



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE CIÊNCIAS AGRÁRIAS**  
**DEPARTAMENTO DE ENGENHARIA AGRÍCOLA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA**

**JULYANNE BRAGA CRUZ AMARAL**

**ESTIMATIVA DE PARÂMETROS DE VEGETAÇÃO E DE QUALIDADE DE ÁGUA**  
**USANDO SENSORIAMENTO REMOTO**

**FORTALEZA**  
**2023**

JULYANNE BRAGA CRUZ AMARAL

ESTIMATIVA DE PARÂMETROS DE VEGETAÇÃO E DE QUALIDADE DE ÁGUA  
USANDO SENSORIAMENTO REMOTO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestra em Engenharia Agrícola. Área de concentração: Manejo e Conservação de Bacias Hidrográficas.

Orientador: Prof. Dr. Fernando Bezerra Lopes.

FORTALEZA

2022

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Sistema de Bibliotecas  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

- A514e Amaral, Julyanne Braga Cruz.  
Estimativa de parâmetros de vegetação e qualidade da água usando sensoriamento remoto / Julyanne Braga Cruz Amaral. – 2023.  
104 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Agrícola, Fortaleza, 2023.  
Orientação: Prof. Dr. Fernando Bezerra Lopes.
1. Sensoriamento remoto. 2. Espectrorradiometria. 3. Monitoramento. 4. Vigna unguiculata. I. Título.  
CDD 630
-

JULYANNE BRAGA CRUZ AMARAL

ESTIMATIVA DE PARÂMETROS DE VEGETAÇÃO E DE QUALIDADE DE ÁGUA  
USANDO SENSORIAMENTO REMOTO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Agrícola da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestra em Engenharia Agrícola. Área de concentração: Manejo e Conservação de Bacias Hidrográficas.

Aprovada em: 28/04/2022.

BANCA EXAMINADORA

---

Prof. Dr. Fernando Bezerra Lopes (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Adunias dos Santos Teixeira, Ph.D.  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Cláudio Clemente Farias Barbosa  
Instituto Nacional de Pesquisas Espaciais (INPE)

A Deus.

Aos meus pais, Adrienne e Julio.

## AGRADECIMENTOS

A Deus, pelo dom da vida e por me conceder saúde e sabedoria para seguir sempre em frente.

Aos meus pais, Julio e Adrienne, pelo amor, dedicação, apoio e incentivo constantes. Por terem acreditado, torcido e orado por mim em todas as situações.

A minha irmã, Marianne, por toda amizade e por sempre estar ao meu lado para o que fosse preciso, dividindo momentos de alegria e sendo meu apoio nas dificuldades.

Aos meus avós, Tarcísio, Maria e Rita, por todo cuidado e amor. Ao meu bisavô Raimundo, que estará sempre no meu coração e em minhas lembranças.

Ao meu noivo, André, pela paciência e apoio nos momentos difíceis, por ter sido meu companheiro nessa jornada. Obrigada por todo incentivo e apoio que me dá todos os dias.

Aos grandes amigos de graduação que vou levar para a vida, Caio e Renata, por todos os momentos compartilhados. Obrigada pela motivação e apoio nesse final de ciclo.

Às amigas de infância Amanda, Gabriela e Larysse, que estão sempre presentes, independente da distância.

À Valéria Severo e Nicole Carvalho por toda ajuda, apoio nas coletas e análises laboratoriais e amizade construída.

Aos colegas de trabalho da HL Soluções Ambientais, pelo apoio e incentivo diário e por tornarem esse final de ciclo mais leve.

À Universidade Federal do Ceará, por proporcionar condições necessárias pra minha formação profissional.

Ao Departamento de Engenharia Agrícola por ter sido minha segunda casa durante os anos de mestrado.

Ao Prof. Dr. Fernando Bezerra Lopes, pela orientação e confiança depositada em mim para a realização deste trabalho.

Aos participantes da banca examinadora professor Adunias dos Santos Teixeira e professor Cláudio Clemente Farias Barbosa pelo tempo, pelas valiosas colaborações e sugestões.

A todos do Grupo de pesquisa e extensão Manejo de Água e Solo no Semiárido – MASSA.

## RESUMO

O sensoriamento remoto é uma técnica que permite a obtenção de informações a respeito de diversos alvos sem que haja contato físico. Este artifício é potencialmente utilizado em atividades agrícolas e ambientais, promovendo monitoramento e gestão mais eficiente das atividades. O monitoramento do estado nutricional das plantas é fundamental para a identificação precoce dos nutrientes que podem limitar o crescimento e produção das culturas, assim como realizar o monitoramento dos recursos hídricos é de suma importância para tomadas de decisões e gestão ambiental. Ambos os monitoramentos são comumente realizados através de análises laboratoriais, por meio de procedimentos que levam tempo, custo de manutenção e alta produção de resíduos. Desse modo, o presente trabalho objetivou quantificar, por meio da espectroscopia de reflectância, os teores de nutrientes foliares da cultura do feijão-caupi e das variáveis limnológicas clorofila-a, sólidos suspensos totais e transparência, como alternativa às análises laboratoriais. A cultura do feijão-caupi foi analisada em três estágios fenológicos: V4, R6 e R9. Foram coletadas amostras foliares para realização das leituras radiométricas e quantificações por digestão via úmida nitro-perclórica. A aquisição das amostras de água foi realizada nos reservatórios Caxitoré, General Sampaio e Pereira de Miranda, onde foi feita a coleta em 3, 4 e 5 pontos, respectivamente, em cada reservatório. Em paralelo às coletas de água, foi efetuada a obtenção de dados hiperespectrais por radiometria *in situ*. As análises de tecidos vegetais e amostras de água foram realizadas em laboratório e a aquisição de dados radiométricos foi conduzida utilizando-se o espectrorradiômetro FieldSpec 3 Hi-Res. Foram construídos três modelos para cada variável, a partir de: correlação simples, correlação 2D (razão de bandas) e regressão por Mínimos Quadrados Parciais (PLSR). As variáveis espectrais mais significativas para os modelos de correlação simples e correlação 2D foram selecionadas pelo maior valor de  $r$ , enquanto que para a construção dos modelos PLSR, utilizou-se o método Stepwise. Foram utilizados 70 e 30% dos dados para a construção e validação dos modelos de predição, respectivamente. A fim de validar os resultados, foram aplicadas as métricas estatísticas: coeficientes de determinação, RMSE e RPD. Os modelos preditivos de PLSR apresentaram melhores performances se comparado à correlação simples e 2D, tanto para os nutrientes foliares quanto para as variáveis limnológicas, apresentando  $R^2$  ajustado de 0,97, 0,23, 0,25 e 0,23 e  $RPD = 1,23, 0,25, 6,09$  e  $2,38$  para as predições de P, K, Ca, e Zn, respectivamente e  $R^2$  ajustado de 0,23, 0,25 e 0,23 e  $RPD = 0,25, 6,09$  e  $2,38$  para clorofila-a, SST e transparência, respectivamente. Foi possível observar que os comprimentos

de ondas mais significativos na predição de nutrientes foliares estão na região do visível, enquanto que para as variáveis limnológicas estão regiões de infravermelho próximo (NIR).

**Palavras-chave:** sensoriamento remoto; espectrorradiometria; monitoramento; *Vigna unguiculata*.



## ABSTRACT

Remote sensing is a technique that allows obtaining information about different targets without physical contact. This device is potentially used in agricultural and environmental activities, promoting more efficient monitoring and management of activities. Monitoring the nutritional status of plants is essential for the early identification of nutrients that can limit the growth and production of crops, as well as monitoring water resources is of paramount importance for decision making and environmental management. Both monitoring are commonly performed through laboratory analysis, through procedures that take time, maintenance cost and high waste production. Thus, the present work aimed to quantify, by means of reflectance spectroscopy, the contents of leaf nutrients of the cowpea crop and the limnological variables chlorophyll-a, total suspended solids and transparency, as an alternative to laboratory analyses. The cowpea crop was analyzed in three phenological stages: V4, R6 and R9. Leaf samples were collected for radiometric readings and quantification by wet nitro-perchloric digestion. The acquisition of water samples was carried out in the Caxitoré, General Sampaio and Pereira de Miranda reservoirs, where the collection was carried out at 3, 4 and 5 points, respectively, in parallel with the water collection, hyperspectral data were obtained by in situ radiometry. The analyzes of plant tissues and water samples were performed in the laboratory and the acquisition of radiometric data was carried out using the FieldSpec 3 Hi-Res spectroradiometer. Three models were built for each variable, based on: simple correlation, 2D correlation (band ratio) and Partial Least Squares Regression (PLSR). The most significant spectral variables for the simple correlation and 2D correlation models were selected by the highest value of  $r$ , while for the construction of the PLSR models, the Stepwise method was used. 70 and 30% of the data were used for the construction and validation of the prediction models, respectively. In order to validate the results, statistical metrics were applied: determination coefficients, RMSE and RPD. The PLSR predictive models presented better performances when compared to the simple and 2D correlation, both for leaf nutrients and for limnological variables, presenting adjusted  $R^2$  of 0.97, 0.23, 0.25 and 0.23 and  $RPD = 1.23, 0.25, 6.09$  and  $2.38$  for the predictions of P, K, Ca, and Zn, respectively and adjusted  $R^2$  of 0.23, 0.25 and 0.23 and  $RPD = 0.25, 6.09$  and  $2.38$  for chlorophyll-a, SST and transparency, respectively. It was possible to observe that the most significant wavelengths in the prediction of leaf nutrients are in the visible region, while for the limnological variables they are in the near infrared (NIR) regions.

**Keywords:** remote sensing; spectroradiometrics; monitoring; *Vigna unguiculata*.

## LISTA DE FIGURAS

Figura 1 – Elementos fundamentais do Sensoriamento Remoto.....	21
Figura 2 – Espectro eletromagnético.....	22
Figura 3 – Comportamento espectral dos diferentes alvos.....	23
Figura 4 – Fator de reflectância da vegetação verde e sadia.....	24
Figura 5 – Curvas de reflectância da água nos estados líquido, gasoso (nuvem) e sólido (neve).....	26
Figura 6 – Diferentes formas de interação da radiação com os corpos hídricos.....	27
Figura 7 – Comportamento espectral das Clorofilas a, b e c.....	28
Figura 8 – Comportamento espectral da água para diferentes concentrações de sedimentos em suspensão.....	29
Figura 9 – Reflectância espectral da água clara contendo diferentes composições de sólidos suspensos: (a) solo argiloso; (b) solo siltoso.....	30
Figura 10 – Reflectância espectral da água contendo diferentes concentrações de Matéria Orgânica Dissolvida.....	31
Figura 11 – Localização do experimento.....	38
Figura 12 – Geometria de aquisição dos dados radiométricos.....	41
Figura 13 – Teores dos nutrientes: fósforo (a), potássio (b), cálcio (c) e zinco (d) nas folhas do <i>Vigna Unguiculata</i> (L.) Walp. Letras distintas sugerem diferença estatística pelo teste de Tukey, a 5% de probabilidade.....	45
Figura 14 – Espectros médios de reflectância e os respectivos desvios padrões de cada estágio fenológico (A) V4 (B) R6 (C) R9.....	48
Figura 15 – Correlograma entre a reflectância e os teores de P, K, Ca e Zn nas folhas do <i>Vigna Unguiculata</i> (L.) Walp.....	49
Figura 16 – Correlograma 2D entre a reflectância espectral e os teores foliares de fósforo (A), de potássio (B), de cálcio (C) e de zinco (D).....	52

Figura 17 – Relações entre os teores medidos e estimados de P (a), K (b) e Ca (c) usando o modelo de banda única.....	55
Figura 18 – Relações entre os teores medidos e estimados de P (a), K (b), Ca (c) e Zn (d) usando o modelo de razão de bandas.....	57
Figura 19 – Relação entre os teores medidos e estimados de cálcio (a) e zinco (b) na fase fenológica V4.....	58
Figura 20 – Relação entre os teores medidos e estimados de zinco na fase fenológica R6.	58
Figura 21 – Relação entre os teores medidos e estimados de K (a) e Ca (b) na fase fenológica R9.....	59
Figura 22 – Relações entre os teores medidos e estimados de P (a), K (b), Ca (c) e Zn (d) utilizando dados das três fases fenológicas (V4, R6 e R9).....	60
Figura 23 – Localização da área de estudo.....	67
Figura 24 – Municípios da bacia do Curu e seus afluentes.....	68
Figura 25 – Pluviometria da Bacia do Curu entre os anos de 2014 e 2019.....	69
Figura 26 – Geologia da Bacia do Curu.....	70
Figura 27 – Declividade da bacia do Curu.....	71
Figura 28 – Classes de solos da bacia do Curu.....	72
Figura 29 – Uso e Ocupação do solo da bacia do Curu.....	73
Figura 30 – Localização dos pontos de coleta.....	74
Figura 31 – Coleta de amostras de água em garrafas plásticas.....	75
Figura 32 – Calibração com placa spectralon.....	77
Figura 33 – Coleta de dados radiométricos.....	77
Figura 34 – Resposta espectral média dos reservatórios amostrados.....	81
Figura 35 – Correlogramas entre o fator de reflectância e variáveis medidas: (A) clorofila-a em $\mu\text{g L}^{-1}$ , (B) SST em $\text{mg L}^{-1}$ , (C) transparência em m.....	83
Figura 36 – Correlograma 2D entre o fator de reflectância e variáveis medidas: (A) clorofila-a em $\mu\text{g L}^{-1}$ , (B) SST em $\text{mg L}^{-1}$ , (C) transparência em m.....	85

Figura 37 – Relações entre os valores medidos e estimados de SST (A) e Transparência (B) usando o modelo de correlação simples.....	87
Figura 38 – Relações entre os valores medidos e estimados de Clorofila-a, (A), SST (B) e Transparência (C) usando o modelo de correlação 2D.....	88
Figura 39 – Relações entre os valores medidos e estimados de clorofila-a (A), SST (B), Transparência (C) usando o modelo PLSR.....	89

## LISTA DE TABELAS

Tabela 1 – Análise físico-química de solo da área experimental.....	39
Tabela 2 – Fenologia do <i>Vigna unguiculata</i> (L.) Walp.....	40
Tabela 3 – Análise de variância – ANOVA.....	44
Tabela 4 – Modelos para estimativas dos teores de nutriente na folha utilizando uma única banda espectral.....	50
Tabela 5 – Modelos para estimativas dos teores de nutrientes nas folhas utilizando razão de bandas espectrais.....	52
Tabela 6 – Bandas espectrais selecionadas para a calibração dos modelos por PLSR....	53
Tabela 7 – Equações utilizadas na calibração dos modelos por PLSR.....	53
Tabela 8 – Municípios parcialmente drenados pela baía do Curu.....	68
Tabela 9 – Caracterização dos reservatórios.....	74
Tabela 10 – Atributos analisados, metodologias e referências.....	76
Tabela 11 – Estatística descritiva para as variáveis analisadas no reservatório Caxitoré.....	79
Tabela 12 – Estatística descritiva para as variáveis analisadas no reservatório General Sampaio.....	79
Tabela 13 – Estatística descritiva para as variáveis analisadas no reservatório Pereira de Miranda.....	80
Tabela 14 – Modelos para estimativas dos teores de nutriente na folha utilizando uma única banda espectral.....	84
Tabela 15 – Modelos para estimativas dos teores de nutrientes nas folhas utilizando razão de bandas espectrais.....	85
Tabela 16 – Bandas espectrais selecionadas para a calibração dos modelos por PLSR....	86
Tabela 17 – Equações utilizadas na calibração dos modelos por PLSR.....	86

## LISTA DE ABREVIATURAS E SIGLAS

ANOVA	Análise de Variância
BHC	Bacia Hidrográfica do Curu
CDOM	Matéria Orgânica Colorida Dissolvida
Cl <sub>a</sub>	Clorofila-a
COAs	Constituintes Opticamente Ativos
MOD	Material Orgânico Dissolvido
NIR	Região do Infravermelho Próximo
PCA	Análise de Componentes Principais
PLSR	Regressão de Mínimos Quadrados Parciais
R6	Fase Reprodutiva 6
R9	Fase Reprodutiva 9
REM	Radiação Eletromagnética
SIS	Sólidos Inorgânicos em Suspensão
SR	Sensoriamento Remoto
SSF	Sólidos em Suspensão Fixos
SST	Sólidos em Suspensão Totais
SSV	Sólidos em Suspensão Voláteis
SWIR	Região do Infravermelho Médio
V4	Fase Vegetativa 4
VIS	Região do Visível

## LISTA DE SÍMBOLOS

$R^2$	Coeficiente de determinação
$R^2$ ajust	Coeficiente de determinação ajustado
$r$	Coeficiente de correlação de Pearson
$\rho$	Fator de reflectância
$FRB\lambda$	Fator de reflectância bidirecional

