes abaixo da média. Enquanto que os rios Madeira (115,9%) e São Francisco, e a Amostra Global (157,3%) apresentaram valores de “a” superiores a média. Neste caso, o rio Amazonas (a=235,1) foi o que mais se aproximou do valor médio de coeficiente linear (a=202,9).

Tabela 11: Valores de coeficientes angulares e lineares para 650nm, 740nm, 865nm, 865/650nm no faixa de 100 a 500mg/L

		650	740	865	865/650
AMAZONAS	a	235.1	2416.3	1958.6	379.9
	b	0.1	0.7	0.6	0.9
BAGRE	a	1.3	280399.8	46909.3	651.6
	b	-2.1	2.3	1.6	1.4
MADEIRA	a	68.6	5161.4	6829.2	654.9
	b	-0.4	0.9	0.9	1.5
SÃO FRANCISCO	a	642.8	1593.6	1558.6	307.0
	b	0.5	0.7	0.6	0.7
SOLIMÕES	a	67.0	6189.2	14196.1	766.4
	b	-0.3	0.9	1.0	1.5
AMOSTRA GLOBAL	a	319.2	3092.2	4094.9	609.8
	b	0.1	0.8	0.8	1.4

Para 740nm, o coeficiente linear variou de 2,7% no rio São Francisco até 474% no Lago Bagré. Neste caso, apenas o Lago Bagré apresentou “a” superior à média, todos os outros corpos d’água apresentaram valores abaixo de 100% (Amazonas com 4,1%, amostra global com 5,2%, Madeira com 8,7%, Solimões com 10,5% e São Francisco com 2,7%). Aqui, nenhum dos rios/reservatórios apresentou coeficiente linear próximo ao da média (a=59.152,1).

No caso dos coeficientes lineares relativos ao comprimento de onda 865nm, “a” variou de 10,9% no rio São Francisco até 328% no Lago Bagre. Onde, novamente o único rio que apresentou coeficiente linear superior ao da média foi o Lago Bagré. Os rios São Francisco (10,9%), Amazonas (13,7%), Amostra global (28,7%), Madeira (47,8%) e Solimões (99,3%) apresentaram valores inferiores a média (100%). Aqui, o rio Solimões ($a=14.196,1$) revela “a” muito próximo ao da média ($a=14.290,4$)

Para a razão entre as bandas 865/650nm, o coeficiente linear variou de 55,6% no rio São Francisco até 138,8% para o rio Solimões. Para a razão de bandas o padrão inverte quando comparado com a avaliação de bandas únicas. Ocorre uma redução da variação, com aproximação do valor médio e um aumento dos valores de coeficientes quando comparados a média. Apenas dois rios apresentaram coeficiente linear inferiores a média (100%), o rio São Francisco e o rio Amazonas (68,8%). Já os rios Madeira (118%) e Solimões (138,8%), o Lago Bagré (118%) e a amostra global revelam coeficientes acima da média. Neste caso Lago Bagre (651.5) e rio Madeira (654.9) apresentam semelhanças entre os coeficiente e se aproximaram do valor médio de “a” ($a=552$), entretanto a amostra global apresentou uma maior proximidade com $a=609,8$.

Tabela 12: Variações do parâmetro “a” para concentrações entre 100 e 500mg/L

a	Mínimo	Média	Máximo	GLOBAL
650nm	1,34	202,9	642,8	319,2
740nm	1593,5	59.152,1	280.399,8	3092,2
865nm	1558,6	14.290,4	46.909,3	4094,9
865/650nm	307	552	766,4	609,8

Com relação ao coeficiente angular “b”, a tabela 13 apresenta os dados referentes ao faixa de 100 a 500nm, para os mesmos comprimentos de onda (650nm, 740nm, 865nm e a razão entre as bandas 865nm/650nm). Avaliando esse parâmetro para 650nm, observa-se que houve uma variação de -120% para o rio São Francisco até 532,5% no Lago Bagré. A maioria dos rios e reservatório apresentou valores inferiores a média (100%). Os rios são Francisco, Amostra global (-35%), e os rios Amazonas (-27,5%), Solimões (72,5%), apresentaram valores inferiores a média do coeficiente angular para este comprimento de onda. Enquanto que o Lago Bagré foi o único corpo d’água que apresentou um valor superior. Aqui, o rio Madeira ($b=-0.4$) foi o único que apresentou um coeficiente igual ao da média ($b=-0,4$).

Tabela 13: Variações do parâmetro “b” para concentrações entre 100 e 500mg/L

b	Mínimo	Média	Máximo	GLOBAL
650nm	-2,1	-0,4	0,5	0,1
740nm	0,7	1,1	2,3	0,8
865nm	0,6	0,9	1,6	0,8
865/650nm	0,9	1,2	1,5	1.4

Em 740nm, a variação foi de 61,8% no rio São Francisco até 212,7% no Lago Bagré. a maior parte dos rios apresentou coeficiente angular inferior a média (São Francisco; Amazonas com 66,4%; amostra global com 70%; Madeira com 80,9%; Solimões com 85,5%), exceto o Lago bagré, que novamente é único a apresentar um coeficiente angular acima da média. Neste caso, o rio que menos se afastou da média ($b=1,1$) foi o Solimões ($b=0.9$).

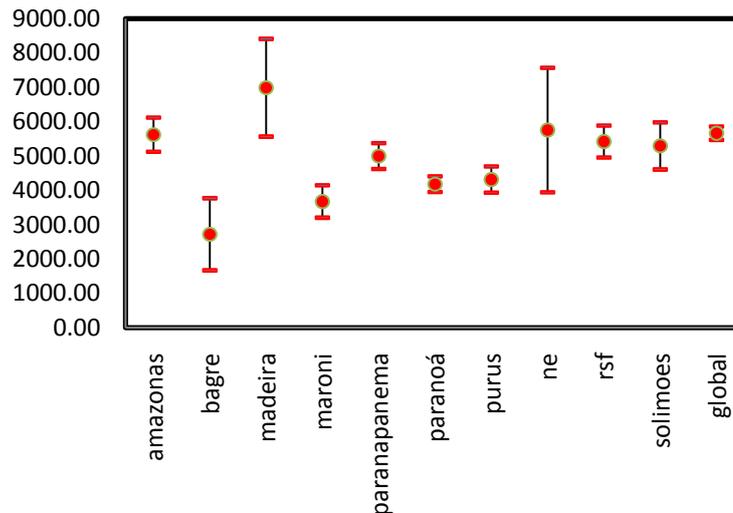
Para 865nm, o coeficiente variou de 66,7% no rio São Francisco a 175,6% no Lago Bagré. Os rios São Francisco, Amazonas (67,8%) e Amostra global (85,6%) apresentaram valores inferiores a média. Já o rio Solimões (115,6%) e o Lago Bagré apresentaram valores de “b” superiores a média. Aqui, novamente o rios Madeira apresenta um coeficiente igual ao da média ($b=0.9$) e o Solimões ($b=1.0$) bem próximo.

Para a razão entre as bandas 865/650nm, o coeficiente variou de 56,7% no rio São Francisco até 128,3% no rio Solimões. Os rios São Francisco e Amazonas (75%) apresentaram coeficiente abaixo da média. Já os rios Madeira (120,8%) e Solimões, Lago Bagre (115,8%) e a Amostra global (112,5%) apresentaram coeficientes superiores a media. O Lago Bagre (1.4) foi o corpo d’água que apresentou um coeficiente mais próximo ao da média ($b=1,5$), entretanto, para esta razão de bandas o coeficiente da amostra global ($b=1.4$) foi o que mais se ajustou à média ($b=1,2$).

Considerando os coeficientes lineares e angulares de acordo com a faixa de concentração, os dados revelam que para baixas concentrações ($CSS < 100\text{mg/L}$) houve uma maior dispersão dos dados nas bandas de 650nm e 740nm. Entretanto, é possível identificar que a menor dispersão ocorreu na banda de 865nm, levantando a hipótese de que este é o melhor comprimento de onda para avaliar CSS nessa faixa de concentração. Reforçando a idéia de que a utilização de uma única banda para essa faixa é mais apropriada para investigação de CSS via sensoriamento remoto, e que a mais adequada é a banda relativa ao

infravermelho próximo. Como os coeficientes da Amostra Global referentes ao melhor comprimento de onda (865nm) ficaram distantes da média, pode-se ainda afirmar que equações específicas para cada corpo d'água são mais indicadas nestes casos (Figura 38). Vale ressaltar que, neste caso, razão de bandas não foi eficiente para esse faixa.

a) Variação de "a" - 865nm



b) Variação de "b" - 865nm

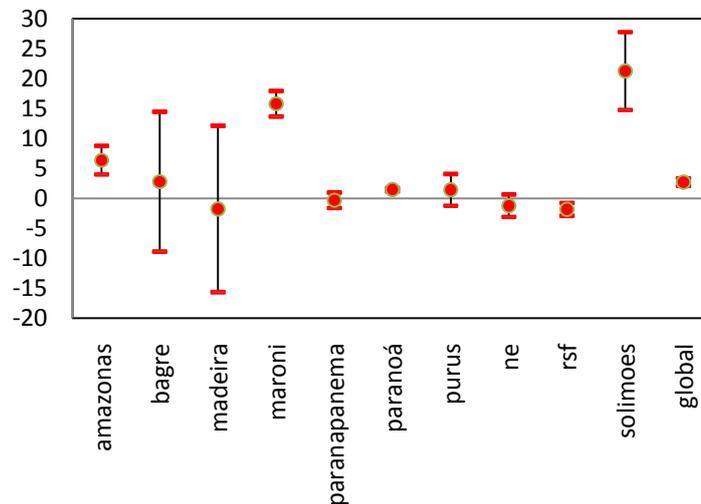


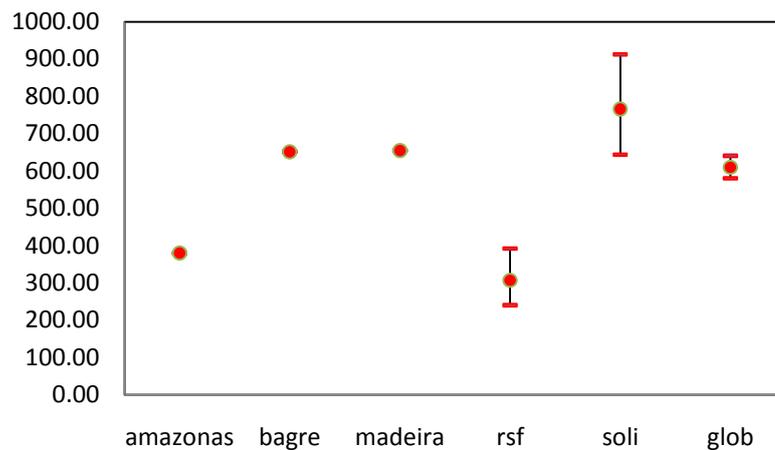
Figura 38: Variação dos valores: a) Coeficiente angular e b) Coeficiente linear; para concentrações de 0 a 100mg/L.

Ao contrário, para CSS superiores a 100mg/L, a dispersão foi reduzida principalmente para a razão de bandas. Observa-se que conforme aumentamos o comprimento de onda,

melhor é o ajuste os coeficientes ao valor médio relativo ao coeficiente do comprimento de onda em análise.

Analisando a variação dos coeficientes angular como os lineares relativos à razão de bandas (865/650nm) da Amostra Global para essa faixa de concentração é possível perceber que os valores dos coeficientes da Amostra Global chegam mais próximo dos valores médios de coeficiente angular e linear (Figura 39).

a) Variação de "a" - 865/650nm



b) Variação de "b" - 865/650nm

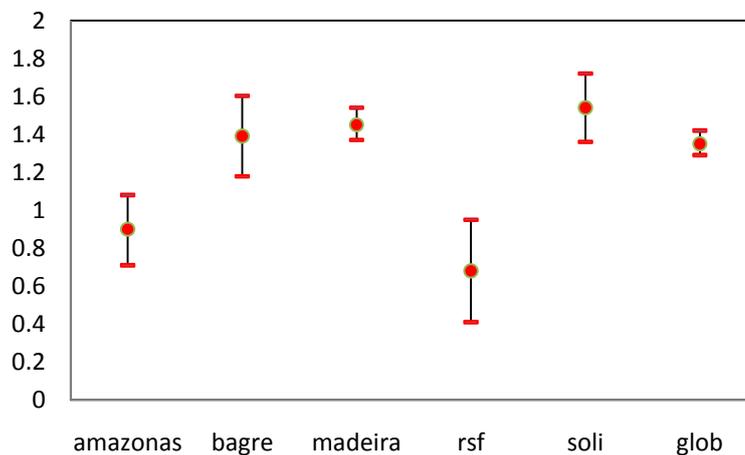


Figura 39: Variação do valores de : a) Coeficiente linear e b) Coeficiente angular; para concentrações entre 100 a 500mg/L

Fato que não se repete ao avaliar as bandas em separado (650nm, 740nm e 865nm) nessa faixa de concentração, que apresentam valores mais distantes da média. Reforçando a idéia de que a utilização de uma razão entre infravermelho e vermelho é uma melhor opção para esse faixa de concentração. Ainda com base nos coeficientes da razão de bandas, pode-se afirmar que equação da Amostra Global apresenta um grande potencial para representa cada corpo d'água de maneira individual.

4.2.4 Variação da raiz do erro médio quadrático (RMSE%) entre amostras

Para cada faixa de concentração avaliamos as performances de um modelo único com uma equação global (desenvolvido com todos os pontos de todos os campos) comparando com os modelos específicos (desenvolvidos para cada campo em separado). O objetivo foi avaliar se o uso de um modelo único seria adequado em vez de usar modelos diferenciados. Aplicou-se o modelo geral em cada rio para observar quando o erro aumenta ou diminui ao analisar os corpos d'água individualmente. Em seguida, foi feita a comparação entre os valores de RMSE% usando o modelo global ou o modelo de cada área. Este procedimento foi aplicado em todas as bandas, mas devido ao grande volume de dados serão analisados apenas os melhores resultados.

Para o faixa de 0 a 100mg/L (Figura 40), quando aplicamos o modelo global linear e avaliamos a diferença de erros entre o modelo global e o modelo linear de cada rio/reservatório, identificamos que a média de aumento de erro (RMSE) para o comprimento 650nm foi de 35,1%, variando de 0,8% (Maroni) a 108,4% (Bagré) entre as bacias. Nessa faixa do espectro a variação do erro usando um modelo global entre os rios Amazonas (13,8%) e Madeira (13,7%) foi muito similar, podendo assinalar uma semelhança da composição dos sedimentos destes rios. Os outros rios não seguiram nenhum padrão, apresentando maiores diferenças de valores de RMSE para os rios Paranapanema (72,7%), Paranoá (67,9%), São Francisco (48,8%) e Lago Bagré (108,4%), ou seja, eles apresentaram maiores erros ao usar o modelo global.

Na faixa de 865nm, a média de aumento de erro foi de 23,7%, variando de 1% (Amazonas) a 87,7% (Bagré) entre as bacias. Os rios Amazonas (1%), Madeira (5,1%) e Maroni (5,6%) apresentaram diferenças de valores inferiores a 6% de RMSE, mostrando um comportamento similar nesse comprimento de onda e que para estes casos não há uma

diferença significativa entre o modelo global e o modelo específico. Os rios São Francisco (9,9%), Solimões (10,7%), Purus (18,2%) e Açudes do nordeste (15,6%) apresentaram variações intermediárias, enquanto que Paranapanema (45,6%) e Bagré (87,7%) apresentaram as maiores diferenças entre ao aplicar o modelo global nos dados específicos de cada corpo d'água.

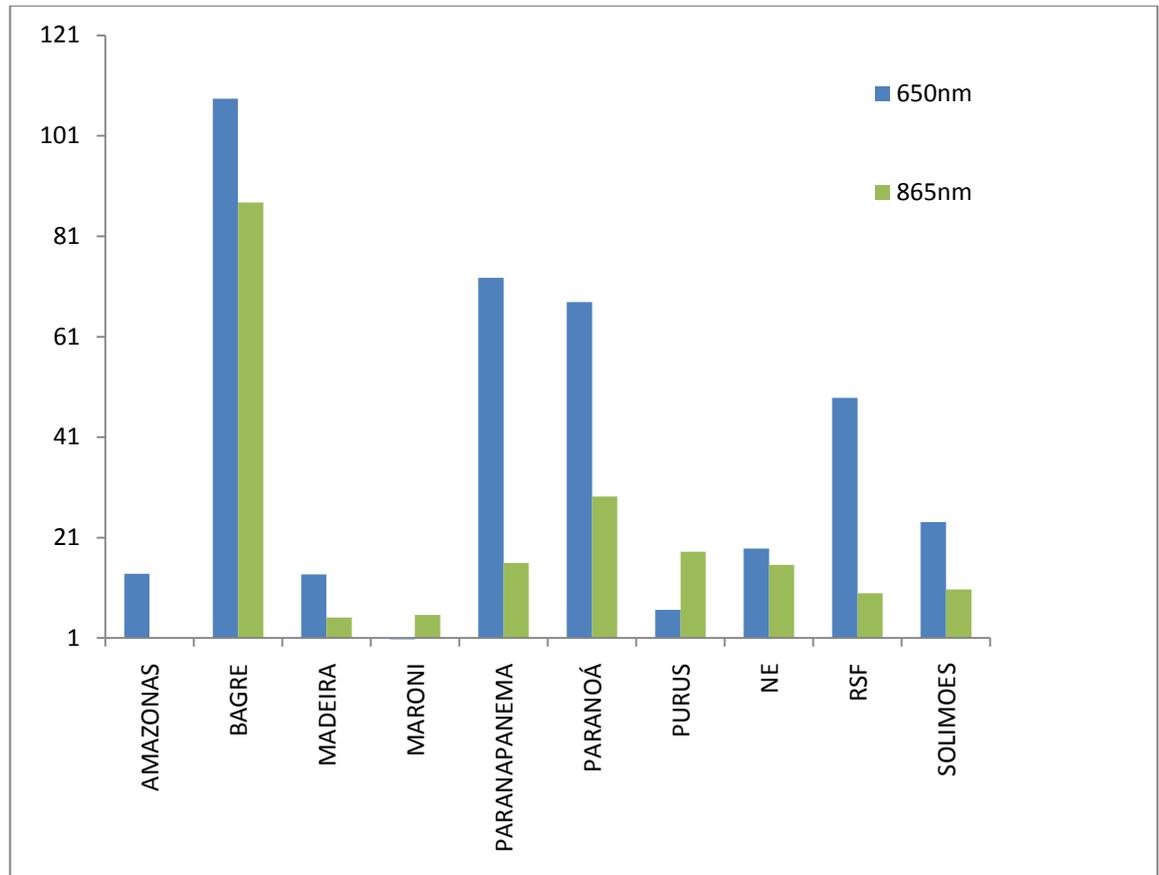


Figura 40: Variação de RMSE% para concentrações de 0 a 100mg/L (Onde: Δ RMSE% = RMSE% obtido na aplicação – RMSE% individual).

Para o faixa de 100 a 500mg/L (Figura 41) foi possível perceber que a média de aumento de erro (RMSE%) ao aplicar a equação global em relação ao uso dos modelos específicos para a faixa do 865nm, todos os campos apresentarem aumento de RMSE% inferior a 5% (Amazonas com 0,9%; Bagré com 2,1%; Madeira com 2,5%; Solimões com 4,5%), com exceção do rio São Francisco (RMSE de 23,3%).