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO GERAL.....</b>	<b>19</b>
<b>1.1</b>	<b>Hipótese.....</b>	<b>20</b>
<b>1.2</b>	<b>Objetivo.....</b>	<b>20</b>
<b>2</b>	<b>REVISÃO DE LITERATURA.....</b>	<b>21</b>
<b>2.1</b>	<b>Sensoriamento Remoto.....</b>	<b>21</b>
<i>2.1.1</i>	<i>Comportamento espectral de alvos.....</i>	<i>22</i>
<i>2.1.2</i>	<i>Comportamento espectral da vegetação.....</i>	<i>23</i>
<i>2.1.3</i>	<i>Estimativa de nutriente foliares por Sensoriamento Remoto.....</i>	<i>25</i>
<i>2.1.4</i>	<i>Comportamento espectral da água.....</i>	<i>25</i>
<i>2.1.5</i>	<i>Propriedades dos componentes opticamente ativos na água.....</i>	<i>27</i>
<i>2.1.5.1</i>	<i>Clorofila-a.....</i>	<i>27</i>
<i>2.1.5.2</i>	<i>Sólidos inorgânicos em suspensão.....</i>	<i>29</i>
<i>2.1.5.3</i>	<i>Material orgânico dissolvido.....</i>	<i>30</i>
<b>2.2</b>	<b>Modelos de Estimativa da Concentração de Clorofila-a.....</b>	<b>31</b>
<i>2.2.1</i>	<i>Regressão por Mínimos Quadrados Parciais (Partial Least Square Regression – PLSR).....</i>	<i>32</i>
<b>3</b>	<b>OBTENÇÃO DAS CONCENTRAÇÕES NUTRICIONAIS FOLIARES DA CULTURA DO FEIJÃO-CAUPI POR MEIO DA ESPECTROSCOPIA DE REFLECTÂNCIA.....</b>	<b>34</b>
<b>3.1</b>	<b>Introdução.....</b>	<b>35</b>
<b>3.2</b>	<b>Objetivos.....</b>	<b>37</b>
<b>3.3</b>	<b>Metodologia.....</b>	<b>37</b>
<i>3.3.1</i>	<i>Caracterização da área de estudo.....</i>	<i>37</i>
<i>3.3.2</i>	<i>Aquisição de amostras foliares.....</i>	<i>39</i>
<i>3.3.3</i>	<i>Aquisição de dados hiperespectrais.....</i>	<i>40</i>
<i>3.3.4</i>	<i>Calibração dos modelos de estimativa dos teores nutricionais foliares.....</i>	<i>41</i>
<i>3.3.4.1</i>	<i>Correlação simples.....</i>	<i>41</i>
<i>3.3.4.2</i>	<i>Razão de bandas.....</i>	<i>42</i>
<i>3.3.4.3</i>	<i>Regressão por Mínimos Quadrados Parciais (Partial Least Square Regression – PLSR) .....</i>	<i>42</i>
<i>3.3.5</i>	<i>Validação dos modelos de estimativa de teores nutricionais foliares.....</i>	<i>43</i>



<b>3.4</b>	<b>Resultados e Discussão.....</b>	<b>43</b>
<b>3.4.1</b>	<b><i>Teor dos nutrientes foliares.....</i></b>	<b>43</b>
<b>3.4.2</b>	<b><i>Análise dos dados hiperespectrais.....</i></b>	<b>45</b>
<b>3.4.3</b>	<b><i>Estimativa de teores nutricionais foliares.....</i></b>	<b>49</b>
<b>3.4.3.1</b>	<b><i>Correlação simples.....</i></b>	<b>49</b>
<b>3.4.3.2</b>	<b><i>Correlação 2D.....</i></b>	<b>50</b>
<b>3.4.3.3</b>	<b><i>Regressão por Mínimos Quadrados Parciais (Partial Least Square Regression – PLSR).....</i></b>	<b>52</b>
<b>3.4.3.3.1</b>	<b><i>Validação dos modelos.....</i></b>	<b>55</b>
<b>3.5</b>	<b>Conclusão.....</b>	<b>62</b>
<b>4</b>	<b>USO DE SENSORIAMENTO REMOTO PARA ESTIMAR AS CONCENTRAÇÕES DE CLOROFILA-A, SÓLIDOS SUSPENSOS TOTAIS E TRANSPARÊNCIA EM RESERVATÓRIOS DO SEMIÁRIDO NORDESTINO BRASILEIRO.....</b>	<b>63</b>
<b>4.1</b>	<b>Introdução.....</b>	<b>65</b>
<b>4.2</b>	<b>Hipótese.....</b>	<b>65</b>
<b>4.3</b>	<b>Objetivos.....</b>	<b>66</b>
<b>4.4</b>	<b>Metodologia.....</b>	<b>66</b>
<b>4.4.1</b>	<b><i>Caracterização da área de estudo.....</i></b>	<b>66</b>
<b>4.4.1.1</b>	<b><i>Caracterização hidroclimatológica.....</i></b>	<b>69</b>
<b>4.4.1.1.1</b>	<b><i>Clima.....</i></b>	<b>69</b>
<b>4.4.1.1.2</b>	<b><i>Precipitação.....</i></b>	<b>69</b>
<b>4.4.1.2</b>	<b><i>Caracterização fisiográfica.....</i></b>	<b>70</b>
<b>4.4.1.1.1</b>	<b><i>Geologia.....</i></b>	<b>70</b>
<b>4.4.1.1.2</b>	<b><i>Relevo.....</i></b>	<b>70</b>
<b>4.4.1.1.3</b>	<b><i>Pedologia.....</i></b>	<b>72</b>
<b>4.4.1.1.4</b>	<b><i>Uso e ocupação do solo.....</i></b>	<b>73</b>
<b>4.4.2</b>	<b><i>Localização dos pontos de coleta.....</i></b>	<b>74</b>
<b>4.4.3</b>	<b><i>Aquisição de dados limnológicos.....</i></b>	<b>75</b>
<b>4.4.4</b>	<b><i>Aquisição e tratamento de dados radiométricos.....</i></b>	<b>76</b>
<b>4.4.5</b>	<b><i>Calibração dos modelos de estimativa de dados limnológicos.....</i></b>	<b>78</b>
<b>4.5</b>	<b>Resultados e Discussão.....</b>	<b>79</b>
<b>4.5.1</b>	<b><i>Estatística descritiva.....</i></b>	<b>79</b>

4.5.2	<i>Análise dos dados hiperespectrais.....</i>	<b>80</b>
4.5.3	<i>Correlação simples entre a reflectância e as variáveis limnológicas.....</i>	<b>82</b>
4.5.3.1	<i>Calibração dos modelos de correlação simples.....</i>	<b>84</b>
4.5.4	<i>Correlação 2D entre a reflectância e as variáveis limnológicas.....</i>	<b>84</b>
4.5.4.1	<i>Calibração dos modelos de correlação 2D.....</i>	<b>85</b>
4.5.5	<i>Regressão por Mínimos Quadrados Parciais (Partial Least Square Regression – PLSR).....</i>	<b>86</b>
4.5.5.1	<i>Calibração dos modelos de PLSR.....</i>	<b>86</b>
4.5.6	<i>Validação dos modelos.....</i>	<b>87</b>
4.6	<b>Conclusão.....</b>	<b>91</b>
5	<b>CONSIDERAÇÕES FINAIS.....</b>	<b>92</b>
	<b>REFERÊNCIAS .....</b>	<b>93</b>

## 1 INTRODUÇÃO GERAL

O Sensoriamento Remoto (SR) consiste em uma técnica de obtenção de dados da superfície terrestre sem que haja contato direto com o alvo de interesse. A partir da aplicação do SR é possível estimar características de diversos materiais a partir da sua interação com a radiação eletromagnética (REM), em que a REM interage com o objeto e a informação é captada pelo sensor. Os sensores podem estar localizados a bordo de aeronaves, espaçonaves ou outras plataformas e podem ser ativos ou passivos, ou seja, operam com a sua própria fonte de luz ou dependem da energia refletida, respectivamente.

A crescente utilização do SR possibilita um desenvolvimento mais eficiente, promovendo a redução de impactos ambientais negativos, uma vez que reduz as análises laboratoriais geradoras de resíduo para o meio ambiente. Além disso, o SR pode ser utilizado como ferramenta de gestão, por permitir um monitoramento espaço-temporal de diversos objetos, como plantações e recursos hídricos.

A partir de técnicas de espectrorradiometria de reflectância é possível obter conhecimento sobre o comportamento espectral dos alvos, permitindo a identificação das características do objeto de interesse. A folha é o principal órgão da planta utilizado para o estudo do comportamento espectral da vegetação, devido à sua suscetibilidade à REM. A radiação solar, ao incidir sobre a folha, interage com as estruturas foliares, água e pigmentos e reflete para o sensor informações como o estado de saúde e reprodutivo das plantas. As regiões do espectro que possuem maior destaque no comportamento espectral da vegetação são o visível (VIS) e o infravermelho próximo (NIR), pois as alterações na reflectância são maiores nessas regiões.

O SR atua como um recurso de monitoramento hídrico de Clorofila-a (Cla), Matéria Orgânica Colorida Dissolvida (CDOM), Sólidos Suspensos Totais (SST), temperatura de superfície da água, dentre outras variáveis. O monitoramento dos recursos hídricos é uma ferramenta de fundamental importância para a sua gestão, pois permite a avaliação da qualidade da água de modo a acompanhar suas alterações no tempo e no espaço em resposta às intervenções antrópicas no ambiente.

Aliados à espectroscopia de reflectância, técnicas matemáticas são utilizadas para construção de modelos capazes de estimar teores dos nutrientes foliares da vegetação, bem como dos constituintes da água. Modelos como Correlação Simples, Razão de Bandas e Regressão dos Mínimos Quadrados Parciais permitem uma quantificação rápida e não destrutiva da variável de interesse a ser analisada.

## **1.1 Hipótese**

A utilização de ferramentas de sensoriamento remoto a nível de campo, aliadas a técnicas matemáticas permite o monitoramento e estimativa das concentrações nutricionais foliares do feijão-caupi, bem como dos parâmetros de qualidade da água em reservatórios artificiais do semiárido.

## **1.2 Objetivo**

Aplicar métodos de regressão e técnicas de sensoriamento remoto para quantificar os teores de P, K, Ca e Zn nas folhas de *Vigna Unguiculata* (L.) Walp e estimar as concentrações de clorofila-a, sólidos suspensos totais e transparência a partir de dados de sensoriamento remoto.


## 2 REVISÃO DE LITERATURA

### 2.1 Sensoriamento Remoto

Sensoriamento remoto consiste na utilização de sensores, que podem estar em diferentes níveis de aquisição de dados, como a bordo de aeronaves, espaçonaves ou outras plataformas, visando obter informações sobre determinados objetos, processos ou fenômenos da superfície sem que haja contato físico com eles, a partir das interações entre REM e o alvo estudado (NOVO, 2010).

A Figura 1 exemplifica os quatro elementos fundamentais para a utilização de técnicas de SR. A REM é a fonte de energia necessária para iluminar o alvo, a não ser que ele seja capaz de emitir energia própria e é o elemento de ligação entre todos os outros: sensor, fonte e alvo; e o sensor é o equipamento que coleta e registra a resposta da interação da REM com o alvo, objeto de estudo (LOPES, 2013).

Figura 1 - Elementos fundamentais do Sensoriamento Remoto




Fonte: Novo e Ponzoni (2001).

Segundo Novo e Ponzoni (2001), a REM propaga-se no vácuo à velocidade da luz e sua interação com o meio físico pode ser explicada através de dois modelos: o modelo corpuscular (quântico) e o ondulatório.

No modelo quântico, a REM resulta de pequenos pulsos de energia, enquanto que no modelo ondulatório, a REM é propagada na forma de ondas que oscilam entre os campos elétrico e magnético. O conjunto de comprimentos de onda os quais a REM é composta, é conhecido como Espectro eletromagnético e é dividido em regiões espectrais, conforme exibe a Figura 2.

Segundo Barbosa (2019), para fins de estudo do sensoriamento remoto da água, trabalha-se com REM na região do visível (400 – 700 nm) e infravermelho próximo (até ~900 nm).



Fonte: INPE (2021).


Utiliza-se o sensoriamento remoto mundialmente para fins diversos, como inventários, mapeamentos e monitoramento de recursos naturais. Diversas pesquisas têm demonstrado que essa tecnologia garante resultados positivos em estudos da água, como na estimativa de parâmetros individuais de qualidade da água (VENTURA, 2013; COELHO *et al.*, 2017; KIM *et al.*, 2017; ABDELMALIK, 2018; JIANG *et al.*, 2019; PEREIRA *et al.*, 2019; SAYERS *et al.*, 2019; LOPES *et al.*, 2019; SUN *et al.*, 2019).

### 2.1.1 Comportamento espectral de alvos

Os objetos da superfície terrestre possuem diferentes composições moleculares, deste modo, refletem e absorvem energia eletromagnética de maneira diferente, o que confere respostas espectrais distintas (Figura 3). Comportamento espectral de alvos trata da caracterização da interação da REM com cada alvo e a intensidade a qual ela é refletida, absorvida, transmitida ou emitida nos diversos comprimentos de onda (HAMADA, 2000).

Lopes (2013) afirma que é possível obter informações a respeito dos diferentes alvos utilizando sensores acoplados em plataformas orbitais, aerotransportadas e/ou de campo. A espectroradiometria tem sido utilizada para estudar com mais detalhes as características de um objeto utilizando o SR e, segundo Menezes (2001), a observação de imagens interpretadas por meio da análise espectral garantem maior segurança nos resultados do que com atributos espaciais.

Figura 3 - Comportamento espectral dos diferentes alvos



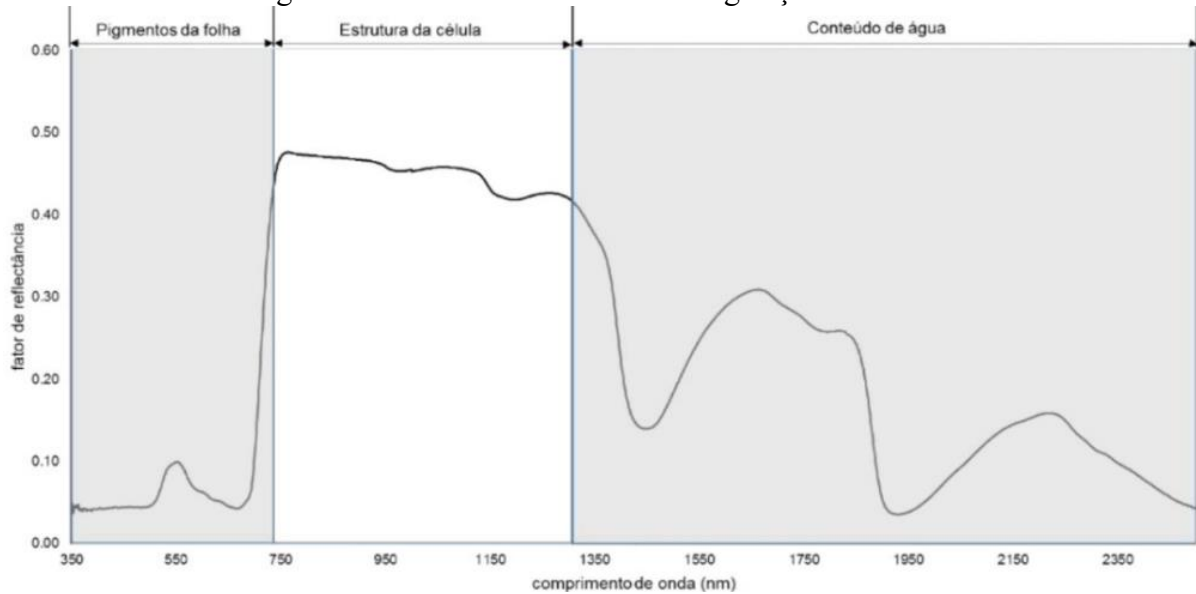
Fonte: Adaptado de Swain & Davis (1978).

### 2.1.2 Comportamento espectral da vegetação

A folha exerce uma função muito importante no estudo do comportamento espectral da vegetação, por ser o principal órgão sujeito à radiação eletromagnética (FERREIRA; SILVA, 2011). Segundo Liu (2015), a radiação solar atinge o dossel e interage com a celulose, solutos, espaços celulares ocupados pela água e pelo ar e a concentração de pigmentos fotossintetizantes, dessa forma, tem-se na avaliação do comportamento espectral da vegetação, um significativo fator para monitoramento de culturas agrícolas (LIANG, 2005).