Já para a razão de bandas entre 865/650nm a média do aumento de erros foi ainda menor (o RMSE% variou em média 2,02%) com valor mínimo 0,2 (Madeira) a 3,9% (São

Francisco). Para esse faixa de concentração a razão de bandas apresentou em todos os campos um aumento do erro inferior a 5% (Madeira com 0,2%; Bagré com 1,4; Amazonas com 1,6%%; Solimões com 3% e São Francisco com 3,9%).

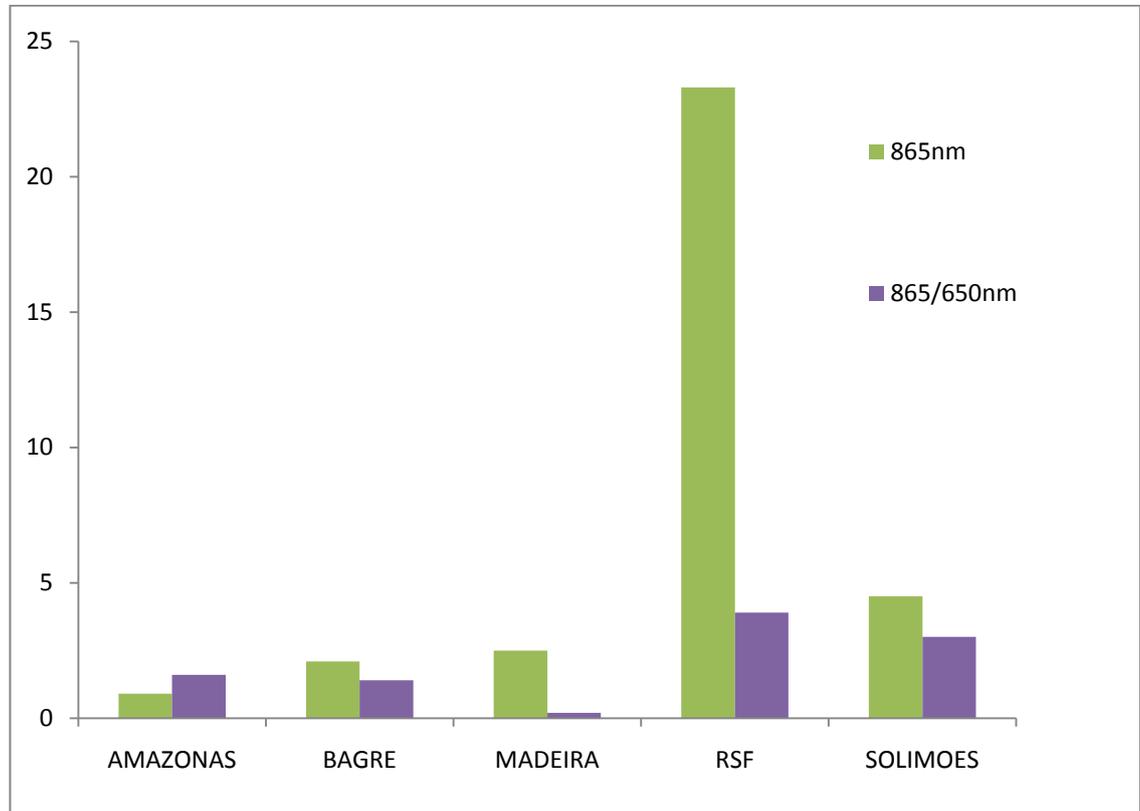


Figura 41: Variação de RMSE% para concentrações de 100 a 500mg/L (Onde: Δ RMSE% = RMSE% obtido na aplicação – RMSE% individual).

Esses testes demonstram que a análise de uma amostra global (incluindo todos os pontos de coleta) apresentou valores de RMSE% maiores que a análise individual, corroborando com o que já foi constatado por Chen *et al*, 2015, que afirma não ser adequado avaliar todos os dados juntos, pois dessa forma a análise irá gerar valores de RMSE % muito alto, reduzindo a confiabilidade da informação e que o ideal é realizar a avaliação de RMSE por faixa de concentração, para evitar erros associados à saturação do sinal relativo a altas concentrações. Porém, o uso de um modelo único (baseado em uma razão de bandas) demonstrou-se muito eficiente para águas com concentrações altas de sedimentos, “perdendo” para os modelos individuais de apenas algumas percentagens. Esse ponto é muito importante na ótica de um monitoramento automatizado de rios no Brasil e na América do Sul.

CAPÍTULO 5 – CONCLUSÕES

A partir da integração dos dados de refletância e concentração de sedimentos em suspensão de diferentes regiões do país foi possível ter uma ideia do funcionamento do comportamento espectral dos sedimentos em suspensão em diversos ecossistemas brasileiros e permitiu o início da construção de uma base de dados nesse sentido. Uma importante fonte de informação para cientistas e órgãos de monitoramento de qualidades da água.

Avaliando a escolha dos modelos de regressão, para baixas concentrações de sedimento em suspensão ($CSS < 100 \text{mg/L}$) o modelo linear explica a relação entre refletância e CSS, enquanto que para altas concentrações ($CSS > 100 \text{mg/L}$) o modelo potência mostrou-se mais adequado.

Com base nos menores valores de RMSE%, foi possível identificar qual a melhor banda do espectro para o estudo da concentração de MPS de acordo com o faixa estabelecida. De maneira geral, corpos d'água com baixas concentrações de sólido em suspensão ($CSS < 100 \text{mg/L}$) apresentaram melhores resposta em comprimentos de onda compreendidos na faixa do infravermelho próximo, enquanto que regiões com altas concentrações ($CSS > 100 \text{mg/L}$), o modelo apresentaram melhores resultados para razões de bandas entre infravermelho/vermelho.

Os algoritmos obtidos por meio dos modelos foram desenvolvidos com o objetivo de determinar a concentração de sedimentos em suspensão a partir da reflectância. Com base nos valores de RMSE% e nos coeficientes (lineares e angulares) foi possível avalia-se a possibilidade de aplicação de um único algoritmo para todas as amostras. Assim, foi possível perceber que para baixas CSS ($CSS < 100 \text{mg/L}$) a diferença entre um modelo global e o modelo específico de cada bacia apresentou grandes variações de erro (RMSE%) levando a hipótese de que o uso de um único modelo não seja adequado para concentrações inferiores a 100mg/L , sendo melhor desenvolver um modelo para cada corpo d'água ou região.

Enquanto, que para regiões com concentrações superiores a essa faixa a aplicação de um único algoritmo não apresentou grandes variações de RMSE%, levando a crer que, a aplicação de um modelo global nessa faixa de concentração para a banda do infravermelho (865nm) e para a razão de bandas entre infravermelho e vermelho (865/650) gera dados próximos aos encontrado com modelos individuais.

Nessa pesquisa, foi possível perceber que para baixas concentrações tanto o sensor Sentinel- 2 como Landsat – 8 e MODIS são boas ferramentas de recuperação de CSS via sensoriamento remoto orbital. Entretanto, para regiões com CSS superiores a 100mg/L o sensor Sentinel- 2 e o Landsat demonstraram um maior potencial frente ao MODIS, sendo o Sentinel-2 ainda mais indicado dentre os três devido a apresentar uma resolução espectral com mais bandas na faixa do infravermelho próximo.

CONSIDERAÇÕES FINAIS

No desenvolvimento da pesquisa tivemos algumas dificuldades com relação à recuperação de dados, pois os dados foram recolhidos de várias instituições de pesquisa e cada uma realizava a coleta e o armazenamento de maneira diferente, embora os dados fossem coletados com o mesmo tipo de sensor e o mesmo protocolo de campo. Porém, não existia uma sistemática para organização e processamento com vista à padronização dos dados. Deste modo, podemos considerar como um grande avanço na sistematização e análises dos dados de radiometria do protocolo de padronização e organização dos dados radiométricos estabelecidos nesta dissertação (APENDICE A e B). Este servirá de subsídio para pesquisas similares (com uso de radiômetros da RAMSES da TriOS) e facilitará a modelagem e implementação de um Sistema Gerenciador de Banco de Dados Espaciais para parâmetros hidrológicos por meio de sensoriamento remoto para corpos d'água brasileiros.

Os produtos de sensoriamento remoto da água podem funcionar como complemento para dados *in situ* de forma eficiente e abrangente, com uma ótima relação custo-benefício para o monitoramento da qualidade da água de grandes áreas (países e continentes, por exemplo), pois permite a recuperação de concentração de sólidos em suspensão de forma sinóptica.

Recomendo que futuramente sejam realizados:

- 1) Testes de dados reais de sensoriamento remoto;
- 2) Observações de outras regiões do Brasil e do Mundo;
- 3) Testar outras faixa do espectro eletromagnético e razões de bandas
- 4) Realizar análises estatísticas mais robustas para validar os modelos
- 5) Ampliar o estudo pra outros componentes opticamente ativos
- 6) A consolidação do modelo conceitual do banco de dados e sua implementação do Posgre/postGis; e a Disponibilização dos dados via GISWEB.

REFERÊNCIAS BIBLIOGRÁFICAS

Agência Nacional de Águas- ANA (2007). **GEO Brasil : recursos hídricos : resumo executivo.** / Ministério do Meio Ambiente ; Agência Nacional de Águas ; Programa das Nações Unidas para o Meio Ambiente. Brasília : MMA; ANA, 2007.

Agência Nacional de Águas- ANA (2013). **Conjuntura dos recursos hídricos no Brasil: 2013/** Agência Nacional de Águas. -- Brasília: ANA, 2013.

ALCÂNTARA, E., CURTARELLI, M., & STECH, J. (2016). Estimating total suspended matter using the particle backscattering coefficient: results from the Itumbiara hydroelectric reservoir (Goiás State, Brazil). **Remote Sensing Letters**, 7(4), 397-406.