O comportamento espectral de uma folha verde sadia está disposto na Figura 4 e caracteriza-se em três regiões espectrais: I) de 300 até 700 nm, apresentando baixa reflectância (menor que 20%); II) entre 700 nm a 1300 nm, manifestando uma reflectância relativamente alta (entre 30% e 50%) e III) entre 1300 e 2500 nm, onde a reflectância varia de valores abaixo de 20% a até 4% (NOVO, 2010; LORENZZETTI, 2015).

Figura 4 - Fator de reflectância da vegetação verde e sadia



Fonte: Novo (2010).

Na região do visível (VIS), os principais componentes que promovem alterações na resposta espectral da planta são clorofila e carotenoides (NOVO, 2010; LORENZZETTI, 2015). As folhas verdes saudáveis absorvem energia nos comprimentos de onda do azul (400–500 nm) e vermelho (600 – 700 nm), ocasionando a ocorrência da reflectância principalmente na região específica do verde (550 nm).

A região do infravermelho próximo (NIR), localizada entre os comprimentos de onda de 700 e 1.300 nm, é influenciada pela estrutura celular do mesófilo, onde a reflectância aumenta devido ao elevado espalhamento interno na folha (DOS SANTOS DA SILVA, ARLENE; SILVA GALEN, 2016). A reflectância no NIR é estreitamente influenciada pelo crescimento foliar e pelo incremento da biomassa em plantas bem fertilizadas, além disso, essa região é muito utilizada na previsão de nutrientes foliares, em virtude das correlações entre as alterações de reflectância com mudanças estruturais (SCHLEMMER *et al.* 2013).

A faixa que compreende os comprimentos de onda de 1.300 a 2.500 nm é denominada como infravermelho médio (SWIR) e é definida pelo conteúdo de água na folha. Nessa região, conforme a folha estiver mais seca, maiores serão os fatores de reflectância (PONZONI; SHIMABUKURO, 2009). Segundo Ponzoni *et al.* (2012), os comprimentos de onda onde concentram-se os picos de absorção de água são: 1450 nm, 1950 nm e 2700 nm, equivalendo às bandas de absorção atmosférica.



### **2.1.3 Estimativa de nutrientes foliares por Sensoriamento Remoto**

Segundo Paulo *et al.* (2018), sensoriamento remoto é uma técnica que está conquistando espaço na agricultura, principalmente na predição de nutrientes em plantas. Para utilizar a REM na estimativa de nutrientes foliares é necessário conhecimento da composição química e estrutura celular da folha, bem como dos fatores que neles interferem. As principais características de interesse são mudanças na quantidade de pigmentos fotossintetizantes e sua morfologia interna (PONZONI, 2007).

As regiões mais utilizadas para identificar modificações na reflectância provenientes da nutrição foliar são as regiões do visível e infravermelho próximo. Observa-se um aumento da reflectância no comprimento de onda de 550 nm (verde) e 715 nm (borda-vermelha), em virtude do aumento das quantidades de clorofila (DAUGHTRY *et al.*, 2000).

A partir dos dados de reflectância obtidos por meio de sensores, é possível o desenvolvimento de índices e modelos, que aliados a dados resultantes de análises laboratoriais (ROSSATO *et al.*, 2012), permitem a estimativa de nutrientes foliares a partir da correlação entre os melhores comprimentos de onda que exprimem determinada característica e os parâmetros da vegetação (EPIPHANIO *et al.*, 1996).

A utilização de técnicas de sensoriamento remoto na agricultura permite que o produtor tenha conhecimento a respeito das variações espaciais e fenológicas dos nutrientes nas culturas, bem como realizar suplementações imediatas nas quantidades necessárias pela planta (BRANDÃO, 2009).


### **2.1.4 Comportamento espectral da água**

A água pode ser encontrada na superfície da Terra nos estados sólido, líquido e gasoso e, de acordo com a forma na qual se encontra, apresenta comportamento espectral distinto (Figura 5).

Diferentemente dos demais alvos, a água líquida apresenta baixa reflectância, o que dificulta os estudos por imagens de satélites. No estado líquido, a água apresenta reflectância inferior a 10% e localiza-se em comprimentos de onda entre 380 e 700 nm (faixa do visível), sendo absorvida nas demais regiões do espectro. No estado gasoso, a reflectância da água é alta, em torno de 70% ao longo de todo o espectro, com absorção nos comprimentos de 1000, 1300 e 2000 nm (região do infravermelho). Para a água no estado sólido, a reflectância se mantém alta, em torno de 80% nos comprimentos de onda entre 700 e 1200 nm (região do infravermelho

próximo), entretanto, decresce para valores abaixo de 20% nos comprimentos de onda acima de 1400 nm (NOVO, 2010).

Figura 5 - Curvas de reflectância da água nos estados líquido, gasoso (nuvem) e sólido (neve)



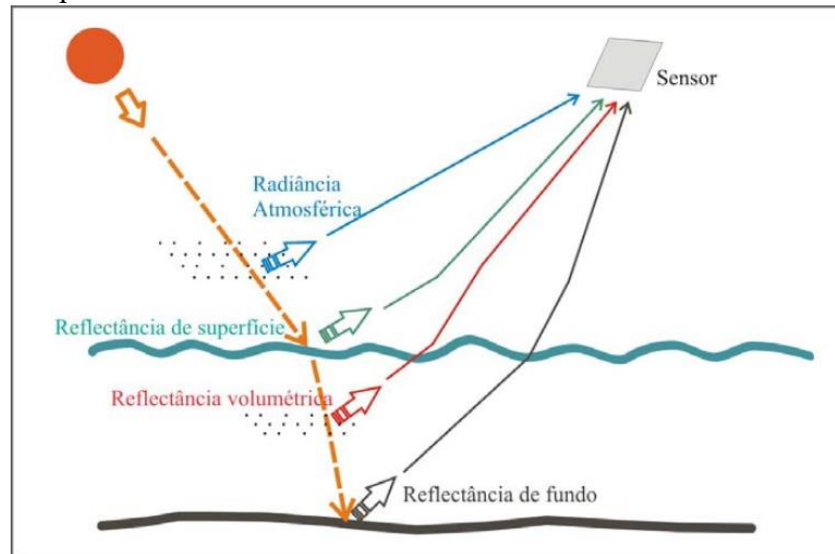
Fonte: Novo (2008).

O comportamento espectral da água não é determinado apenas por características da própria água, mas também em função dos Constituintes Opticamente Ativos (COAs) nela presentes, como pigmentos fotossintetizantes (clorofila-a); sólidos inorgânicos em suspensão (SIS) e material orgânico dissolvido (MOD) (KIRK, 2011).

A radiação, ao penetrar na coluna d'água sofre alterações na sua intensidade e composição espectral, diminuindo rapidamente nos metros iniciais e depois mais lentamente. Essa radiação que contribui para os processos dos sistemas aquáticos, é a fotossinteticamente ativa, que está compreendida entre 400 nm e 700 nm, região em que a radiação solar atinge o meio ambiente terrestre com maior intensidade. (BARBOSA, 2005).

Segundo Novo (2010), a água pura apresenta baixa reflectância na região do visível, em resposta ao pequeno espalhamento e alta transmitância, o que o difere do fluxo incidente no solo e vegetação, onde a maior parte é refletido. A Figura 6 exemplifica as interações da radiação eletromagnética com os constituintes do corpo d'água.

Figura 6 - Diferentes formas de interação da radiação com os corpos hídricos



Fonte: Adaptado de Barbosa, (2005).

A energia proveniente do Sol incide sobre os corpos hídricos e o total registrado pelo sensor é resultante de quatro fontes: radiação atmosférica ( $L_p$ ), radiação de superfície ( $L_s$ ), radiação volumétrica ( $L_v$ ) e radiação de fundo ( $L_b$ ).

A radiação é emitida pela fonte geradora de energia, podendo: interagir com as moléculas da atmosfera e, de fato, nunca atingir a superfície da água ( $L_p$ ); penetrar cerca de 1 mm na água, sendo refletida da superfície ( $L_s$ ); penetrar e interagir com a água e seus constituintes orgânicos e inorgânicos e emergir da coluna d'água sem interagir com o fundo ( $L_v$ ) ou penetrar na água, alcançar o fundo e ser propagada de volta na coluna d'água até entrar em contato com o sensor ( $L_b$ ) (BARBOSA *et al.*, 2005).

## 2.1.5 Propriedades ópticas dos componentes opticamente ativos na água

### 2.1.5.1 Clorofila – a


A clorofila-a é um fitopigmento que está presente em todos os grupos de algas. Matsushita *et al.* (2015) afirmam em seus estudos que a concentração de clorofila-a é um dos atributos mais importantes para a avaliação e monitoramento do estado dos corpos hídricos.

Segundo Londe (2008), a radiação aproveitada pelos pigmentos fotossintetizantes para a realização da fotossíntese está compreendida nas faixas do azul (400 a 500 nm) e do vermelho (600 a 700 nm), absorvendo maior quantidade de energia nessas faixas do que na

região espectral do verde (500 a 600 nm), o que confere a coloração verde nos corpos hídricos com grandes quantidades de algas.

Além da clorofila-a, outros pigmentos, conhecidos como pigmentos acessórios, também realizam, em menor quantidade, a absorção de energia (clorofilas b, c, d, e) (BERNARDO *et al.*, 2016). A Figura 7 exibe o comportamento espectral de alguns destes tipos de pigmentos.

Figura 7 - Comportamento espectral das Clorofilas a, b e c

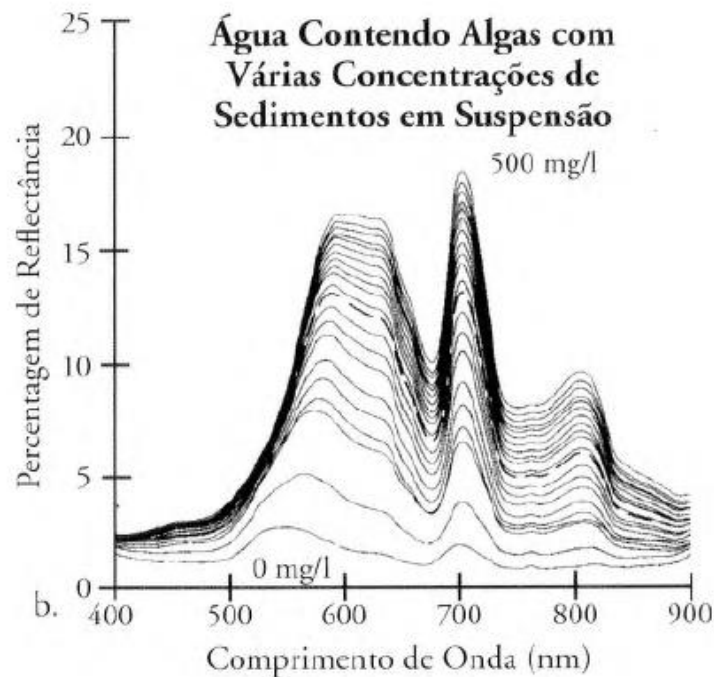


Fonte: Kemker (2014).

A região compreendida entre 350 e 700 nm faz correspondência à faixa de radiação fotossinteticamente ativa. Tal faixa é onde a maioria dos modelos de recuperação de clorofila-a são desenvolvidos (LE *et al.*, 2009), sendo de grande importância para os estudos sobre comportamento espectral da água. Segundo Kirk (2011), na região entre 400 e 500 nm ocorre alta absorção do azul pela clorofila-a, na região de 675 nm ocorre alta absorção do vermelho e ocorre um pico de reflectância na região de 550 nm, devido a menor absorção do verde.

Quando um corpo hídrico possui sedimentos em suspensão e clorofila ao mesmo tempo, observa-se uma resposta espectral diferente. Ao adicionar concentrações de sedimentos à água, o pico de reflectância no visível desloca-se de 547 nm para 596 nm (Figura 8).

Figura 8 - Comportamento espectral da água para diferentes concentrações de sedimentos em suspensão



Fonte: Jensen (2009).

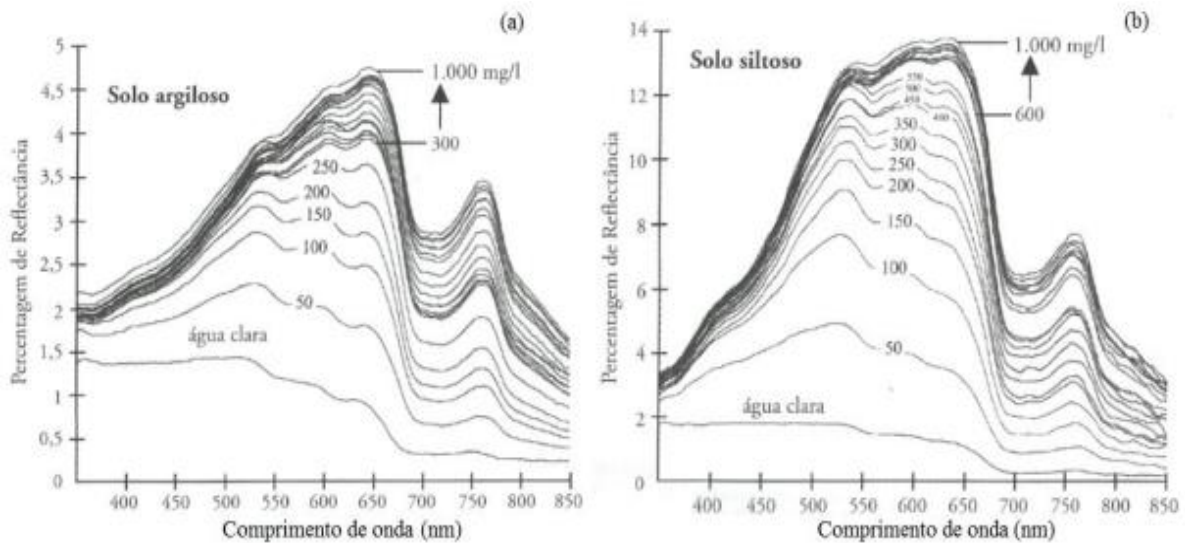
#### 2.1.5.2 Sólidos Inorgânicos em Suspensão

Segundo Barbosa (2005), o TSS (total de sólidos em suspensão) é todo o material particulado em suspensão na água e que não passa por um filtro de  $0,45 \mu\text{m}$ . O TSS representa o componente que tem maior peso na reflectância espectral da água.

Sólidos nos corpos hídricos fazem referência a toda matéria que permanece como resíduo após a evaporação. Sólidos inorgânicos em suspensão são o total de partículas inorgânicas que ficam suspensas em função do tamanho e quantidade. A fração inorgânica é constituída principalmente de silte e argila (KEMKER, 2014).

Conforme a concentração de partículas inorgânicas em suspensão na água aumenta, o efeito de espalhamento da luz também é elevado, o que resulta em maiores valores de reflectância ao longo de todo o espectro (Figura 8), com um pico na região do infravermelho próximo, mais precisamente em 810 nm (BERNARDO, 2015).

Figura 9 - Reflectância espectral da água clara contendo diferentes composições de sólidos suspensos: (a) solo argiloso; (b) solo siltoso



Fonte: Jensen (2009).


Na Figura 9 observa-se que tanto o tamanho quanto o tipo de partícula influenciam os processos de absorção e espalhamento, tendo o solo siltoso uma composição que resulta em uma reflectância mais alta do que o solo argiloso, que por ser um solo escuro, devido à maior quantidade de matéria orgânica, resulta em valores mais baixos de reflectância. O aumento das concentrações dos sólidos inorgânicos proporcionou um aumento de reflectância em todos os comprimentos de onda e promoveu o deslocamento do pico para as regiões de maiores comprimentos de onda na faixa do visível.

Diversos estudos mencionam que existe forte correlação entre a concentração de partículas de sedimentos em suspensão e a radiância espectral. Lopes *et al.* (2014a) afirmam que o comprimento de onda de 720 nm foi o que melhor apresentou correlação com os sólidos inorgânicos suspensos.

### 2.1.5.3 Material Orgânico Dissolvido

A matéria orgânica dissolvida é constituída por diversas substâncias advindas da excreção, secreção e decomposição de organismos terrestres e aquáticos. Compreende principalmente os ácidos fúlvicos e húmicos presentes nos solos que conferem uma cor amarelada aos corpos hídricos, por remover o componente azul da radiação incidente, sendo chamados de substâncias amarelas (BARBOSA, 2019). A presença desse material na água tem maior influência da absorção de energia na região do azul, entre os comprimentos de onda de

400 a 500 nm, sendo reduzida na região do vermelho, acima de 600 nm (MOBLEY, 2004). A Figura 10 mostra a reflectância da água com diferentes concentrações de MOD.



A Figura 10 infere que a reflectância da água diminui conforme a concentração de MOD é elevada, principalmente da região azul para a vermelha, contudo, entre os comprimentos de onda de 670 e 900 nm ocorre um aumento da reflectância que, segundo Mobley (2004) se deve à presença dos colóides na MOD que contribuem para o espalhamento da REM. Segundo Novo (2001), o aumento da concentração da MOD promove uma coloração da água, inicialmente amarelada, progredindo para uma cor mais escura, devido à redução da reflectância.