ANDRADE, E. M. D., ARAÚJO, L. D. F., ROSA, M. F., DISNEY, W. C. D. R. H. D. E. D. C., & ALVES, A. B. (2007). Seleção dos indicadores da qualidade das águas superficiais pelo emprego da análise multivariada. **Engenharia agrícola.**

AUSTIN, R. W. (1974). The remote sensing of spectral radiance from below the ocean surface. **Optical aspects of oceanography.**

BARBOSA, C. C. F. (2005). **Sensoriamento remoto da dinâmica de circulação da água do sistema planície de Curuaí/Rio Amazonas.** São José dos Campos, 281.

Barbosa, C., Ferreira, R., Araujo, C., & Novo, E. (2014, July). Bio-optical characterization of two Brazilian hydroelectric reservoirs as support to understand the carbon budget in hydroelectric reservoirs. In *Geoscience and Remote Sensing Symposium (IGARSS), 2014 IEEE International* (pp. 898-901). IEEE.

BERNARDO, N., & ALCÂNTARA, E. (2017). Comparing proximal remote sensing and orbital images to estimate the total suspended matter in inland water. **Modeling Earth Systems and Environment**, 3(1), 19.

BERNARDO, N., WATANABE, F., RODRIGUES, T., & ALCÂNTARA, E. (2016). Evaluation of the suitability of MODIS, OLCI and OLI for mapping the distribution of total suspended matter in the Barra Bonita Reservoir (Tietê River, Brazil). **Remote Sensing Applications: Society and Environment**, 4, 68-82.

BERTHOLDO, L., JÚNIOR, L. C., DE ARAGÃO UMBUZEIRO, G., & DA SILVA, C. G. (2013). Mineração de Dados de Qualidade de Água para Agrupamento de Pontos de Amostragem Usados no Monitoramento de Recursos Hídricos. **WCAMA-CSBC**, 1, 1036-1046.

BINDING, C. E., BOWERS, D. G., & MITCHELSON-JACOB, E. G. (2005). Estimating suspended sediment concentrations from ocean colour measurements in moderately turbid waters; the impact of variable particle scattering properties. **Remote sensing of Environment**, 94(3), 373-383.

BOLDRIN, A., LANGONE, L., MISEROCCHI, S., TURCHETTO, M., & ACRI, F. (2005). Po River plume on the Adriatic continental shelf: dispersion and sedimentation of dissolved and suspended matter during different river discharge rates. **Marine Geology**, 222, 135-158.

BOWERS, D. G., EVANS, D., THOMAS, D. N., ELLIS, K., & WILLIAMS, P. L. B. (2004). Interpreting the colour of an estuary. **Estuarine, Coastal and Shelf Science**, 59(1), 13-20.

CAI, L., TANG, D., & LI, C. (2015). An investigation of spatial variation of suspended sediment concentration induced by a bay bridge based on Landsat TM and OLI data. **Advances in Space Research**, 56(2), 293-303.

CALLÈDE, J., COCHONNEAU, G., ALVES, F. V., GUYOT, J. L., GUIMARÃES, V. S., & DE OLIVEIRA, E. (2010). Les apports en eau de l'Amazonie à l'Océan Atlantique. **Revue des sciences de l'eau/Journal of Water Science**, 23(3), 247-273.

CARVALHO, N.O; FILIZOLA JÚNIOR, N.P; SANTOS , P.M.C, LIMA,J.E.F.W. Guia de práticas sedimentométricas. Brasília: ANEEL.2000. 154p.

CHEN, S., HAN, L., CHEN, X., LI, D., SUN, L., & LI, Y. (2015). Estimating wide range Total Suspended Solids concentrations from MODIS 250-m imageries: An improved method. *ISPRS Journal of Photogrammetry and Remote Sensing*, 99, 58-69.

CHEN, Z., HU, C., & MULLER-KARGER, F. (2007). Monitoring turbidity in Tampa Bay using MODIS/Aqua 250-m imagery. **Remote sensing of Environment**, 109(2), 207-220.

CURTARELLI, M. P., OGASHAWARA, I., ALCÂNTARA, E. H., & STECH, J. L. (2015). Coupling remote sensing bio-optical and three-dimensional hydrodynamic modeling to study the phytoplankton dynamics in a tropical hydroelectric reservoir. **Remote Sensing of Environment**, 157, 185-198.

DEKKER, A. G. (1993). Detection of optical water quality parameters for eutrophic waters by high resolution remote sensing.

DOXARAN, D., FROIDEFOND, J. M., LAVENDER, S., & CASTAING, P. (2002). Spectral signature of highly turbid waters: Application with SPOT data to quantify suspended particulate matter concentrations. **Remote sensing of Environment**, 81(1), 149-161.

DURAND, N., FIANDRINO, A., FRAUNIE, P., OUIILLON, S., FORGET, P., & NAUDIN, J. J. (2002). Suspended matter dispersion in the Ebro ROFI: an integrated approach. **Continental Shelf Research**, 22(2), 267-284.

E. S. A. Team (2017). **GMES Sentinel-2 Mission Requirements Document**. EOP-SM/1163/MR. dr, 2.

GEMS - Global Environment Monitoring System (2003). **Improving global water quality monitoring**. Washington: United Nation Environment Program - 2003. 18p. Technical Advisory Paper n.1.

HOOPER, R. P. (1997). Sediment sampling in the national stream quality accounting network. In **US Geological Survey**. Sediment Workshop, Atlanta.

JENSEN, J. R., & EPIPHANIO, J. C. N. (2009). **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São José dos Campos: Parêntese Editora.

JERLOV, N. G. (1976). **Marine optics** (Vol. 14). Elsevier.

JERLOV, N. G., AND E. STEEMASN NIELSEN (1974). **Optical aspects of oceanography**. Academic Press, London and New York, 494 p.

KAMPEL, M., & NOVO, E. M. L. M. (2005). O sensoriamento remoto da cor da água. **Oceanografia por satélites**. São Paulo: Oficina de Textos, 179-196.

KIRK, J.T.O. **Light & Photosynthesis in Aquatic Ecosystems**, London, Cambridge University Press, 1994, v. 2, p. 507.

LIHAN, T., SAITOH, S. I., IIDA, T., HIRAWAKE, T., & IIDA, K. (2008). Satellite-measured temporal and spatial variability of the Tokachi River plume. **Estuarine, Coastal and Shelf Science**, 78(2), 237-249.

LIU, J. T., CHAO, S. Y., & HSU, R. T. (2002). Numerical modeling study of sediment dispersal by a river plume. **Continental Shelf Research**, 22(11), 1745-1773.

LODHI, M. A., RUNDQUIST, D. C., HAN, L., & KUZILA, M. S. (1998). Estimation of suspended sediment concentration in water using integrated surface reflectance. **Geocarto International**, 13(2), 11-15.

MARTINEZ, J. M., ESPINOZA-VILLAR, R., ARMIJOS, E., & SILVA MOREIRA, L. (2015). The optical properties of river and floodplain waters in the Amazon River Basin: Implications for satellite-based measurements of suspended particulate matter. **Journal of Geophysical Research: Earth Surface**, 120(7), 1274-1287.

MARTINEZ, J. M., GUYOT, J. L., FILIZOLA, N., & SONDAG, F. (2009). Increase in suspended sediment discharge of the Amazon River assessed by monitoring network and satellite data. **Catena**, 79(3), 257-264.

MATTHEWS, M. W. (2011). A current review of empirical procedures of remote sensing in inland and near-coastal transitional waters. **International Journal of Remote Sensing**, 32(21), 6855-6899.

MEDEIROS, P. P., DOS SANTOS, M. M., CAVALCANTE, G. H., DE SOUZA, W. F. L., & DA SILVA, W. F. (2014). Características ambientais do Baixo São Francisco (AL/SE): efeitos de barragens no transporte de materiais na interface continente-oceano. **Geochimica Brasiliensis**, 28(1), 65.

MENESES, P. R., ALMEIDA, T. D., ROSA, A. N. D. C. S., SANO, E. E., SOUZA, E. B. D., BAPTISTA, G. M. D. M., & BRITES, R. S. (2012). **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UNB/CNPq.

MENEZES, P. H. B. J. (2013). **Estudo Da Dinâmica Espaço-Temporal Do Fluxo De Sedimentos A Partir Das Propriedades Ópticas Das Águas No Reservatório De Três Marias-Mg** (Doctoral dissertation, Instituto de Geociências).

MILLER, R. L., & MCKEE, B. A. (2004). Using MODIS Terra 250 m imagery to map concentrations of total suspended matter in coastal waters. **Remote sensing of Environment**, 93(1), 259-266.

MOBASHERI, M. R. & HAMID, M. (2004) **Remote Sensing of suspended sediments in surface waters, using MODIS images**. Iran. 6p.

MOBLEY, C.D (1994) "Optical Properties of Water", in **Handbook of Optics**, Second Edition, M. Bass, editor, copyright 1994 by McGraw-Hill, Inc. Reproduced by permission of McGraw-Hill, Inc.

MOLLERI, G. S., NOVO, E. M. D. M., & KAMPEL, M. (2010). Space-time variability of the Amazon River plume based on satellite ocean color. **Continental Shelf Research**, 30(3), 342-352.

Montanher, O. C., Novo, E. M., Barbosa, C. C., Rennó, C. D., & Silva, T. S. (2014). 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**, 29, 67-77.

MONTES-HUGO, M. A., VERNET, M., SMITH, R., & CARDER, K. (2008). Phytoplankton size-structure on the western shelf of the Antarctic Peninsula: a remote-sensing approach. **International Journal of Remote Sensing**, 29(3), 801-829.

MORAES, B. C. (2013). **Avaliação Do Uso De Imagens Do Sensor Modis No Estudo Da Pluma De Sedimentos Do Rio Amazonas** (Doctoral dissertation, Universidade Federal do Rio de Janeiro).