## 2.2 Modelos de estimativa da concentração de clorofila-a

O monitoramento da qualidade da água é fundamental nos dias atuais e, a utilização de dados de sensoriamento remoto pode tornar tal atividade mais eficaz (LOPES *et al.*, 2014b). A concentração de clorofila-a é um parâmetro que se relaciona com a biomassa e a produtividade do fitoplâncton e, para estimá-lo, faz-se uso de modelos combinados com a reflectância (transformação dos sinais de radiância obtidos de maneira remota em determinadas regiões do espectro eletromagnético) (DALL'OLMO; GITELSON, 2005).

Os modelos para estimar as concentrações de clorofila-a foram inicialmente aplicados em águas oceânicas, entretanto, tais estudos têm sido direcionados também, para águas interiores. Carvalho, Barbosa e Novo (2013) afirmam que as águas continentais apresentam clorofila-a, MOD e partículas orgânicas e inorgânicas em altas concentrações e que cada um desses constituintes sofre variações sem depender uns dos outros, dificultando o ajuste dos modelos, uma vez que a matéria orgânica dissolvida e o material em suspensão interferem na resposta espectral dos pigmentos fotossintetizantes.

Para estimar as concentrações de clorofila-a uma operação matemática conhecida como razão entre bandas é comumente utilizada, uma vez que permite discriminar sutis diferenças existentes no comportamento espectral de diferentes alvos, que em bandas originais não são observadas (ARAÚJO, 2013). Para a aplicação da razão, as bandas são selecionadas conforme seus valores máximo e mínimo de reflectância, de modo a expressar os gradientes da curva espectral dos objetos de interesse, proporcionando o realce destes alvos (Sestini, 1999).

Os modelos que aplicam razão de bandas para estimar a concentração de clorofila-a em lagos eutrofizados usam bandas localizadas, principalmente, nas regiões do vermelho e infravermelho próximo (NIR) (GHOLIZADEH *et al.* 2016). Dekker e Petters (1993), afirmam em seus estudos que a máxima absorção em torno do comprimento de onda de 675 nm (vermelho) tem sido tomada como mais importante para extrair informações da clorofila-a.

### ***2.2.1 Regressão por Mínimos Quadrados Parciais (Partial Least Square Regression – PLSR)***

A Regressão de Mínimos Quadrados Parciais (PLSR) tem sido fortemente utilizada para a construção de modelos de estimativa quando se tem um elevado número de fatores com alta colinearidade. Wold; Sjostrom; Eriksson (2001) afirmam que essa técnica reduz os dados a um conjunto menor de componentes que não correlacionados e efetua a regressão de mínimos quadrados para o novo conjunto.

O PLSR usa os princípios da análise de componentes principais (PCA) e regressão linear múltipla para explicar a variabilidade nas variáveis preditoras (X) e de resposta (Y) (MAO *et al.*, 2015; ABDEL-RAHMAN *et al.*, 2017). Este método é comumente utilizado em dados de espectroscópicos, na quimiometria, a fim de tratar a dimensionalidade e colinearidade dos dados produzidos por estes equipamentos (TOBIAS, 1995; LIU *et al.* 2020).



O método PLSR tem sido utilizado por diversos autores (ABDEL-RAHMAN *et al.*, 2017; COMINO *et al.*, 2018; GE *et al.*, 2019; SANTOSO *et al.*, 2019) para predição de nutrientes foliares.

### 3 OBTENÇÃO DAS CONCENTRAÇÕES NUTRICIONAIS FOLIARES DA CULTURA DO FEIJÃO-CAUPI POR MEIO DA ESPECTROSCOPIA DE REFLECTÂNCIA <sup>1</sup>

#### RESUMO

Embora a técnica de sensoriamento remoto hiperespectral venha sendo cada vez mais utilizada para a quantificação nutricional de plantas, é necessário buscar entender se o método responde satisfatoriamente em diferentes estádios fenológicos das culturas. O objetivo do trabalho foi quantificar os teores de P, K, Ca e Zn nas folhas do *Vigna Unguiculata* (L.) Walp por meio de dados espectrais obtidos por espectroradiômetro. O delineamento foi em blocos casualizados com três tratamentos e vinte e cinco repetições. Avaliou-se a cultura em três fases de desenvolvimento: V4, R6 e R9, em que foram coletadas amostras foliares para leitura de dados espectrais com o espectroradiômetro FieldSpec 3 Hi-Res e posterior análise foliar, realizada por meio da digestão via úmida nitro-perclórica, no Laboratório de Solos, Água e Planta da Embrapa Agroindústria Tropical. Para predição dos nutrientes foram utilizados modelos de banda única, razão de bandas e regressão por mínimos quadrados parciais (PLSR). Os modelos de banda única foram ajustados por correlações simples. Nos modelos de razão de bandas os comprimentos de onda foram selecionados pela correlação 2D e nos modelos por PLSR pelo método stepwise. O modelo de melhor ajuste foi o utilizado para estimar os teores de fósforo, nos modelos de banda única ( $R^2 = 0,62$ ; RMSE = 0,54 e RPD = 1,61), razão de bandas ( $R^2 = 0,66$ ; RMSE = 0,65 e RPD = 1,52) e no PLSR, com dados de todas as fases fenológicas ( $R^2 = 0,80$ ; RMSE = 0,47 e RPD = 1,66). A acurácia da modelagem de nutrientes foliares depende do estágio fenológico, bem como da quantidade de dados utilizados, sendo mais precisa com um maior número de amostras.

**Palavras-chave:** *Vigna unguiculata*; feijão-caupi; dados hiperespectrais; avaliação do estado nutricional

---

<sup>1</sup> Artigo publicado na revista Applied Sciences em 04 de janeiro de 2022. Link de acesso ao artigo: <https://www.mdpi.com/2076-3417/12/1/458/htm>

## ABSTRACT

Although the hyperspectral remote sensing technique has been increasingly used for the nutritional quantification of plants, it is necessary to seek to understand whether the method responds satisfactorily in different phenological stages of crops. The objective of this work was to quantify the levels of P, K, Ca and Zn in the leaves of *Vigna Unguiculata* (L.) Walp through spectral data obtained by spectroradiometer. The design was in randomized blocks with three treatments and twenty-five replications. The culture was evaluated in three stages of development: V4, R6 and R9, in which leaf samples were collected for spectral data reading with the Field Spec 3 Hi-Res spectroradiometer and subsequent leaf analysis, performed by means of wet nitro digestion. -perchloric, at the Soil, Water and Plant Laboratory of Embrapa Agroindústria Tropical. For the prediction of nutrients, single band models, band ratio and partial least squares regression (PLSR) were used. Single-band models were fitted by simple correlations. In the band-ratio models, the wavelengths were selected by the 2D correlation and in the PLSR models by the stepwise method. The best fit model was used to estimate phosphorus levels, in the single band models ( $R^2 = 0.62$ ; RMSE = 0.54 and RPD = 1.61), band ratio ( $R^2 = 0.66$ ; RMSE = 0.65 and RPD = 1.52) and in the PLSR, with data from all phenological phases ( $R^2 = 0.80$ ; RMSE = 0.47 and RPD = 1.66). The accuracy of foliar nutrient modeling depends on the phenological stage, as well as the amount of data used, being more accurate with a greater number of samples.

**Keywords:** *cowpea; hyperspectral data; nutritional status assessment*

### 3.1 Introdução

O *Vigna Unguiculata* (L.) Walp (*Vigna unguiculata* (L.) Walp.) é uma cultura originária da África, comumente utilizada como fonte primária de proteína (MUÑOZ-AMATRIAÍN *et al.*, 2017). Essa cultura também tem importância em partes da América do Sul, Ásia e Estados Unidos da América (CARVALHO *et al.*, 2017; LONARDI *et al.*, 2019), por apresentar boa adaptabilidade às condições climáticas. O desenvolvimento dessa cultura está diretamente relacionado à disponibilidade de nutrientes (CAMPANHARO *et al.*, 2013) e, para avaliar se o manejo do solo adotado tem resultados positivos na planta, é feita análise foliar.

A nutrição de plantas é um fator determinante para a realização de processos fisiológicos que influenciam no crescimento, desenvolvimento e produção das culturas (LI *et al.*, 2020). O monitoramento do estado nutricional da vegetação é comumente realizado por meio de análises laboratoriais que exigem grande quantidade de folhas e métodos que demandam tempo, são laboriosos e geram resíduos poluentes (MALMIR *et al.*, 2019). Além disso, tais análises devem ser realizadas frequentemente a fim de garantir melhor representação da situação nutricional das culturas, gerando custos extras para os agricultores (OSCO *et al.*, 2019).

Diante de tantos desafios para a avaliação de nutrientes foliares, técnicas de sensoriamento remoto surgem como técnicas alternativas e eficientes no monitoramento nutricional, bem como no conteúdo de clorofila, identificação de doenças, dentre outras atividades (ABDULRIDHA, J.; BATUMAN, O.; AMPATZIDIS, Y, 2019; CALOU *et al.*, 2020; OSCO *et al.*, 2020; PENG *et al.*, 2019; ZHOU *et al.*, 2016). O sensoriamento remoto permite o monitoramento nutricional de plantas de maneira não destrutiva e rápida, utilizando imagens de satélites e sensores multi e hiperespectrais (O'CONNELL; BYRD; KELLY, 2014; ZHOU *et al.*, 2016; OLIVEIRA *et al.*, 2020).

Pesquisadores têm utilizado dados multiespectrais (CHEN; WANG, 2019; WEN *et al.*, 2019; FLETCHER; REDDY, 2016) e hiperespectrais na folha (PULLANAGARI; KERESZTURI; YULE, 2016; YU; LU; LIU, 2018; WEN *et al.*, 2019) para monitoramento e estimativa nutricional das culturas. Dados multiespectrais registram menor número de informações, uma vez que coletam menor número de bandas largas em determinadas regiões do espectro eletromagnético (PULLANAGARI; KERESZTURI; YULE, 2016).

Por outro lado, dados hiperespectrais registram informações espectrais quase contínuas a partir de bandas estreitas localizadas na região do visível (400–700 nm), infravermelho próximo (NIR: 700–1300 nm) e infravermelho de ondas curtas (SWIR: 1300–2500) (GAMA *et al.*, 2018). O nitrogênio (N) é o nutriente mais avaliado por sensores hiperespectrais, entretanto, estudos também obtiveram resultados satisfatórios para a determinação de fósforo (P), potássio (K) e cálcio (Ca), com dados variando do comprimento de onda 350 a 2500 nm (LING *et al.*, 2019; DE OLIVEIRA; FONTES; PASQUINI, 2019).

A elevada quantidade de informação gerada por sensores hiperespectrais promove uma multicolinearidade entre as bandas vizinhas, o que dificulta a análise dos dados. Os modelos de regressão por mínimos quadrados parciais (PLSR) apresentam resultados satisfatórios na redução da multicolinearidade em dados de espectrorradiometria (ABDELRAHMAN *et al.*, 2017). Estudos têm empregado PLSR na geração de modelos em que se

tenham pequenos conjuntos amostrais e um grande número de respostas. O modelo PLSR tem se mostrado adequado na estimativa dos teores de nutrientes nas culturas (MAO *et al.*, 2015; ABDEL-RAHMAN *et al.*, 2017; GAMA *et al.*, 2018). Além disso, Neto *et al.*, (2017) utilizou o PLSR para estimar a condutividade elétrica (salinidade) do solo utilizando espectroscopia.

Pesquisadores obtiveram resultados eficientes para a estimativa de nutrientes foliares utilizando dados hiperespectrais em leguminosas (HALGERSON *et al.*, 2004; GONZÁLEZ-MARTÍN *et al.*, 2007), laranja-valência (OSCO *et al.*, 2020), milho (WILCOX; FAGERIA, 1976), colza (ZHENG *et al.*, 2018), pastagem (PULLANAGARI; KERESZTURI; YULE, 2016) entre outras culturas. Diversos estudos obtiveram calibrações positivas para a predição de nutrientes em plantas empregando o modelo PLSR. Bons resultados de calibração de modelos para estimar as concentrações de nutrientes foram encontrados em culturas cítricas (GALVEZ-SOLA *et al.*, 2015), em gramíneas (YU; LU; LIU, 2018) e leguminosas (HALGERSON *et al.*, 2004; GONZÁLEZ-MARTÍN *et al.*, 2007).

Apesar de várias pesquisas apresentarem resultados eficientes para a estimativa de nutrientes foliares em diferentes culturas utilizando técnicas de sensoriamento remoto, é necessário buscar entender se o método responde satisfatoriamente em diferentes estádios fenológicos das culturas.

## **3.2 Objetivos**

O objetivo geral deste capítulo foi aplicar métodos de regressão para quantificar os teores de P, K, Ca e Zn nas folhas de *Vigna Unguiculata* (L.) Walp durante as fases vegetativa e reprodutiva por meio de dados espectrais obtidas por espectroscopia de reflectância nas faixas do visível, infravermelho próximo e no infravermelho médio.

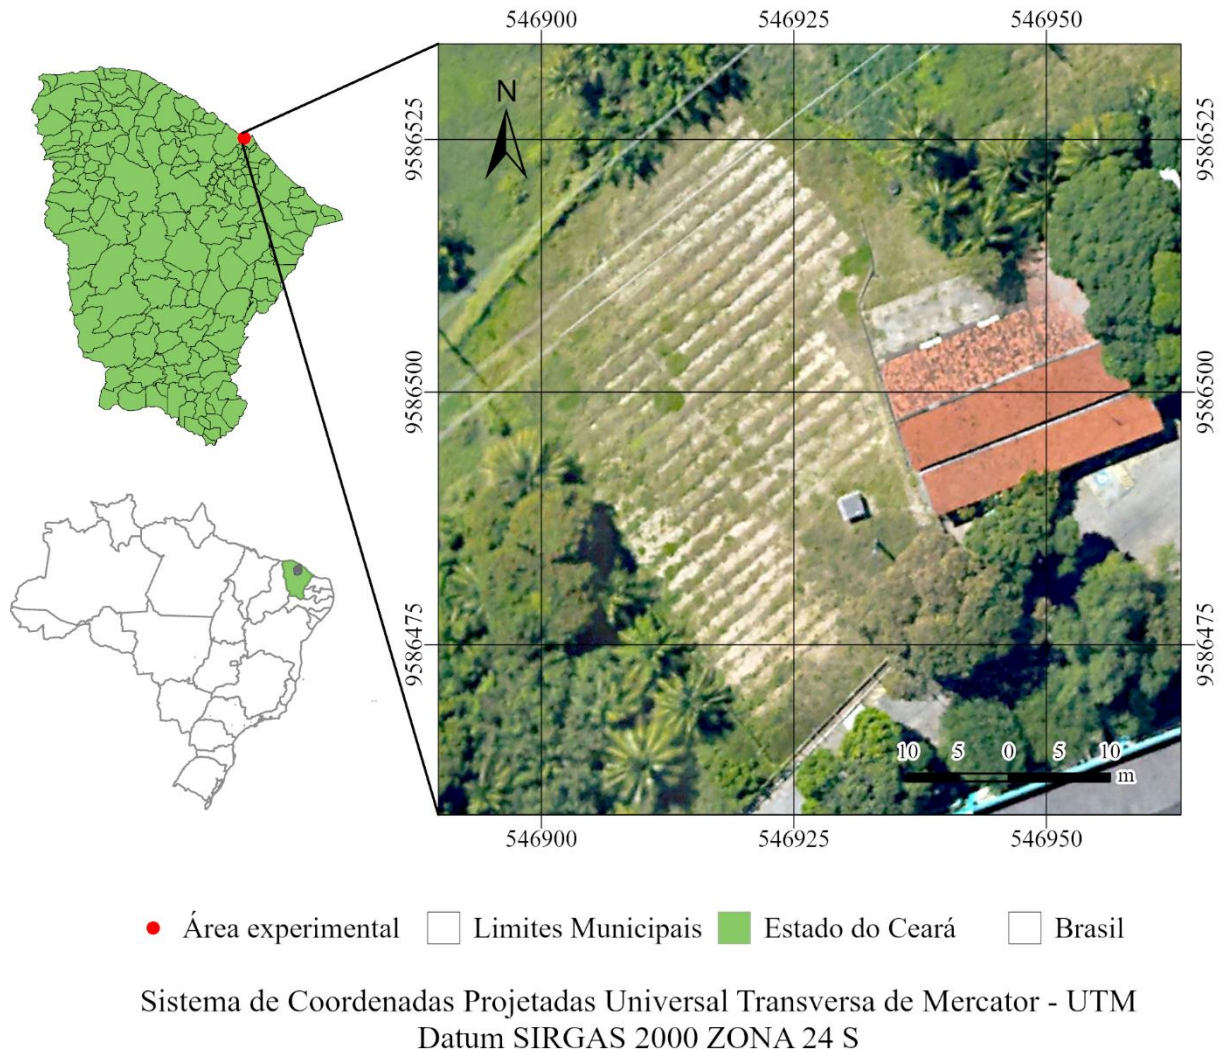
## **3.3 Metodologia**

### ***3.3.1 Caracterização da área de estudo***

O experimento foi realizado em campo experimental na Universidade Federal do Ceará, Campus do Pici (546920 E, 9586497 S) (Figura 11). O clima da região é classificado, segundo Köppen, como tropical chuvoso (Aw'), apresentando estação chuvosa no verão e estação seca no inverno, com temperaturas médias mensal superior a 18 °C. Durante a realização do experimento, os valores mínimo, médio e máximo de temperatura foram 25,9;

27,6 e 28,7 °C, respectivamente; enquanto os valores mínimo, médio e máximo da umidade relativa foram 64,25; 72 e 81,5%, respectivamente. O solo da área é de textura arenosa e as principais características físicas e químicas estão apresentadas na Tabela 1.