MOREL, A.; PRIEUR, L. Analysis of variations in ocean color. (1977). **Limnology and Oceanography**, v.22, p. 709-722.

NASCIMENTO ET AL, 2011. Uso de dados MERIS/ENVISAT em águas interiores. **In: Novas tecnologias para o monitoramento e estudo de reservatórios hidrelétricos e grandes lago.** ALCÂNTARA, E.H, NOVO, E.M.L.M, STECH, J.L., Rio de Janeiro, Ed. Parenteses, 2011.

NÉGREL, P., & LACHASSAGNE, P. (2000). Geochemistry of the Maroni River (French Guiana) during the low water stage: implications for water-rock interaction and groundwater characteristics. **Journal of Hydrology**, 237(3), 212-233.

NEZLIN, N. P., & DIGIACOMO, P. M. (2005). Satellite ocean color observations of stormwater runoff plumes along the San Pedro Shelf (southern California) during 1997–2003. **Continental Shelf Research**, 25(14), 1692-1711.

NOVO, E. M. L. M.(2001) Comportamento Espectral da Água. In: MENESES, P. R.; MADEIRA NETTO, J.S. **Sensoriamento Remoto: Reflectância dos Alvos Naturais.** Brasília: UnB; Embrapa Cerrados, 2001. p.203-222.

PAIVA, E.M.C.D.(2003) Métodos de estimativa da produção de sedimentos em pequenas bacias hidrográficas. In PAIVA, E.M.C.D.; PAIVA, J.B.D. (Orgs.). **Hidrologia aplicada à gestão de pequenas bacias hidrográficas.** Porto Alegre: Associação Brasileira de Recursos Hídricos, 2003. p. 493-506.

PINTO, C. E., MENEZES, P.H., MARTINEZ, J-M, ROIG, H E VILLAR R. (2014) Uso de imagens MODIS no monitoramento do fluxo de sedimentos no reservatório de Três Marias. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.18, n.5, p.507–516, 2014.

PISCOYA, R.C.C.C.; MARTINEZ, J.M.; LOPES, W.T. A; COCHONNEAU, G.; NOGUEIRA, M.G., VENTURA, D.; VIEIRA, M.R.; OLIVIERA, E. (2013). Caracterização do fluxo de sedimentos no reservatório da UHE Jurumirim utilizando dados do sensor espacial MODIS. In **Anais do XIX Simpósio Brasileiro de Recursos Hídricos**, Bento Gonçalves, Nov. 2013.

PISCOYA, R.C.C.C.; MARTINEZ, J.M.; LOPES, W.T. A; COCHONNEAU, G.; VILLAR, R.E.; VENTURA, D.; VIEIRA, M.R.; OLIVIERA, E. (2014). Utilização do sensor espacial MODIS para monitoramento da concentração de sedimentos em suspensão no reservatório da Usina de Itaipu no rio Paraná. In **Anais do XI Encontro Nacional de Engenharia de Sedimentos**, João Pessoa, Nov. 2014.

PREISENDORFER, R. W. (1976). **Hydrologic Optics. Volume 5. Properties.** Honolulu: US Dept. of Commerce, National Oceanic and Atmospheric Administration, Environmental Research Laboratories, Pacific Marine Environmental Laboratory.

RAJESH E DWARAKISH, 2015. Satellite oceanography- A review. International Conference On Water Resources, Coastal And Ocean Engineering (ICWRCOE 2015). **Aquatic Procedia** 4 (2015) 165 – 172

RITCHIE, J. M., R. B. ROGART, AND G. R. STRICHARTZ (1976). "A new method for labelling saxitoxin and its binding to non-myelinated fibres of the rabbit vagus, lobster walking leg, and garfish olfactory nerves." **The Journal of physiology** 261.2 (1976): 477.

ROBERT, E., GRIPPA, M., KERGOAT, L., PINET, S., GAL, L., COCHONNEAU, G., & MARTINEZ, J. M. (2016). Monitoring water turbidity and surface suspended sediment concentration of the Bagre Reservoir (Burkina Faso) using MODIS and field reflectance data. **International Journal of Applied Earth Observation and Geoinformation**, 52, 243-251.

RODRIGUES, T. ; ALCANTARA, E.H. ; WATANABE, F ; ROTTA, L ; IMAI, N. N. ; CURTARELLI, M. ; BARBOSA, C. Comparação entre métodos empíricos para estimativa da concentração de clorofila-a em reservatórios em cascata (Rio Tietê, São Paulo). RBC. **Revista Brasileira de Cartografia** (Online), v. 1, p. 181-192, 2016.

RUDORFF, C. M. **Estudo da composição das águas da planície amazônica por meio de dados de reflectância do sensor Hyperion/EO-1 e de espectrômetro de campo visando à compreensão da variação temporal dos seus constituintes opticamente ativos.**: Instituto Nacional de Pesquisas Espaciais. Dissertação (Mestrado) INPE-14166-TDI/1083, São Jose dos Campos – SP. 166 p. 2006.

RUDORFF, B.F.T., SHIMABUKURO, Y. E., CEBALLOS, J.C. **O Sensor Modis E Suas Aplicações Ambientais No Brasil.** São José dos Campos, S P. Editora Parêntese. Ed.2007.

SIVIERO, M.R.L.; COIADO, E.M. Produção de sedimentos a montante de uma seca no rio Atibaia associada a descarga sólida transportada. **Anais do XII Simpósio Brasileiro de Recursos Hídricos.** Belo Horizonte, MG. ABRH. 1999.

SOUZA, R.B. 2003. **Sensoriamento Remoto Dos Oceanos.** Espaço & Geografia, Vol.6, No 1 (2003), 123:145 ISSN: 1516-9375

TARRANT, P.E., AMACHER, J.A., NEUER, S., (2010). Assessing the potential of Medium- Resolution Imaging Spectrometer (MERIS) and Moderate-Resolution Imaging Spectroradiometer (MODIS) data for monitoring total suspended matter in small and intermediate sized lakes and reservoirs. **Water Resour. Res.** 46 (9), W09532.

TUCCI, CARLOS E. M. **Gestão da água no Brasil – Brasília : UNESCO,** 2001. 156p. ISBN: 85-87853-26-0

VILLAR, R. A.E (2013,b). Monitoramento das dinâmicas espaciais e temporais dos fluxos sedimentares na Bacia Amazônica a partir de imagens de satélite / Raúl Arnal do Espinoza Villar. - - 2013

VILLAR, R. E, MARTINEZ, J.M., LE TEXIER, M., GUYOT, J.L., FRAIZY, P., MENESES, P. R., DE OLIVEIRA, E. (2013a). A study of sediment transport in the Madeira River, Brazil, using MODIS remote-sensing images. **Journal of South American Earth Sciences**, V. 44, 45–54 p. 2013.

VILLAR, R. E., MARTINEZ, J. M., GUYOT, J. L., FRAIZY, P., ARMIJOS, E., CRAVE, A., ... & LAVADO, W. (2012a). The integration of field measurements and satellite observations to determine river solid loads in poorly monitored basins. **Journal of hydrology**, 444, 221-228.

VILLAR, R.E; MARTINEZ, J. M.; GUYOT, J. L.; FRAIZY, P.; ARMIJOS, E.; CRAVE, A.; BAZÁN, H.; VAUCHEL, P.; LAVADO, W.(2012b). The integration

of field measurements and satellite observations to determine river solid loads in poorly monitored basins. **Journal of Hydrology**, v.44, p.45-54. 2012.

WANG, H.Q., HLADIK, C.M., HUANG, W.R., MILLA, K., EDMISTON, L., HARWELL, M.A., SCHALLES, J.F., (2010a). Detecting the spatial and temporal variability of chlorophyll-a concentration and total suspended solids in Apalachicola Bay, Florida using MODIS imagery. **Int. J. Remote Sens.** 31 (2), 439–453.

WANG, J., LU, X., LIEW, S.C., ZHOU, Y., (2010b). Remote sensing of suspended sediment concentrations of large rivers using multi-temporal MODIS images: an example in the Middle and Lower Yangtze River. China. **International Journal of Remote Sensing.** 31 (4), 1103–1111.

WOODRUFF, D. L.; STUMPF, R.P.; SCOPE, J.A., PAERL, H.W. (1999). Remote estimation of water clarity in optically complex estuarine waters. **Remote Sensing of Environment.** 68:41-52.

WU, G., CUI, L., & JI, W. (2008). Time-series MODIS images-based retrieval and change analysis of suspended sediment concentration during flood period in Poyang Lake. **Journal of Lake Science**, 28(12), 6113-6120

Efron, B., & Tibshirani, R. J. (1994). *An introduction to the bootstrap*. CRC press.

APÊNDICE

APÊNDICE A

- **PRÉ-TRATAMENTO NO EXCEL**

A reflectância sensoramento remoto é calculada usando três radiômetros diferentes: 1- Um sensor de radiância aponta para o céu que mede a intensidade da luz de subsidência (Ld); 2- Um sensor de radiância aponta para a água que mede a intensidade da luz de ressurgência (Lu); 3- Um sensor de irradiância apontou para o céu que mede a intensidade da luz subsidência (Ed). Estes dados são coletados em campo (TriOS) e armazenados automaticamente em uma base de dados (MASDA-XE). Durante a amostragem, esses três componentes têm de ser especificado no arquivo MSDA-XE como Ld Deck, Lu Deck e Ed Deck (Figura 01). A especificação "Deck" significa que as medições são recolhidas a partir do convés do barco (e não na água). No laboratório, é realizada a seleção dos melhores dados para cada ponto de coleta na base de dados do MSDA_XE. O primeiro passo do tratamento dos referidos dados consiste de uma exportação destes três arquivos separadamente.