Figura 11 - Localização do experimento



Fonte: Elaboração da autora.

Tabela 1 - Análise físico-química de solo da área experimental

<b>Atributos</b>	<b>Valor</b>
Areia grossa (g kg <sup>-1</sup> )	523,00
Areia fina (g kg <sup>-1</sup> )	370,00
Silte (g kg <sup>-1</sup> )	52,00
Argila (g kg <sup>-1</sup> )	55,00
Argila natural (g kg <sup>-1</sup> )	17,00
Densidade do solo (g cm <sup>-3</sup> )	1,46
Densidade de partículas (g cm <sup>-3</sup> )	2,68
pH (água)	6,92
Cálcio (mmolc dm <sup>-3</sup> )	16,00
Magnésio (mmolc dm <sup>-3</sup> )	13,00
Sódio (mmolc dm <sup>-3</sup> )	3,00
Potássio (mmolc dm <sup>-3</sup> )	1,00
H + Al (mmolc dm <sup>-3</sup> )	18,20
Carbono orgânico (g kg <sup>-1</sup> )	7,02
Nitrogênio total (g kg <sup>-1</sup> )	0,68
Matéria orgânica (g kg <sup>-1</sup> )	12,10
P assimilável (mg dm <sup>-3</sup> )	23,00
Relação C:N	10,00

Fonte: Magalhães (2018).

As parcelas experimentais eram formadas por cinco linhas de plantio, com espaçamento de 1,0 x 0,3 m e área total de 9,0 m<sup>2</sup>. Foram mantidas duas plantas por cova, totalizando uma população de aproximadamente 67.000 plantas ha<sup>-1</sup>. A cultura foi irrigada por gotejamento a cada dois dias, sendo essa irrigação suspensa no estágio de maturação dos frutos.

### 3.3.2 Aquisição de amostras foliares

O ciclo da cultura do *Vigna Unguiculata* (L.) Walp é composto por dez fases fenológicas, definidas por Dourado; Fancelli (2000), sendo cinco fases vegetativas e cinco fases reprodutivas (Tabela 2). As coletas das amostras foliares foram realizadas nos estádios V4 (terceira folha composta totalmente aberta), R6 (pelo menos 50% das flores abertas) e R9 (maturação das vagens). As folhas foram coletadas sempre no mesmo horário (08:00 às 11:00

h), e, imediatamente após a coleta, as leituras radiométricas foram realizadas no Laboratório de Espectroradiometria da Universidade Federal do Ceará. Em seguida, as amostras foram colocadas para secar em estufa e posteriormente utilizadas para a realização das análises minerais.

Tabela 2 - Fenologia do *Vigna unguiculata* (L.) Walp

Fase Fenológica	Código de Identificação	Caracterização da Fase
Vegetativa	V0	Início da germinação
	V1	Cotilédones ao nível do solo
	V2	Folhas primárias expandidas
	V3	Primeira folha trifoliada
	V4	Terceira folha trifoliada
Reprodutiva	R5	Formação dos botões florais
	R6	Abertura da primeira flor
	R7	Surgimento das vagens
	R8	Primeiras vagens cheias
	R9	Maturidade fisiológica

Fonte: Adaptada de Dourado; Fancelli (2000).

### 3.3.3 Aquisição de dados radiométricos hiperespectrais


Para aquisição dos dados radiométricos, utilizou-se o espectroradiômetro FieldSpec 3 Hi-Res (Figura 12), com campo de visada de 25°, que opera na região de 350 a 2500 nm e com resolução espectral de 3 nm em 700 nm, 8,5 nm em 1400 nm e 6,5 nm em 2100 nm. O sensor reamostra os dados para 1 nm, totalizando 2151 bandas.

As leituras foram realizadas em sala escura, e assim eliminada a interferência de radiação externa que viesse a comprometer os resultados. O sensor estava posicionado ao nadir, a 7 cm de distância das amostras.

Como fonte de luz, foi utilizada uma lâmpada halógena de 250 W de potência com refletor parabólico, feixe colimado para o plano visado e com 30° de ângulo zenital de iluminação. Foi utilizada uma placa spectralon branca de alta reflectância para calibração do sensor. Em cada amostra de folhas foram realizadas 5 leituras. Posteriormente os dados foram processados por meio do software ViewSpec Pro e analisados em planilha eletrônica.



Figura 12 - Geometria de aquisição dos dados radiométricos



Fonte: Campelo (2018), adaptado pela autora.

Após a eliminação das medidas não representativas foi realizado o cálculo da média do fator de reflectância. Os valores de radiância espectral foram convertidos em fator de reflectância bidirecional conforme a Equação 1:

$$RB\lambda = \frac{La,\lambda}{Lr,\lambda} \quad (1)$$

em que:

FRB $\lambda$  - fator de reflectância bidirecional (adimensional)

La, $\lambda$  - radiância espectral do alvo (W.cm<sup>-2</sup>.sr<sup>-1</sup>. $\mu$ m<sup>-1</sup>)

Lr, $\lambda$  - radiância espectral da placa de referência (W.cm<sup>-2</sup>.sr<sup>-1</sup>. $\mu$ m<sup>-1</sup>)

### 3.3.4 Calibração dos modelos de estimativa dos teores nutricionais foliares

Os modelos foram testados empregando-se uma correlação simples, razão de duas bandas (correlação 2D) e regressão por mínimos quadrados parciais (PLSR).

O total de dados de trabalho foi dividido em dois conjuntos: calibração dos modelos, que compreende 70% das observações e validação dos modelos, abrangendo os 30% restantes para testagem dos modelos calibrados.

#### 3.3.4.1 Correlação simples

Para selecionar as bandas utilizadas no estudo realizou-se uma análise de correlação simples entre os dados espectrais e os teores de nutrientes obtidos da análise foliar, sendo

selecionadas as bandas com o coeficiente de correlação ( $r$ ) mais próximos de  $-1$  e  $+1$ , uma vez que mais próximo dos valores extremos, sugere-se que a correlação é mais forte.

Selecionado o comprimento de onda que apresentou valor de  $r$  mais próximo de  $|1|$ , a resposta espectral das folhas (grupo de calibração – 70%) foi correlacionada com os teores de nutrientes foliares medidos.

#### 3.3.4.2 Razão de bandas

Gerou-se um gráfico de correlação 2D para selecionar as bandas significativas a serem empregadas na razão de bandas, utilizando-se uma ferramenta estatística para análise de colinearidade, disponível na plataforma online do Instituto Nacional de Pesquisas Espaciais (INPE) (OGASHAWARA *et al.*, 2014).

A correlação 2D é uma técnica estatística que permite quantificar a correlação entre uma variável dependente e algumas variáveis independentes. Segundo Ogashawara *et al.* (2014), essa técnica é comumente aplicada na estimativa de parâmetros biogeoquímicos por meio de dados espectrais e, a utilização de gráficos de correlação é uma ferramenta importante para a seleção de bandas, sendo reforçados pela utilização de sensores hiperespectrais. Almeida *et al.* (2021) utilizaram essa técnica para selecionar os melhores Índices por Diferença Normalizada a fim de estimar a textura do solo.

Selecionada a razão entre as bandas que apresentaram valores de  $r$  mais próximos de  $|1|$ , a razão da resposta espectral das folhas (grupo de calibração – 70%) foi utilizada para produzir modelos de estimativa dos teores de nutrientes foliares medidos.

#### 3.3.4.3 Regressão por Mínimos Quadrados Parciais (Partial Least Square Regression – PLSR)

Para a realização da regressão por mínimos quadrados parciais foram removidas as características espectrais de 350–399 devido alto nível de ruído. O PLSR foi realizado utilizando o software The Unscrambler®, no qual foram adicionados os valores do fator de reflectância para cada comprimento de onda ( $X$ ) e os valores das respostas variáveis ( $Y$ ), que se referiam ao conteúdo de nutrientes do *Vigna Unguiculata* (L.) Walp.

Para seleção dos comprimentos de onda significativos, foi utilizado o do software IBM SPSS Statistics®, a partir do método Stepwise, posteriormente foi utilizado o software The Unscrambler® (CAMO AS, 2021) em versão de teste, para construir os modelos de predição do teor nutricional das folhas.

### 3.3.5 Validação dos modelos de estimativa de teores nutricionais foliares

A fim de avaliar o desempenho dos modelos, foram calculados os indicadores estatísticos: coeficiente de determinação ( $R^2$ ) (Equação 1); coeficiente de determinação ajustado ( $R^2_{ajust}$ ) (Equação 2), Raiz do Erro Quadrático Médio (RMSE) (Equação 3) e a Razão da Performance do Desvio (RPD) (Equação 4).

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{Y}_i - Y_i)^2}{N}} \quad (2)$$

$$RDP = \frac{\sigma_{Y_o}}{RMSE} \quad (3)$$

em que:

$\hat{Y}_i$  representa os valores calculados pelos modelos na  $i$ -ésima observação;

$Y_i$  são os valores medidos ou observados em laboratório na  $i$ -ésima observação;

$\bar{Y}$  representa a média dos valores observados;

$N$  é o número de observações;

$k$  é o total de variáveis independentes;

$\sigma$  é o desvio padrão para os valores medidos ou observados.

## 3.4 Resultados e Discussão

### 3.4.1 Teor dos nutrientes foliares

Verificou-se que há diferença estatística quando se analisa a variação dos nutrientes entre as fases fenológicas (Tabela 3). Tomando como base a Tabela 3, observa-se que pelo menos dois nutrientes apresentam desempenho significativamente ( $P < 0.05$ ) diferentes de acordo com as fases fenológicas estudada.

Tabela 3 - Análise de variância – ANOVA

	Soma dos quadrados	Grau de Liberdade	Quadrado médio	Teste F	Valor P
<b>P</b>					
<b>Entre grupos</b>	46,425	2	23,213	89,998	0,000
<b>Nos grupos</b>	18,313	71	0,258		
<b>Total</b>	64,738	73			
<b>K</b>					
<b>Entre grupos</b>	3449,707	2	1724,853	129,082	0,000
<b>Nos grupos</b>	948,733	71	13,362		
<b>Total</b>	4398,440	73			
<b>Ca</b>					
<b>Entre grupos</b>	3647,912	2	1823,956	79,339	0,000
<b>Nos grupos</b>	1632,242	71	22,989		
<b>Total</b>	5280,154	73			
<b>Zn</b>					
<b>Entre grupos</b>	77754,282	2	38877,141	47,858	0,000
<b>Nos grupos</b>	57676,758	71	812,349		
<b>Total</b>	135431,041	73			

Fonte: Elaboração da autora.

Os teores de P, K e Ca (Figura 13) estão inseridos nas faixas consideradas adequadas para o pleno desenvolvimento da cultura (Yarce; Rojas, 2012), sendo valores entre 2,5 a 5,0 g kg<sup>-1</sup> para o fósforo; 8,0 a 50,0 g kg<sup>-1</sup> para o potássio e 8,0 a 30,0 g kg<sup>-1</sup> para o cálcio. Essas faixas são indicativas do estado nutricional da planta, onde valores inferiores ao da faixa representam carência nutricional e conseqüente necessidade de correção, enquanto valores superiores indicam toxicidade (MARTINEZ *et al.*, 2003; YARCE; ROJAS, 2012).

Durante o ciclo do *Vigna Unguiculata* (L.) Walp verificou-se a diminuição nos teores de P, K e Zn e a manutenção ou o aumento nos teores de Ca (Figura 13) nas folhas. Isso pode ser explicado, em parte, pela translocação diferencial entre esses nutrientes, sendo o cálcio um elemento pouco translocado no floema (MARSCHNER, 2012), de modo que se verifica tendência de acúmulo nas folhas durante o desenvolvimento da planta. A diminuição dos demais nutrientes avaliados pode ser conseqüência da translocação das folhas para as partes reprodutivas.

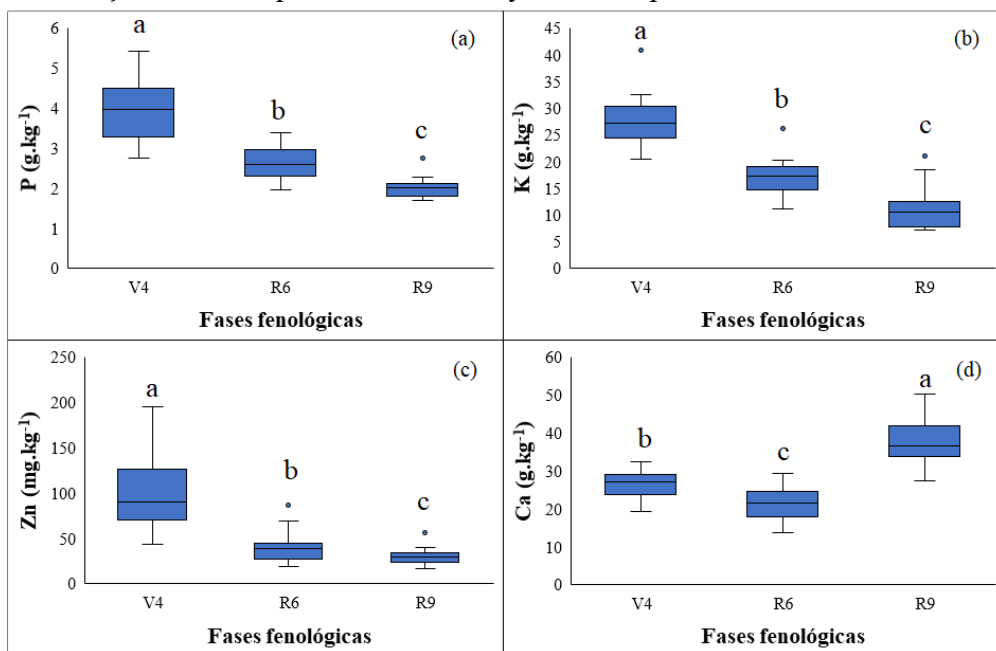
O P é um nutriente necessário em todas as fases fenológicas da cultura, principalmente nos estádios iniciais, uma vez que a sua limitação pode restringir o desenvolvimento da planta (BÜLL *et al.*, 2008). Esse nutriente atua no aumento das células (MARSCHNER, 2012), e sua maior absorção ocorre na fase de pré floração, entretanto,

segundo (ZUCARELI, 2005), conforme ocorre o desenvolvimento da cultura, seus teores são reduzidos nas folhas.

Existe uma relação antagonista entre K e Ca, no qual um elemento afeta a absorção do outro (CAVALCANTE *et al.*, 2018). O maior requerimento do Ca no estágio fenológico R9 (Figura 13c) está relacionado com a fixação das vagens. Portanto, devido a relação de antagonismo entre esses dois nutrientes, os teores de K são reduzidos (Figura 13b).

O zinco (Zn) é um micronutriente essencial na nutrição de plantas (MALAVOLTA, 2006). Ele exerce influência sobre o crescimento vegetal e das raízes, participa de muitas vias metabólicas e permite a ampliação da área fotossintética (PEDROSA, 2017), desse modo, é requerido principalmente nas fases iniciais das plantas, sendo reduzido conforme o ciclo da cultura avança (Figura 13d).

Figura 13 - Teores dos nutrientes: fósforo (a), potássio (b), cálcio (c) e zinco (d) nas folhas do *Vigna Unguiculata* (L.) Walp. Letras distintas sugerem diferença estatística pelo teste de Tukey, a 5% de probabilidade



Fonte: Elaboração da autora.

### 3.4.2 Análise dos dados hiperespectrais

As propriedades espectrais de uma folha são função de sua composição química, morfologia e estrutura interna (PONZONI; SHIMBUKURO; KUPLICH, 2012). As funções dos nutrientes na fisiologia da planta influenciam a reflectância espectral das folhas. Todos os estágios fenológicos da cultura foram registrados por curvas de reflectância espectral típica da

vegetação verde sadia (MOREIRA, 2011) e apresentaram valores de reflectância com leves alterações entre si (Figura 14). A diminuição dos teores de nutrientes na planta promove uma maior reflectância nas folhas por afetar de forma significativa as propriedades ópticas da folha (NANNI, 2015). Uma pequena diferença entre os valores de nutrientes na folha, que são menores na fase R9, revelam leves mudanças na reflectância.

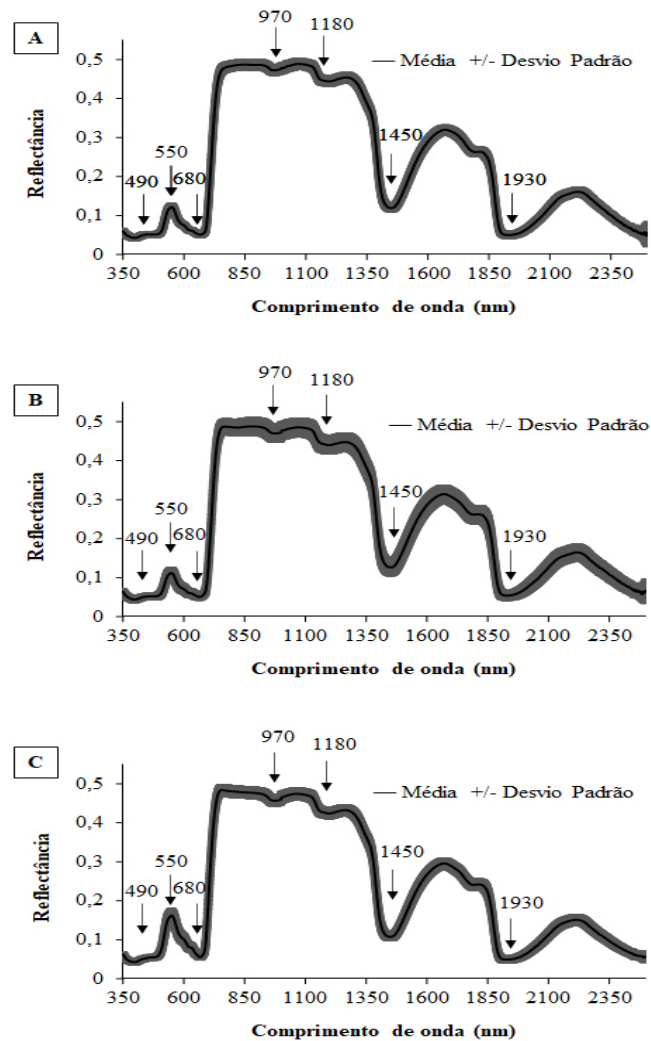
Na região do visível, a vegetação apresentou, nos três estágios fenológicos estudados, fatores de reflectância mais baixos quando comparados com a região do infravermelho, sendo observados vales de absorção localizados no azul (490 nm) e vermelho (680 nm). O estudo elaborado por Liu *et al.* (2017) está em concordância com esse resultado, afirmando que a forte absorção da luz por pigmentos domina as propriedades da folha verde no espectro visível. Os pigmentos que interferem fortemente na reflectância dessa região são clorofila, carotenos e xantofilas. Na região do visível há interação entre a energia radiante e a estrutura foliar por meio da absorção e espalhamento, em que é seletivamente absorvida pela clorofila e convertida em calor ou fluorescência, sendo fotoquimicamente estocada na forma de componentes orgânicos (DE CARVALHO *et al.*, 2005).

Na fase R9 ocorre um aumento da reflectância na região do visível (Figura 14c) de aproximadamente 20% quando comparado com as demais fases. Isso ocorre devido à senescência das plantas, que se encontram com teores de clorofila reduzido e diminuem a absorção da radiação por esses pigmentos (TIERNY; VANDEBORRE; DAOUDI, 2008). Chicati (2015), obteve resultados semelhantes, em que o pico de reflectância do feijoeiro comum nas proximidades do comprimento de onda de 550 nm foi elevado conforme a cultura chegava ao fim do ciclo.

No infravermelho próximo (700 e 1000 nm), ocorre pequena absorção da radiação, por outro lado, há um grande espalhamento interno de radiação na folha, em que as estruturas do mesófilo têm grande influência na reflectância (JENSEN, 2011). A disponibilidade de água é um fator que também pode interferir na reflectância de uma folha nessa região, pois pode causar alterações na relação água-ar no mesófilo. Picos de reflectância podem ser vistos na região do infravermelho próximo durante cada estágio fenológico do estudo, causados por baixa absorção de REM (970 e 1180 nm) e espalhamento dentro das estruturas foliares (PAPA *et al.*, 2010). Nessa região, a reflectância média foi de 0,5 (Figura 14). No NIR, constatou-se que as plantas não apresentaram grandes variações na reflectância nos diferentes estágios fenológicos, tendo em vista que durante todo o ciclo a cultura não apresentou estresse hídrico ou nutricional que possam ter causado alterações na estrutura celular da folha do feijoeiro.

No SWIR (1000 a 2400 nm), a refletância da cultura é mais influenciada pela água (MOREIRA, TEIXEIRA; GALVÃO, 2014). A redução na quantidade de água implica na degradação de proteínas e pigmentos fotossintetizantes, o que restringe a absorção da radiação eletromagnética e, conseqüentemente, resulta no aumento da reflectância nessa região. Nos comprimentos de onda de 1450 e 1930 nm, podem ser vistos vales bem marcantes que indicam a presença de água na folha (Figura 14). Pode-se ver que os vales em 1450 e 1930 nm são bastante acentuados, o que indica a presença de água. Durante o desenvolvimento da cultura, praticamente não houve alterações nesta região, pois a irrigação continuou ao longo do ciclo e foi suspensa apenas na fase R9, contudo, não são observadas alterações na reflectância nesse estágio fenológico, o que indica que a leitura foi feita antes da planta demonstrar sinais de déficit hídrico.

**Figura 14** - Espectros médios de reflectância e os respectivos desvios padrões de cada estágio fenológico (A) V4 (B) R6 (C) R9



Fonte: Elaboração da autora.

O P participa dos processos de produção de energia para a fotossíntese (SILVA, 2013). A redução dos teores desse nutriente acarreta a diminuição da eficiência da clorofila, ocasionando um aumento da reflectância na região do visível, como ocorre em uma planta que está em processo de senescência.

O K, assim como o P, está incluso no processo de produção de energia, atuando na ativação da enzima ATPase, proporcionando a formação de ATP (TAIZ; ZEIGER, 2004). Stein; Thomas; Lorentz; Strahm, (2014) verificaram que nas regiões do visível e borda vermelha estão localizados comprimentos de onda importantes para a predição desse nutriente nas folhas.



O Ca tem participação na transferência de elétrons do fotossistema II ao fotossistema I, ou seja, tem contribuição no aumento de clorofila na folha e, conseqüentemente, aumenta a absorção na região do visível (GONG, 2011).

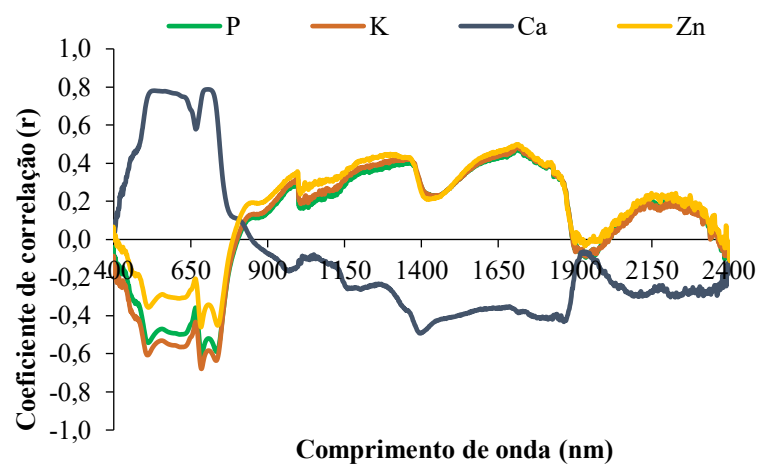
O Zn atua na atividade da enzima superóxido dismutase que aumenta a atividade fotossintética da planta (BARBOSA *et al.*, 2014). Esse nutriente está correlacionado com os comprimentos de onda entre 680 e 720 nm, localizados na região da borda vermelha, conforme afirmam SHAO; HE (2014).

### 3.4.3 Estimativa de teores nutricionais foliares

#### 3.4.3.1 Correlação simples

Os valores de coeficiente de correlação de Pearson (Figura 15) entre os teores de P, K, Ca e Zn nas folhas e os valores de reflectância (Figura 14) apresentam os comprimentos de onda que têm maior correlação e que posteriormente foram selecionados para criação dos modelos empíricos de estimativa do teor de nutrientes nas folhas do *Vigna Unguiculata* (L.) Walp.

Figura 15 - Correlograma entre a reflectância e os teores de P, K, Ca e Zn nas folhas do *Vigna Unguiculata* (L.) Walp



Fonte: Elaboração da autora.

Verifica-se que os valores de coeficientes de correlação para o Zn não foram satisfatórios para nenhum comprimento de onda ao longo do espectro. Desse modo, não foi possível a criação de um modelo empírico para a estimativa desse nutriente, a partir de uma única banda.

Analisando-se a Figura 15, é possível verificar os comprimentos de onda em que houve maior correlação entre os teores foliares dos elementos e os fatores de reflectância. Na Tabela 4, estão exibidos os comprimentos de onda selecionados, bem como as equações de calibração e validação e valores de  $R^2$ .

Como tratado anteriormente, a região do visível é fortemente influenciada pelos pigmentos presentes na folha, principalmente a clorofila. Nas proximidades do comprimento de 700 nm existe um ponto conhecido como red edge (borda vermelha) que é o limite do processo de absorção da clorofila e onde inicia o espalhamento nas estruturas internas das folhas (CURRAN *et al.*, 1991). Chu *et al.* (2014) evidenciam que a faixa compreendida entre os comprimentos de onda de 650 a 750 nm (borda vermelha) é fundamental para o entendimento da reflectância conforme as alterações bioquímicas da planta. Para a criação dos modelos foi selecionada pelo menos um comprimento de onda nessas duas regiões (visível e borda vermelha), pois se relacionam de alguma maneira com a clorofila.

Tabela 4 - Modelos para estimativas dos teores de nutriente na folha utilizando uma única banda espectral

Nutriente	Comprimento de onda (nm)	Equações	$R^2$
P	684	$y = -89,297x + 8,158$	0,62
K	684	$y = -915,51x + 74,546$	0,63
Ca	720	$y = 208,12x - 41,659$	0,67

Fonte: Elaboração da autora.

Pesquisadores estudando a estimativa de teores de nutrientes nas folhas utilizando modelos de uma única banda obtiveram bons resultados quando selecionaram comprimentos de onda localizados na região do visível (TIAN *et al.*, 2011; ABDEL-RAHMAN; AHMED; BERG, 2010). Por outro lado, Carvalho (2005) encontrou altas correlações negativas ( $R^2 = -0,7$ ) entre os teores de fósforo e a reflectância espectral, principalmente entre os comprimentos de onda de 1400 a 1900 nm, o que contradiz o resultado obtido neste estudo.

#### 3.4.3.2 Correlação 2D

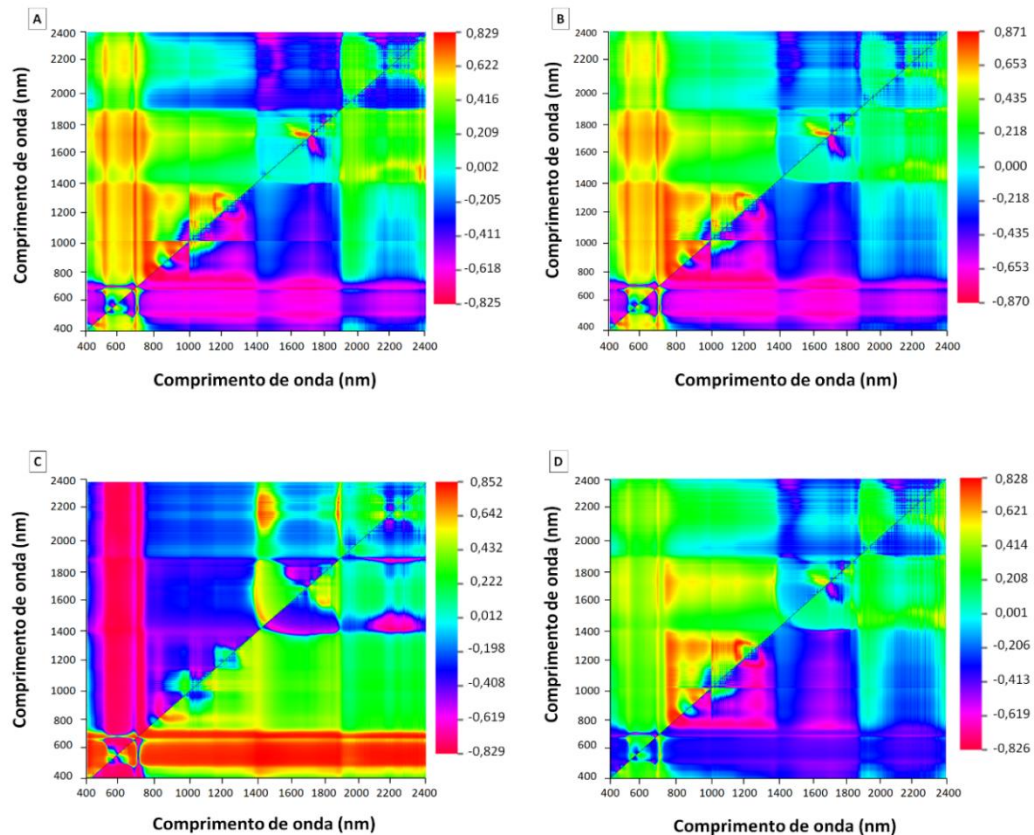
Tomando-se por base os maiores coeficientes de correlação 2D (Figura 16) foram selecionados dois comprimentos de onda para desenvolver os modelos de estimativa. É possível verificar os comprimentos de onda utilizados para realização da razão de bandas, bem como as equações de calibração e valores de  $R^2$  na Tabela 5.

Verifica-se que a maioria dos modelos utilizados para predição de elementos com uma banda e razão de duas bandas selecionou comprimentos de onda localizados nas faixas espectrais da borda vermelha e infravermelho próximo. Segundo Zucareli (2005), a seleção de comprimentos de onda nessas duas regiões melhora a precisão da estimativa. A seleção desses comprimentos de onda em torno de 680 nm para fósforo e potássio está relacionada com a participação desses nutrientes nos processos de formação de energia para a fotossíntese. Conforme Mee; Balasundram; Mohd Hanif (2017), em torno do comprimento de onda de 680 nm ocorre alta absorção do pigmento clorofila.

Uma outra região com forte absorção de clorofila, está nas proximidades do comprimento de onda de 740 nm (MEE; BALASUNDRAM; MOHD HANIF, 2017). A seleção desse comprimento de onda para o cálcio está relacionada com a contribuição desse nutriente para o aumento de clorofila na folha.

Os comprimentos de onda selecionados para obtenção dos modelos de estimativa dos teores de P, K e Ca estão localizados na região do infravermelho próximo (NIR). Observa-se ainda que embora esteja mais adequado na detecção de compostos orgânicos, o NIR também é capaz de extrair informações sobre a fração inorgânica de amostras de folhas como Ca, K e outros micronutrientes (PRANANTO; MINASNY; WEAVER, 2020).

Figura 16 - Correlograma 2D entre a reflectância espectral e os teores foliares de fósforo (A), de potássio (B), de cálcio (C) e de zinco (D)



Fonte: Elaboração da autora.

Tabela 5 - Modelos para estimativas dos teores de nutrientes nas folhas utilizando razão de bandas espectrais

Nutriente	Razão de bandas (nm)	Equações	R <sup>2</sup>
P	826/750	$P = 34,63x - 32,35$	0,66
K	744/816	$K = -256,09x + 265,54$	0,70
Ca	720/844	$Ca = 89,675x - 33,934$	0,63
Zn	1252/1148	$Zn = 6818,2x - 6643$	0,66

Fonte: Elaboração da autora.

### 3.4.3.3 Regressão por Mínimos Quadrados Parciais (Partial Least Square Regression – PLSR)

Utilizando os dados de reflectância do feijoeiro, foram testados modelos que visam estimar os teores de nutrientes nas folhas nas fases V4, R6 e R9 separadamente, bem como um único modelo testado a partir de dados das três fases em conjunto. As bandas selecionadas para geração dos modelos para estimativa dos teores de nutrientes nas folhas do *Vigna Unguiculata* (L.) Walp estão dispostas na Tabela 6 e as equações de calibração na Tabela 7.