08/12/2014 13:35:03	6849_2014-12-08_1	SAM_8429	Lu	SPECTRUM	Deck	RAW
08/12/2014 13:35:03	6849_2014-12-08_1	SAM_8429	Lu	SPECTRUM	Deck	CALIBRATE
08/12/2014 13:35:03	6849_2014-12-08_1	SAM_842A	Ld	SPECTRUM	Deck	RAW
08/12/2014 13:35:03	6849_2014-12-08_1	SAM_842A	Ld	SPECTRUM	Deck	CALIBRATE
08/12/2014 13:35:03	6849_2014-12-08_1	SAMIP_508A	Ed	SAMIP	Deck	RAW
08/12/2014 13:35:03	6849_2014-12-08_1	SAM_8418	Ed	SPECTRUM	Deck	RAW
08/12/2014 13:35:03	6849_2014-12-08_1	IP_c0b0	Ed	Pressure	Deck	Calibrated
08/12/2014 13:35:03	6849_2014-12-08_1	IP_c0b0	Ed	Inclination	Deck	Calibrated
08/12/2014 13:35:03	6849_2014-12-08_1	SAM_8418	Ed	SPECTRUM	Deck	CALIBRATE

Figura 01: Demonstração da interface MSDA_XE

Para cada ficheiro deve-se verificar se estão ativados: Deck, Espectrum, Calibrado. Após ativação destes requisitos, o usuário deve avaliar as curvas e selecionar somente os dados bons pra exportar (o número de linhas deve ser o mesmo para Lu, Ld e Ed – em cada ponto) Somente deverão ser exportados os arquivos dentro destes padrões (Figura 02).

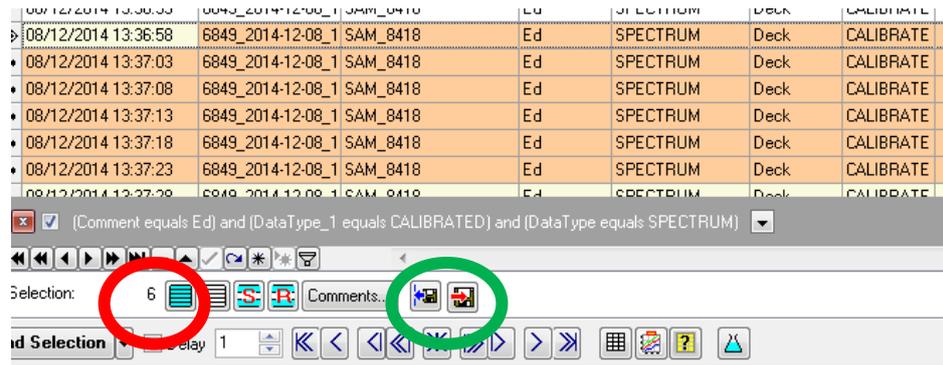


Figura 02: Identificação do número de linhas que estão selecionadas para exportação (em vermelho e botão de exportação (em verde).

Em seguida, uma nova janela irá abrir pedindo as configurações para concluir a exportação do arquivo. Deve-se escolher MatLab Serial Data > Single > diretório para exportação (Figura 03). O conjunto de dados exportado será um arquivo “.mlb” (que o Excel é capaz de ler). Por convenção, o nome deste arquivo será Lu spectrum LO, Ld spectrum LO ou Ed spectrum LO, dependendo do tipo de dados. O ideal é que haja uma pasta para cada ponto de uma campanha para que os arquivos Ed, Ld e Lu estejam no mesmo diretório. A organização dos dados de saída é muito importante para que não haja problemas posteriores.

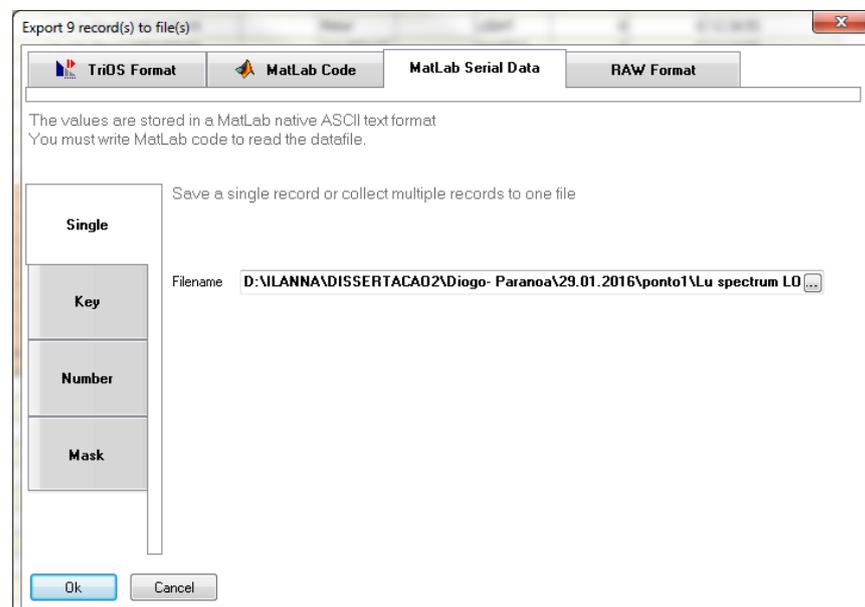


Figura 03: Concluindo a exportação dos dados.

2.3.2 Pré-tratamento no Excel

Em seguida, os dados exportados passam por um pré-tratamento no Excel, onde sofre algumas modificações (Figura 04) para que em seguida o programa R possa fazer a leitura correta dos dados e, então, realizar as interpolações (padronização dos comprimentos de ondas) e cálculos estatísticos.

Depois de abrir um arquivo (Ed spectrum.mlb por exemplo) com o Excel, algumas mudanças têm que ser feitas:

- 1- Abrir o arquivo MLB.txt e tocar “.” por “,” . Em seguida, fecha. (esta etapa pode ser reduzida, caso o padrão do computador se alterado para o Inglês)
- 2- Depois clica com o botão direito sobre este arquivos e pede pra “abrir com” e escolha Excel.
- 3- Não suprimir as linhas 1 a 19, será importante para o resto do protocolo.
- 4- Coma primeira coluna selecionada vá à aba “Dados” > “Ferramenta de dados” > escolha “texto para colunas” e converta o conjunto de dados (1). Escolha: Delimitado (2), Espaço (3) e Finalize (4).
- 5- Depois, selecione toda a tabela e troque “%” por nada. E “=-NAN” por “NaN”
- 6- Completar alguma célula vazia com “NaN”. Geralmente na primeira linha das duas últimas colunas, abaixo de "Comentário" e "IDData".
- 7- Salvar> outros formatos> Texto (MS DOS) que será chamado de " Ed espectro LO fixe.txt", por exemplo.

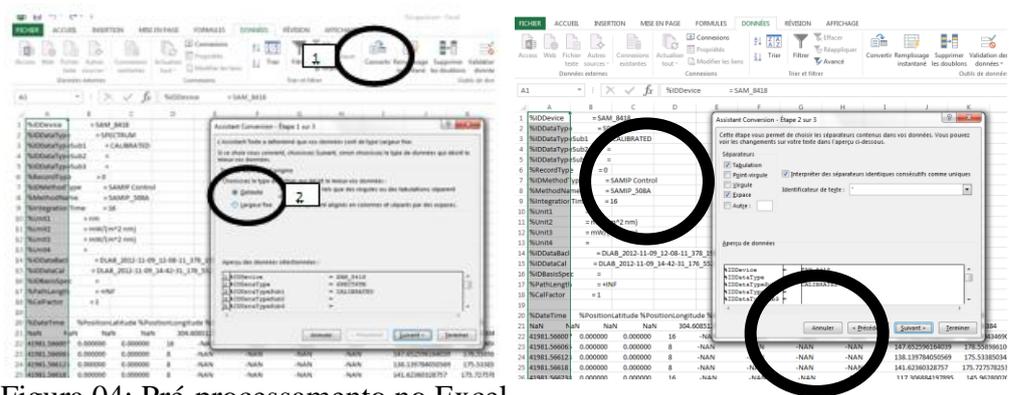


Figura 04: Pré-processamento no Excel.

Após esta etapa, os dados salvos já podem em .txt (MS DOS) já podem ser importados pelo programa , onde



serão realizadas as etapas finais.

2.3.3 Interpolações e Cálculos Estatístico

Na etapa final, os dados são processados no programa,  um software livre (<http://www.r-project.org/>) que disponibiliza uma ampla variedade de técnicas estatísticas e gráficas, testes estatísticos clássicos, análise de séries temporais e outras. Para este trabalho foi utilizada a versão R Studio e as rotinas aplicadas encontram-se no Anexo I. Assim, foram desenvolvidas duas rotinas de processamento dos dados:

- A primeira rotina converte os dados para obter um valor radiométrico para um comprimento de onda específico. Ela produz um novo arquivo ".txt", que será chamado de "espectro Ed LO fixe", por exemplo (e assim por diante com Lu e Ld). Os dados de saída desta etapa serão os dados de input para o segundo script.
- A segunda vai fazer o cálculo adequado de Rrs com os três arquivos produzidos pelo primeiro script (Ed spectrum LO fixe, Ld spectrum LO fixe e Lu spectrum LO fixe) e outros arquivos ".txt" que são :Rrs bruta; Rrs corrigida; Média e desvio padrão para Rrs bruta e Média e desvio padrão para Rrs corrigida. Também são gerados gráficos de distribuição para melhor visualização dos dados na própria interface do R..

APÊNDICE B

SCRIPTS DE INTERPOLAÇÃO DOS COMPRIMENTOS DE ONDA - R)

1) PRIMEIRO SCRIPT: INTERPOLAÇÃO DAS QUANTIDADES RADIOMÉTRICA PARA CADA COMPRIMENTO DE ONDA.

```
#####
##### #
# #   interpolação das quantidades radiométrica para cada comprimento de
onda. # #
#
#####
####
```

#Este Roteiro tem por objetivo padronizar os dados radiométricos que usamos para medir a irradiância reflectância (RRS).