Os modelos testados para as fases fenológicas individuais (Tabela 6) não selecionaram bandas úteis para a predição dos teores de todos os nutrientes avaliados no estudo. Contudo, quando se utilizou os dados das três fases em conjunto foi possível selecionar uma quantidade de bandas considerável para a elaboração do modelo para cada nutriente.

Tabela 6 - Bandas espectrais selecionadas para a calibração dos modelos por PLSR

Estádio Fenológico	Nutriente	Bandas	n	R <sup>2</sup> -ajust
V4	Ca	413, 625, 1301, 1405, 1683, 1714, 1726, 1727, 1883, 1904	16	0,98
	Zn	634, 1364, 1981, 1994	16	0,73
R6	Zn	923, 925, 944, 951, 1864, 1890	17	0,90
R9	K	630, 1405	17	0,43
	Ca	613, 631, 1350	17	0,59
Todos (V4, R6, R9)	P	504, 651, 685, 1649, 1715	50	0,77
	K	504, 651, 685, 1715, 1735	50	0,84
	Ca	705, 1890, 2377	50	0,73
	Zn	751, 1715, 2434	50	0,57

n: Número de dados utilizados para calibração dos modelos.

Fonte: Elaboração da autora.

Tabela 7 - Equações utilizadas na calibração dos modelos por PLSR

Estádio Fenológico	Nutriente	Equação
V4	Ca	Ca = 41,380740 - 10,38684λ1683nm - 3,63733λ1405nm + 1,344476λ413nm + 4,155283 λ1883nm - 9,864286 λ1726nm - 7,38664 λ1714nm - 7.014894 λ1031nm + 5,896256 λ1904nm - 10,20575 λ1727nm + 2,19506 λ625nm
	Zn	Zn = -607,617 - 10181,2 λ634nm + 3809,383 λ1364nm + 2204,323 λ1994nm - 3493,65 λ1981nm
R6	Zn	Zn = -119,164400 + 70,25752 λ944nm + 71,05573 λ951nm + 71,56557 λ1890nm + 88,90969 λ1864nm + 68,28416 λ925nm + 67,71706 λ923nm
R9	K	K = -1,65418 - 80,7834 λ630nm + 116,8171 λ1405nm

<b>Todas as fases juntas (V4, R6, R9)</b>	Ca	$Ca = 106,346000 - 252,393 \lambda_{1350nm} + 3637,852 \lambda_{631nm} - 3048,85 \lambda_{613nm}$
	P	$P = 6.162487 - 124.4690 \lambda_{685nm} + 181.6616 \lambda_{651nm} - 87.4141 \lambda_{504nm} + 299.9536 \lambda_{1715nm} - 293.5019 \lambda_{1649nm}$
	K	$K = 8,754299 - 427,4241 \lambda_{685nm} + 2012,5704 \lambda_{651nm} - 1940,1794 \lambda_{504nm} + 2668,3838 \lambda_{1715nm} - 2624,0833 \lambda_{1735nm}$
	Ca	$Ca = 16,96427 + 193,3209 \lambda_{705nm} - 670,447 \lambda_{2377nm} + 458,5386 \lambda_{1890nm}$
	Zn	$Zn = -92,4856 + 1803,0171 \lambda_{1715nm} - 2073,2190 \lambda_{2434nm} - 519,7374 \lambda_{751nm}$

PLSR: Partial Least-Squares Regression (Regressão por Mínimos Quadrados Parciais); V4: Fase Vegetativa - 4; R6: Fase Reprodutiva - 6; R9: Fase Reprodutiva - 9;  $\lambda$ : Fator de reflectância

Fonte: Elaboração da autora.

Analisando-se a Tabela 6, verifica-se que nos modelos PLSR obtidos para a predição de P foram selecionados comprimentos de onda localizados tanto na região do visível quanto nos intervalos do NIR que sofrem influência desse nutriente. O P é um macronutriente importante por estar envolvido nos processos metabólicos das plantas (WALSHE *et al.*, 2020), fazendo parte de moléculas de proteínas e lipídios. As regiões do espectro mais sensíveis a esses compostos estão localizadas entre os comprimentos de onda de 350 a 1500 nm e de 2350 a 2500 nm (PRANANTO; MINASNY; WEAVER, 2020). Além disso, o P também participa dos processos de produção de energia para a fotossíntese (SILVA, 2013), sendo fortemente influenciado pelos comprimentos de onda na região do visível.

No presente estudo, apenas um comprimento de onda foi selecionado no intervalo citado por Prananto; Minasny; Weaver (2020) e os demais comprimentos de onda selecionados pelos modelos PLSR estão, em sua maioria, na região do visível (Tabela 6).

O K é um macronutriente que se relaciona fortemente com carboidratos e ácidos orgânicos, podendo ser medido indiretamente por meio desses compostos via região do infravermelho próximo (CLARK; MAYLAND; LAMB, 1987). Em discordância dos resultados obtidos neste estudo, Prananto; Minasny; Weaver (2020) afirmam que as regiões mais fortemente afetadas por carboidratos no espectro eletromagnético estão, aproximadamente, entre os comprimentos de onda de 1000 a 1500 nm e 1950 e 2300 nm.

Os modelos PLSR selecionaram poucos comprimentos de onda no infravermelho próximo, sendo na fase V4, onde houve um maior número de comprimentos de onda

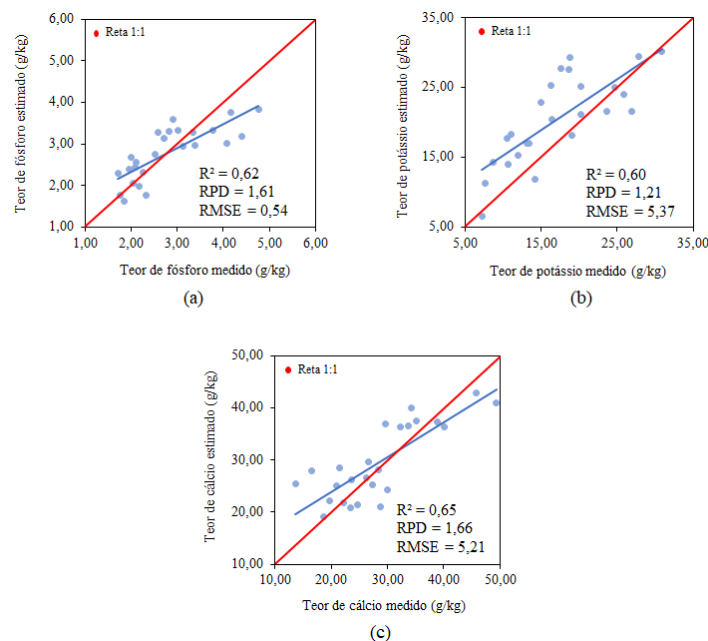
selecionados para obtenção do modelo de estimativa do Ca. O Ca é um macronutriente que está fortemente relacionado com a estrutura da folha, no espectro eletromagnético, essa região está localizada no infravermelho próximo, entre 700 e 1500 nm. Diferente dos resultados aqui alcançados, Vazquez; Garcia-Criado; Perez-Corona (1995) afirmam que composto de Ca se liga a células vegetais e sensíveis na região NIR.

Analisando-se a Tabela 6 é possível verificar que poucos dos modelos obtidos aqui selecionaram comprimentos de onda dentro do intervalo de 680 a 720 nm, o que pode contribuir para a obtenção de modelos com baixa eficácia de estimativa do teor de zinco. O Zn é um micronutriente para o ciclo de vida dos vegetais e exerce diversas atividades metabólicas na planta. Zhou *et al.* (2016) afirmam em seus estudos que o Zn está correlacionado aos comprimentos de onda da borda vermelha (680 a 720 nm), contudo, esses resultados são divergentes dos encontrados no presente estudo.

#### 3.4.3.3.1 Validação dos modelos

Os gráficos referentes à validação dos modelos utilizando apenas uma única banda estão dispostos na Figura 17.

Figura 17 - Relações entre os teores medidos e estimados de P (a), K (b) e Ca (c) usando o modelo de banda única



Fonte: Elaboração da autora.

Os parâmetros usados para analisar o desempenho do modelo para a variável fósforo usando apenas uma banda apresentaram  $R^2$  de 0,62, RPD de 1,61 e RMSE de 0,54 g.kg-

<sup>1</sup>, classificando-os como moderado para  $R^2$  e RMSE e satisfatório para RPD (Figura 17a). A estimativa de fósforo tende a subestimar os valores de abaixo de 2 g.kg<sup>-1</sup> e subestimar os valores acima de 2 g.kg<sup>-1</sup>

Os parâmetros usados para analisar o desempenho do modelo para a variável potássio usando apenas uma banda apresentaram  $R^2$  de 0,60, RPD de 1,21 e RMSE de 5,37 g.kg<sup>-1</sup>, classificando-os como moderado para  $R^2$  e insuficiente para RPD e RMSE (Figura 17b). O modelo tende a subestimar os valores de potássio abaixo de 15 g.kg<sup>-1</sup> e subestimar os valores acima de 15 g.kg<sup>-1</sup>

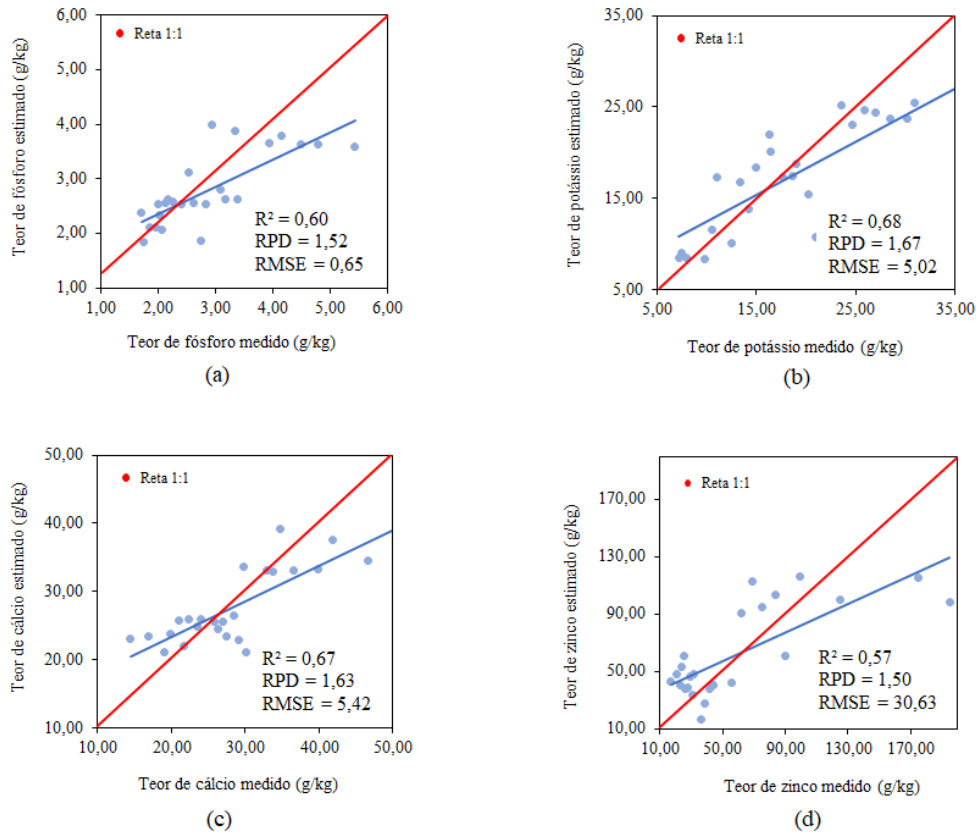
Os parâmetros usados para analisar o desempenho do modelo para a variável cálcio usando apenas uma banda apresentaram  $R^2$  de 0,65, RPD de 1,66 e RMSE de 5,21 g.kg<sup>-1</sup>, classificando-os como moderado para  $R^2$ , satisfatório para RPD e insuficiente para RMSE (Figura 17c). O modelo para a estimativa de cálcio tende a subestimar todos os valores preditos. Apesar de o modelo subestimar as concentrações, apresenta a mesma tendência, ou seja, de subestimar os valores menores e maiores de cálcio.

Segundo os critérios de Ge *et al.*, (2019), os modelos utilizados para predição de fósforo e cálcio encontram-se com alta acurácia, porém, o RMSE do modelo para estimar cálcio é insuficiente, elegendo o modelo de estimativa de fósforo como o de maior confiança dentre os modelos de uma banda.

Os gráficos referentes à validação dos modelos utilizando razão de bandas estão dispostos na Figura 18.



Figura 18 - Relações entre os teores medidos e estimados de P (a), K (b), Ca (c) e Zn (d) usando o modelo de razão de bandas



Fonte: Elaboração da autora.


O desempenho do modelo usando razão de bandas para a estimativa de fósforo apresentou  $R^2$  de 0,60, RPD de 1,52 e RMSE de 0,65 g.kg<sup>-1</sup>, classificados, como moderado para o  $R^2$  e satisfatório para RPD e RMSE (Figura 18a). O desempenho do modelo usando razão de bandas para a estimativa de potássio apresentou  $R^2$  de 0,68, RPD de 1,67 e RMSE de 5,02 g.kg<sup>-1</sup>, classificados, como moderado para o  $R^2$  e satisfatório para RPD e RMSE (Figura 18b). O desempenho do modelo usando razão de bandas para a estimativa de cálcio apresentou  $R^2$  de 0,67, RPD de 1,63 e RMSE de 5,42 g.kg<sup>-1</sup>, classificados, como moderado para o  $R^2$  e satisfatório para RPD e RMSE (Figura 18c). O desempenho do modelo usando razão de bandas para a estimativa de zinco apresentou  $R^2$  de 0,57, RPD de 1,50 e RMSE de 30,63 g.kg<sup>-1</sup>, classificados, como moderado para o  $R^2$  e satisfatório para RPD e RMSE (Figura 18d).

O uso da razão de bandas permitiu a obtenção de modelos preditivos para cada um dos nutrientes em estudo, contudo, o modelo utilizado para estimar fósforo foi o que apresentou melhor desempenho. Os modelos de estimativa dos nutrientes tendem, a superestimar os menores valores e subestimar os maiores valores. Os valores de RMSE para previsão de zinco são excessivamente altos em comparação com os outros nutrientes. Liao *et al.* (2012)

confirmam que as previsões de micronutrientes geralmente não são tão boas quanto as relatadas para macronutrientes.

Os gráficos referentes à validação dos modelos para estimar os teores de P, K, Ca e Zn nas folhas do *Vigna unguiculata* (L.) Walp em suas diferentes fases fenológicas, utilizando PLSR são apresentados nas Figuras 19, 20, 21 e com dados de todas as fases, na Figura 22.

Figura 19 - Relação entre os teores medidos e estimados de cálcio (a) e zinco (b) na fase fenológica V4

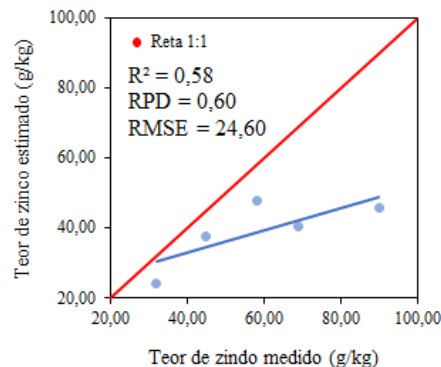


Fonte: Elaboração da autora.

Os parâmetros usados para analisar o desempenho do modelo para a variável cálcio usando PLSR na fase fenológica V4 apresentaram valores de  $R^2$  de 0,78, RPD de 1,10 e RMSE de 3,10 g.kg<sup>-1</sup>, classificando-os como moderado para  $R^2$  e insuficiente para RPD e RMSE (Figura 19a). O modelo tende a superestimar todos os valores desse nutriente.

Os parâmetros usados para analisar o desempenho do modelo para a variável zinco usando PLSR na fase fenológica V4 apresentaram valores de  $R^2$  de 0,97, RPD de 1,40 e RMSE de 31,60 g.kg<sup>-1</sup>, classificando-os como forte para  $R^2$ , satisfatório para RPD e insuficiente para RMSE (Figura 19b). A estimativa de zinco tende a superestimar todos os valores de zinco.