#esta padronização envolve uma interpolação para cada comprimento de onda das medições brutas feitos no campo.

#O Objeto final é um novo conjunto de dados que contém tantas linhas como o número de comprimento de onda e as colunas do número de medições mais um.

#A Primeira coluna contém apenas o comprimento de onda. Os nomes das outras colunas são a data e hora das medições escritas como números.atenção

#Preste atenção para o primeiro e os últimos passos deste script quando você chamar e salvar os resultados em seu computador!

O arquivo de entrada será o Ed spectrum LO.txt (o qruivo que foi exportado do MSDA e editado no EXCEL), antes de colocar este arquivo no R deve muda de “,” para “.” e o de saída deve ser Ed spectrum LO fixe.txt.

```
#      1 - Chame o conjunto de dados
#####
donnies=read.table("Z:/Donnies/Radiomitrie/2011-2015 - Campagnes Purus
Andre/Donnies retraities Sylvain/Campagne 2012/1_Ber_09_05/Rrs/Ed spectrum LO
d'origine.txt",h=T,skip=19)
dim(donnies)
head(donnies)

#      2 - suprimir os valores em falta do conjunto de dados
#####
supprCol=which(donnies[3,]=="NaN")
data=t(donnies[,-c(1:4,supprCol,(max(supprCol)+1):ncol(donnies))])

#      3 - interpolar os valores para cada comprimento de onda
#####

#      3a - Cálculo da inclinação entre cada ponto
#####
pente=matrix(0,nrow(data)-1,ncol(data)-1)
for(i in 1:nrow(data)-1)
{
  for(j in 2:ncol(data))
  {
    pente[i,j-1]=(data[i+1,j]-data[i,j])/(data[i+1,1]-data[i,1])
  }
}
dim(pente)
head(pente)

#      3b - Criar um vector e uma matriz que contém os resultados da
interpolação
```

```

#####
#####
vec=seq(ceiling(min(data[,1])),floor(max(data[,1])),1)
vec

data.2=matrix(0,length(vec),ncol(data))
data.2[,1]=vec

#      3c - Cálculo dos novos dados
#####
LO=data[,1]
for(i in 1:length(vec))
{
  LOsup=LO-vec[i]
  LOsup.2=which(LOsup>0)
  LOsup.3=min(LOsup.2)

  for(j in 2:ncol(data))
  {
    data.2[i,j]=data[LOsup.3,j]-(data[LOsup.3,1]-vec[i])*pente[LOsup.3-
1,j-1]
  }
}

#      3d - Criar uma janela gráfica para verificar se a interpolação está
correta
#####
#####
par(mfrow=c(1,2))
plot(data.2[,1],data.2[,2],type='l',main='Raw
measurements',xlab='Wavelength',ylab='Radiometric quantity')
plot(data[,1],data[,2],type='l',col='blue',main='Retreated
measurements',xlab='Wavelength',ylab='Radiometric quantity')

#      3e - Dê nomes às colunas do novo conjunto de dados
#####
colnames(data.2)=paste("H_",donnies[,1],sep="")
colnames(data.2)[1]="LO"

#      4 - Salve os resultados #####
write.table(data.2,"Z:/Donnies/Radiomitrie/Donnies Purus Andre/Donnies retraits
Sylvain/Campagne 2012/2012-05-11/Rrs/Ed spectrum LO fixe.txt",
col.names=T,row.names=F, sep="\t")

```

OBSERVAÇÃO ENTRE ETAPAS:

- O resultado será salvo em .txt
 - Haverá um arquivo texto para cada variável, que serão inseridos na próxima rotina.
 - Estes arquivos devem ser editados de forma que substitua “vírgula” por “ponto”
 - Em seguida, copie o “caminho de cada um dos arquivos e cole no local correspondente (logo no início da rotina) e no fim da rotina altere o caminho da pasta onde o arquivo de saída deverá ser salvo.
 - Salve o arquivo em .txt e altere novamente de “ponto” para “vírgula”
-

2) SEGUNDO SCRIPT: CALCULANDO A REFLECTÂNCIA DO SR (Rrs)

```
#####
##
#
#
#           CÁLCULO DA REFLECTÂNCIA DE SR (Rrs)
#
#
#
#####
#####
```

#EstE Roteiro tem por objetivo calcular diretamente a reflectância Rrs de -sensoriamento remoto para todos os comprimentos de onda disponíveis.

Trabalha com radiância e irradiância conjuntos de dados que foram normalizados em primeiro lugar.

#O Objeto final é um novo conjunto de dados que contém tantas linhas como o número de comprimento de onda e as colunas do número de medições mais um.

#A Primeira coluna contém apenas o comprimento de onda. Os nomes das outras colunas são a data e hora das medições escritas como números.

Preste atenção para o primeiro e os últimos passos deste script quando você chamar e salvar os resultados em seu computador!

OS ARQUIVOS DE ENTRADA SERÃO OS LO fixe.txt. RESULTANDES DO PRIMEIRO SCRIPT.

```
#      1 - Chame o conjunto de dados
#####
```

```
Lu=read.table("Z:/Donnies/Radiometrie/2011-2015 - Campagnes Purus
Andre/Donnies retraities Sylvain/Campagne 2012/1_Ber_09_05/Rrs/Lu spectrum LO
fixe.txt",h=T)
```

```
Ld=read.table("Z:/Donnies/Radiometrie/2011-2015 - Campagnes Purus
Andre/Donnies retraities Sylvain/Campagne 2012/1_Ber_09_05/Rrs/Ld spectrum LO
fixe.txt",h=T)
```

```
Ed=read.table("Z:/Donnies/Radiometrie/2011-2015 - Campagnes Purus
Andre/Donnies retraities Sylvain/Campagne 2012/1_Ber_09_05/Rrs/Ed spectrum LO
fixe.txt",h=T)
```

```
#      2 - Cálculo dos verdadeiros valores da Lu (Lu-0.028Ld)
```

```
#####
```

```
##
```

```
#      2a - Criar um vector e uma matriz que contém os
resultados da interpolação
```

```
#####
```

```
#####
```

```
vec=seq(max(min(Lu[,1]),min(Ld[,1])),min(max(Lu[,1]),max(Ld[,1])),1)
```

```
ligneLu1=which(Lu[,1]==min(vec))
```

```
ligneLu2=which(Lu[,1]==max(vec))
```

```
Lu.2=Lu[ligneLu1:ligneLu2,]
```

```
ligneLd1=which(Ld[,1]==min(vec))
```

```
ligneLd2=which(Ld[,1]==max(vec))
```

```
Ld.2=Ld[ligneLd1:ligneLd2,]
```

```
ifelse((ncol(Lu.2)<=ncol(Ld.2)),(LuVrai=matrix(0,length(vec),ncol(Lu.2))),(L
uVrai=matrix(0,length(vec),ncol(Ld.2))))
```

```
LuVrai[,1]=vec
```

```
#      2b - Calcular o verdadeiro Lu, associando as medições
fazer à mesma hora exata
```

```
#####
```

```
#####
```

```
for(i in 2:ncol(Lu.2))
```

```
{
```

```
  for(j in 2:ncol(Ld.2))
```

```
  {
```

```
    if(colnames(Lu.2)[i]==colnames(Ld.2)[j])
```

```
    {
```

```
      LuVrai[,i]=Lu.2[,i]-0.028*Ld.2[,j]
```

```
    }
```

```
  }
```

```
}
```

```
ifelse((ncol(Lu.2)<=ncol(Ld.2)),(colnames(LuVrai)=colnames(Lu.2)),(colnam
es(LuVrai)=colnames(Ld.2)))
```

```

head(LuVrai)
matplot(LuVrai[,1],LuVrai[,-1],type='l')

#      2c - Suprimir os resultados negativos
#####
vec=which(LuVrai[300,1:ncol(LuVrai)]<=0)
ifelse(length(vec)==0,(LuVrai.2=LuVrai),(LuVrai.2=LuVrai[,-vec]))
matplot(LuVrai.2[,1],LuVrai.2[,-1],type='l')

#      3 - Faça o cálculo adequado de Rrs (Lu / Ed)
#####

#      3a - Criar um vector e uma matriz que contém os
resultados da interpolação
#####
#####
vec=seq(max(min(LuVrai.2[,1]),min(Ed[,1])),min(max(LuVrai.2[,1]),max(Ed[
,1])),1)
ligneLuVrai1=which(LuVrai.2[,1]==min(vec))
ligneLuVrai2=which(LuVrai.2[,1]==max(vec))
LuVrai.3=LuVrai.2[ligneLuVrai1:ligneLuVrai2,]
ligneEd1=which(Ed[,1]==min(vec))
ligneEd2=which(Ed[,1]==max(vec))
Ed.2=Ed[ligneEd1:ligneEd2,]
ifelse((ncol(LuVrai.3)<=ncol(Ed.2)),(Rrs=matrix(0,length(vec),ncol(LuVrai.3)
)),(Rrs=matrix(0,length(vec),ncol(Ed.2))))
Rrs[,1]=vec

#      3b - Calcular o verdadeiro Lu, associando as medições
feitas na mesma hora exata
#####
#####
for(i in 2:ncol(LuVrai.3))
{
  for(j in 2:ncol(Ed.2))
  {
    if(colnames(LuVrai.3)[i]==colnames(Ed.2)[j])
    {
      Rrs[,i]=LuVrai.3[,i]/Ed.2[,j]
    }
  }
}
ifelse((ncol(LuVrai.3)<=ncol(Ed.2)),(colnames(Rrs)=colnames(LuVrai.3)),(col
names(Rrs)=colnames(Ed.2)))
head(Rrs)

```

```

matplot(Rrs[,1],Rrs[,-1],type='l')

#      3c - Suprimir os resultados negativos
#####
vec=which(Rrs[300,1:ncol(Rrs)]<=0)
ifelse(length(vec)==0,(Rrs.2=Rrs),(Rrs.2=Rrs[,-vec]))
matplot(Rrs.2[,1],Rrs.2[,-1],type='l')

#      4 - Representação gráfica dos resultados
#####
par(mfrow=c(1,2))
matplot(Rrs.2[,1],Rrs.2[,-1],type='l',xlab="Wavelength (nm)",ylab="Remote-
sensing reflectance",main="Totality of the Rrs measurements")
Moyenne=rep(0,nrow(Rrs.2))
Mediane=rep(0,nrow(Rrs.2))
EcartType=rep(0,nrow(Rrs.2))
for(i in 1:nrow(Rrs.2))
{
  Moyenne[i]=mean(Rrs.2[i,-1])
  Mediane[i]=median(Rrs.2[i,-1])
  EcartType[i]=sd(Rrs.2[i,-1])
}
plot(Rrs.2[,1],Moyenne,type='l',ylim=c(min(Rrs.2[,-1]),max(Rrs.2[,-
1])),xlab="Wavelength (nm)",ylab="Remote-sensing reflectance",main="Mean and
median values of Rrs",col='red',lwd=2)
lines(Rrs.2[,1],Moyenne-EcartType,lty=2,col='darkgrey',lwd=2)
lines(Rrs.2[,1],Moyenne+EcartType,lty=2,col='darkgrey',lwd=2)
lines(Rrs.2[,1],Mediane,type='l',col='blue',lwd=2)
legend(Rrs.2[1,1],(max(Rrs.2[,-1])), "Mean values of Rrs",pch='-
',cex=0.7,pt.cex=2,col='red',bty='n',text.font=4)
legend(Rrs.2[1,1],(max(Rrs.2[,-1])-(max(Rrs.2[,-1])/2)), "Median values of
Rrs",pch='- ',cex=0.7,pt.cex=2,col='blue',bty='n',text.font=4)
legend(Rrs.2[1,1],(max(Rrs.2[,-1])-(max(Rrs.2[,-1])/6)), "Standard deviation of
Rrs",pch='- ',cex=0.7,pt.cex=2,col='darkgrey',bty='n',text.font=4)

#      4 - Salve os resultados
#####
write.table(Rrs.2,"Z:/Donnies/Radiometrie/Donnies Purus Andre/Donnies
retraities Sylvain/Campagne 2012/2012-05-11/Rrs/20120511 PUR Rrs LO
fixe.txt",row.names=F,col.names=T,sep='\t')

# 5 - SALVANDO A MEDIA E O DESVIO PADRÃO
#Moyenne[i]=mean(Rrs.2[i,-1])#media
#EcartType[i]=sd(Rrs.2[i,-1]) #desvio padrao

```

```

MEDIA<- c("Moyenne")
DESVIO_PADRAO<- c("EcartType")
VARIAVEIS_ESTATISTICAS<- data.frame(Moyenne,EcartType)
VARIAVEIS_ESTATISTICAS

write.table(VARIAVEIS_ESTATISTICAS,"D:/ILANNA/DISSERTAÇÃO2/P
H-      3      marias/Resultado_final_R/Rrs      pto      10      teste      LO
fixe.txt",row.names=F,col.names=T,sep='\t')

```

3) ANÁLISE PELO MÉTODO BOOTSTRAP

```

#####
#####
# EXECUTA O BOOTSTRAP EM REGRESSOES LINEARES E POWER-
LAW #
#####
#####
#
#
# Definir o numero de reamostragem usado no procedimento de bootstrap
Bootstrap_Iteration= 1000

# Exemplo de conjunto de dados com 6 colunas contendo concentraoes de
Ozonio nas informoes de ar e clima
setwd("D:/ILANNA/MEU BANCO/BOOTSTRAP/JM/")
data=read.table("bootstrap.csv",dec=".",sep="," ,head=T)
data
attach(data)

Var1=data$XCOMPRIMENTO DE ONDA
Var2=data$MPS

#####
#####
# O pacote 'simpleboot' tem de ser descarregado primeiro

library(simpleboot)

# Construir uma regresso linear na relao entre 'mps' e 'Rsr'
(concentrao = a * refletancia + b)

```

```

lmodel_linear <- lm(Var2 ~ Var1)

# Mostrar os dados (em preto) e a regress??o (em azul) num gr??fico
x11()
plot(Var1,Var2,pch=16,main='Linear regression')
abline(lmodel_linear$coefficients[1],lmodel_linear$coefficients[2],
col='blue',lwd=2)

# Fa??a um bootstrap no conjunto de dados e execute s??ries de regress??o
lboot_linear <- lm.boot(lmodel_linear, R = Bootstrap_Iteration)
summary(lboot_linear)

st1Linear=lmodel_linear$coefficients[1]+summary(lboot_linear)$stdev.params
[1]
st2Linear=lmodel_linear$coefficients[1]-
summary(lboot_linear)$stdev.params[1]
st3Linear=lmodel_linear$coefficients[2]+summary(lboot_linear)$stdev.params
[2]
st4Linear=lmodel_linear$coefficients[2]-
summary(lboot_linear)$stdev.params[2]

abline(st1Linear,st3Linear, col='gray',lwd=2,lty='dashed')
abline(st2Linear,st4Linear, col='gray',lwd=2,lty='dashed')

reglin=matrix(0,4,2)
reglin[,1]=c("Original intercept :", "Original slope :", "Standard Deviation of
Intercept :", "Standard Deviation of Slope :")
reglin[,2]=c(lmodel_linear$coefficients[1],lmodel_linear$coefficients[2],summ
ary(lboot_linear)$stdev.params[1],summary(lboot_linear)$stdev.params[2])

#CALCULO DE RMSE PARA O MODELO LINEAR

L=lmodel_linear$coefficients[2]*Var1+lmodel_linear$coefficients[1]

nlin=length(Var1)

Dif_conc_L= matrix(0,nlin)

for (i in 1:nlin)
{
Dif_conc_L[i]= (Var2[i]-L[i])^2 }

write.table(Dif_conc_L,"D:/LANNA/MEU
BANCO/BOOTSTRAP/JM/Dif_conc_L_L8_IR.txt",row.names=F,col.names=T,sep='
\t')

Bias_L=0

```

```

for (i in 1:nlin)
  {Bias_L= Bias_L+Dif_conc_L[i]}

MSE_L= (Bias_L)/nlin

RMSE_L= sqrt(MSE_L)

RMSE_L_porcent= RMSE_L/(mean(Var2))

# Construa uma regressão da lei de potência (power-law) na relação entre
'mps' e 'Rsr' potencia (concentração = a * reflectancia ^ (b) )
newVar1=log(Var1)
newVar2=log(Var2)
lmodel_power <-lm(newVar2 ~ newVar1)

# Mostre os dados (em preto) ea regressão (em azul) num gráfico
x11()
plot(newVar1, newVar2 ,pch=16,main="Power-law regression")
abline(lmodel_power$coefficients[1],lmodel_power$coefficients[2],
col='blue',lwd=2)

# Faça um bootstrap no conjunto de dados e execute séries de regressão
# Mudou os valores originais para logarítmicos > cuidado com o valor de
intercepto

lboot_power <- lm.boot(lmodel_power, R = Bootstrap_Iteration)
summary(lboot_power)[6]

st1Power=lmodel_power$coefficients[1]+summary(lboot_power)$stdev.params[1]
st2Power=lmodel_power$coefficients[1]-
summary(lboot_power)$stdev.params[1]
st3Power=lmodel_power$coefficients[2]+summary(lboot_power)$stdev.params[2]
st4Power=lmodel_power$coefficients[2]-
summary(lboot_power)$stdev.params[2]

abline(st1Power,st3Power, col='gray',lwd=2,lty='dashed')
abline(st2Power,st4Power, col='gray',lwd=2,lty='dashed')

regpow=matrix(0,4,2)
regpow[,1]=c("Original intercept :", "Original slope :", "Standard Deviation of
Intercept :", "Standard Deviation of Slope :")
regpow[,2]=c(lmodel_power$coefficients[1],lmodel_power$coefficients[2],summary(lboot_power)$stdev.params[1],summary(lboot_power)$stdev.params[2])

#CALCULO DE RMSE PARA O MODELO potencia

```

```

#((lmodel_power$coefficients[2]*Var1)+ log(lmodel_power$coefficients[1]))

LP=
(exp(lmodel_power$coefficients[1]))*(Var1^lmodel_power$coefficients[2])

nlin=length(Var1)

Dif_conc_LP= matrix(0,nlin)

write.table(Dif_conc_LP,"D:/ILANNA/MEU
BANCO/BOOTSTRAP/JM/Dif_conc_LP_L8_IR.txt",row.names=F,col.names=T,sep
='\t')

for (i in 1:nlin)
{
  Dif_conc_LP[i]=(Var2[i]-LP[i])^2}

Bias_LP=0

for (i in 1:nlin)
{Bias_LP= Bias_LP+Dif_conc_LP[i]}

MSE_LP= (Bias_LP)/nlin

RMSE_LP= sqrt(MSE_LP)

RMSE_LP_porcent= RMSE_LP/(mean(Var2))

detach(data)

#####
#####

reglin # MATRIZ DE REGRESS??O LINEAR
write.table(reglin,"D:/ILANNA/MEU
BANCO/BOOTSTRAP/JM/a_e_b_L8_IR.txt",row.names=F,col.names=T,sep='\t')
regpow #MATRIZ DE REGRESS??O POWER-LAW
write.table(regpow,"D:/ILANNA/MEU
BANCO/BOOTSTRAP/JM/a_e_b_power-
law_L8_IR.txt",row.names=F,col.names=T,sep='\t')

```