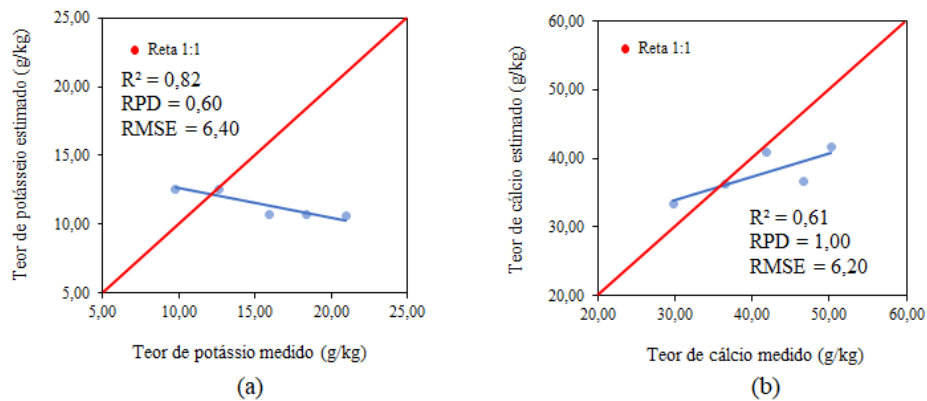
Figura 20 - Relação entre os teores medidos e estimados de zinco na fase fenológica R6



Fonte: Elaboração da autora.

Os parâmetros usados para analisar o desempenho do modelo para a variável zinco usando PLSR na fase fenológica R6 apresentaram valores de  $R^2$  de 0,58, RPD de 0,60 e RMSE de 24,60 g.kg<sup>-1</sup>, classificando-os como moderado para  $R^2$  e insuficiente para RPD e RMSE (Figura 20). O modelo para a estimativa de zinco tende a subestimar todos os valores de zinco.

Figura 21 - Relação entre os teores medidos e estimados de K (a) e Ca (b) na fase fenológica R9

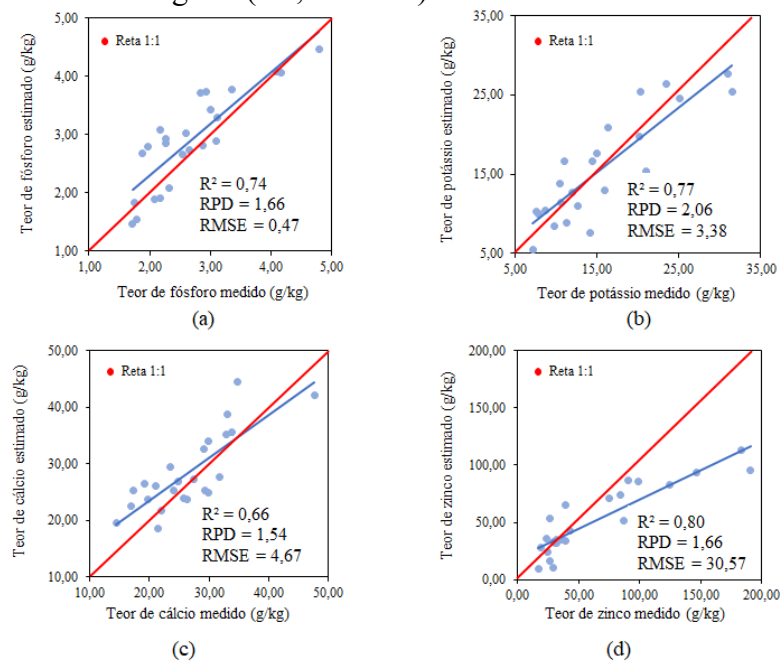


Fonte: Elaboração da autora.

Os parâmetros usados para analisar o desempenho do modelo para a variável potássio usando PLSR na fase fenológica R9 apresentaram valores de  $R^2$  de 0,82, RPD de 0,60 e RMSE de 6,40 g.kg<sup>-1</sup>, classificando-os como forte para  $R^2$  e insuficiente para RPD e RMSE (Figura 21a). O modelo de estimativa de potássio tende a superestimar valores até 10,0 g.kg<sup>-1</sup> e superestimar os valores acima de 10,0 g.kg<sup>-1</sup>.

Os parâmetros usados para analisar o desempenho do modelo para a variável cálcio usando PLSR na fase fenológica R9 apresentaram valores de  $R^2$  de 0,61, RPD de 1,00 e RMSE de 6,20 g.kg<sup>-1</sup>, classificando-os como moderado para  $R^2$  e insuficiente para RPD e RMSE (Figura 21b). A estimativa de cálcio tende a superestimar valores até 40,0 g.kg<sup>-1</sup> e superestimar os valores acima de 40,0 g.kg<sup>-1</sup>.

Figura 22 - Relações entre os teores medidos e estimados de P (a), K (b), Ca (c) e Zn (d) utilizando dados das três fases fenológicas (V4, R6 e R9)



Fonte: Elaboração da autora.

O desempenho do modelo usando PLSR com dados de todas as fases fenológicas utilizado para a estimativa de fósforo apresentou  $R^2$  de 0,74, RPD de 1,66 e RMSE de 0,47  $\text{g.kg}^{-1}$ , classificados, como moderado para o  $R^2$  e satisfatório para RPD e RMSE (Figura 22a). O desempenho do modelo usando PLSR com dados de todas as fases fenológicas utilizado para a estimativa de potássio apresentou  $R^2$  de 0,77, RPD de 2,06 e RMSE de 3,38  $\text{g.kg}^{-1}$ , classificados, como moderado para o  $R^2$  e insuficiente para RPD e RMSE (Figura 22b). O desempenho do modelo usando PLSR com dados de todas as fases fenológicas utilizado para a estimativa de cálcio apresentou  $R^2$  de 0,66, RPD de 1,54 e RMSE de 4,67  $\text{g.kg}^{-1}$ , classificados, como moderado para o  $R^2$ , satisfatório para RPD e insuficiente para RMSE (Figura 22c). O desempenho do modelo usando PLSR com dados de todas as fases fenológicas utilizado para a estimativa de zinco apresentou  $R^2$  de 0,80, RPD de 1,66 e RMSE de 30,57  $\text{g.kg}^{-1}$ , classificados, como moderado para o  $R^2$ , satisfatório para RPD e insuficiente para RMSE (Figura 22d).

Com exceção do modelo para estimar zinco, os demais apresentaram tendência semelhante à reta 1:1. O melhor modelo selecionado usando dados de todas as fases fenológicas em conjunto, foi aquele usando PLSR para estimar os teores de fósforo, com um  $R^2$  de 0,74, RPD de 1,66 e RMSE de 0,47.

Os modelos PLSR por fase fenológica produziram resultados divergentes, variando conforme o estágio fenológico da cultura. O modelo PLSR referente ao uso de dados de todos

os três estádios fenológicos apresentou melhor desempenho do que aqueles utilizando dados dos estádios separados (V4, R6 e R9). Com exceção do modelo para estimar zinco utilizando dados de todas as fases fenológicas, os demais apresentaram valores de  $R^2$  que possuem potencial predição dos teores de nutrientes em estudo (acima de 0,70).

Em estudo com amostras de alfafa compactadas, González-Martín; Hernández-Hierro; González-Cabrera (2007) chegaram a valores de RPD de 3,6; 3,4; 3,1 e 2,9 para obtenção do teor de P, K, Ca e Zn, respectivamente, o que diverge dos resultados obtidos neste estudo, onde foram obtidos valores de RPD de 1,66 para P, valores entre 0,6 e 2,06 para K, valores entre 1,00 e 1,54 para Ca e valores entre 0,360 e 1,66 para Zn. Santoso *et al.*, (2019) utilizando PLSR para a previsão do teor de nutrientes da folha de dendê, medindo a reflectância com um espectrorradiômetro, obtiveram valores de  $R^2$  entre 0,49 e 0,90 para predição do fósforo e valores variando entre 0,61 e 0,85; 0,69 e 0,86 para estimar potássio e cálcio, respectivamente, o que coincide com os resultados obtidos aqui (P: 0,77, K: 0,84, Ca: 0,73). Pesticco *et al.*, (2005) ao utilizar PLSR para estimar nutrientes em espécie de planta lenhosa obtiveram valores de RPD de 2,3 e 3,8 para predição de P e Ca, respectivamente, se opondo ao produto deste estudo, que resultou em valores inferiores de RPD (1,66 para P e valores entre 1,10 e 1,54 para Ca).

Observando-se a distribuição de zinco nas folhas em cada fase fenológica (Figura 18), verifica-se que na fase vegetativa (V4) o nutriente estava presente em maiores teores e apresentava uma maior variabilidade e, à medida que a planta se desenvolvia, os teores e zinco na folha foram reduzidos, assim como a variabilidade dentro da fase fenológica. Ao comparar com os gráficos da validação por fase fenológica, verifica-se um padrão semelhante, em que na fase V4 (Figura 19) o modelo apresenta  $R^2$  de 0,97 com linha de tendência acima e paralela à reta 1:1; na fase R6 (Figura 20) o modelo comporta-se de maneira inferior ao modelo da V4, com  $R^2$  de 0,58 e linha de tendência abaixo e quase perpendicular à reta 1:1 e, na fase R9 (Figura 21), não são selecionadas bandas úteis para a obtenção de um modelo de estimativa devido aos baixos teores e baixa amplitude dos dados.

Verifica-se que os valores de RMSE para a predição de zinco são excessivamente elevados em relação aos demais. Liao *et al.* (2012) confirmam que de maneira geral, as previsões de micronutrientes não são tão boas quanto as relatadas sobre macronutrientes. Comino *et al.*, (2018) também verificaram a ineficiência de modelos de regressão por mínimos quadrados parciais utilizados para estimar os teores de zinco, devido ao alto valor de RMSE, semelhante ao obtido no presente estudo. Contudo, pode-se obter melhores correlações quando há um teor mais alto de nutrientes. Ramoelo *et al.*, (2013) obtiveram bons resultados ao analisar nutrientes de plantas usando espectroscopia NIR. O modelo de regressão de mínimos quadrados

parciais é uma forma poderosa de análise multivariada para previsão de nutrientes nas folhas (CAPOLUPO *et al.*, 2015; LI *et al.*, 2016; ABDEL-RAHMAN *et al.*, 2017; GALVEZ-SOLA *et al.*, 2018). Por outro lado, verifica-se que os modelos utilizando de PLSR para estádios fenológicos separados, não são modelos confiáveis para estimar nutrientes nas folhas. Segundo Campelo (2018), a quantidade de dados utilizados para a predição dos modelos exerce influência sobre os resultados, o que explica o melhor desempenho dos modelos testados utilizando os dados das três fases fenológicas em conjunto.

### 3.5 Conclusão

A seleção da banda melhorou o desempenho dos modelos nas três metodologias aplicadas. Os modelos construídos usando PLSR tornaram-se confiáveis após a seleção da banda utilizando dados de todas as fases fenológicas em conjunto, mas ainda necessita de ajustes para realizar a predição de micronutrientes como o zinco.

O uso de dados de refletância obtidos por espectroscopia permite quantificar o teor de nutrientes; entretanto, o grau de precisão dos modelos varia de acordo com o estágio fenológico da cultura e a quantidade de dados utilizados, sendo mais preciso com maior quantidade de informações e com a utilização dos dados em conjunto de todas as fases estudadas. A regressão parcial de mínimos quadrados associada à espectroscopia mostra grande potencial para o desenvolvimento de modelos preditivos de nutrientes em *Vigna Unguiculata* (L.) Walp.

As bandas localizadas nas regiões do visível e infravermelho próximo mostraram-se promissoras na estimativa do teor de nutrientes nas folhas de *Vigna Unguiculata* (L.) Walp. Contudo, a estimativa do teor de zinco nas folhas não gerou resultados satisfatórios e apresentou baixo potencial preditivo.

A técnica de previsão do teor de nutrientes nas folhas proporciona resultados mais rápidos para o monitoramento das necessidades nutricionais da cultura, uma vez que não exigem análises laboratoriais, geração de resíduos e nem necessita da remoção de grande quantidade de material vegetal, desse modo, permite a correção nutricional da cultura de maneira mais ágil, reduzindo as possíveis injúrias que venham aparecer em decorrência do desequilíbrio nutricional.

#### 4 USO DA ESPECTROSCOPIA PARA ESTIMAR AS CONCENTRAÇÕES DE CLOROFILA-A, SÓLIDOS SUSPENSOS TOTAIS E TRANSPARÊNCIA EM RESERVATÓRIOS DO SEMIÁRIDO BRASILEIRO

##### RESUMO

Conforme há o aumento populacional, ocorre a redução da qualidade e, conseqüentemente, da quantidade de água potável disponível para consumo. Em detrimento dessa situação, é de suma importância o monitoramento da qualidade da água, podendo ser realizado com o uso de técnicas de sensoriamento remoto. Tais técnicas permitem a avaliação da qualidade do recurso água por meio de sensores multi e hiperespectrais, permitindo que as informações obtidas funcionem como ferramentas de gestão e tomadas de decisões. Portanto, objetiva-se estimar as concentrações de clorofila-a, sólidos suspensos totais (SST) e transparência da água a partir de dados de sensoriamento remoto. O estudo foi realizado nos Reservatório Caxitoré, Pereira de Miranda e General Sampaio, localizados na Bacia Hidrográfica do rio Curu, Ceará. As campanhas foram realizadas no período entre os anos de 2014 e 2019, em pontos georreferenciados, sendo 3 pontos para o reservatório Caxitoré, 4 para o General Sampaio e 5 para o Pereira de Miranda. Foram analisadas as variáveis limnológicas: clorofila-a, SST e transparência. Os dados radiométricos foram coletados *in situ*, utilizando o espectroradiômetro ASD FieldSpec® 3 Hi-Res, com campo de visada de 25°, e que abrange a faixa espectral de 350 a 2500 nm. Para a estimativa das variáveis foram treinados modelos de correlação simples, correlação 2D e regressão por mínimos quadrados parciais (PLSR), utilizando 70% dos dados para calibração e os 30% restantes utilizados para validação dos modelos. A fim de avaliar o desempenho dos modelos, foram calculados os indicadores estatísticos coeficiente de correlação ( $r$ ); coeficiente de determinação ( $R^2$ ); raiz do erro quadrático médio (RMSE) e razão da performance do desvio (RPD). O modelo de correlação simples não foi utilizado para a estimativa de clorofila-a, por apresentar baixa correlação ( $r = 0,2$ ) e apresentou-se inadequado para a predição de SST e transparência, com  $RPD = 1,03$  e  $0,68$ , respectivamente e moderado coeficiente de determinação ( $R^2 = 0,74$  e  $0,58$ ). Para predição das variáveis usando correlação 2D, os modelos se apresentaram inadequados, para clorofila-a e SST, com  $RPD = 1,55$  e  $0,02$ , respectivamente e  $R^2 = 0,45$  para ambas variáveis, contudo, na estimativa da transparência foi possível obter um resultado classificado como excelente, a partir das métricas  $RPD = 2,04$  e  $R^2 = 0,8$ . O modelo usando o método PLSR apresentou os resultados mais satisfatórios para as

variáveis clorofila-a, SST e transparência, com RPD = 2,95, 2,64 e 2,17 e  $R^2 = 0,84, 0,82$  e  $0,89$ , respectivamente.

**Palavras-chave:** qualidade da água; sensores hiperespectrais; modelo preditivo

### ABSTRACT

As population growth decreases, there is a reduction in quality and, consequently, in the amount of water available for consumption. In this situation, it is extremely important to monitor the water quality, which can be carried out with the technical use of sensing. Such resources allow an assessment of water quality through sensors, functioning as information and decision management functionalities. Therefore, the objective is to estimate chlorophyll-a solids, total suspended transparents (SST) and water transparency from remote sensing data. The study will be carried out in the Caxitoré, Pereira de Miranda and General Sampaio Reservoirs, located in the Curu Hydrographic Basin, Ceará. The campaigns were carried out in the period between 2014 and 2019, at georeferenced points, with 3 points for the Caxitoré reservoir, 4 for General Sampaio and 5 for Pereira de Miranda. The limnological variables were analyzed: chlorophyll-a, TSS and transparency. Radiometric data were collected in situ, using an ASD FieldSpec® 3 Hi-Res spectroradiometer, with a 25° field of view, covering the spectral range from 350 to 2500 nm. For the estimation of variables, simple correlation, 2D correlation and partial least squares regression (PLSR) models were trained, using 70% of the data for calibration and the remaining 30% used for their validation. In order to evaluate the performance of the models, the statistical indicators correlation coefficient ( $r$ ); determination coefficient ( $R^2$ ); root mean square error (RMSE) and ratio of deviation performance (RPD). The simple correlation model was not used to estimate chlorophyll-a, as it presented a low correlation ( $r = 0.2$ ) and was inadequate for predicting SST and transparency, with RPD = 1.03 and 0.68, respectively, and moderate coefficient of determination ( $R^2 = 0.74$  and  $0.58$ ). For the prediction of variables using 2D correlation, the models were inadequate, for chlorophyll-a and SST, with RPD = 1.55 and 0.02, respectively, and  $R^2 = 0.45$  for both variables, however, in the estimation of transparency it was possible to obtain a result classified as excellent, from the metrics RPD = 2.04 and  $R^2 = 0.8$ . The model using the PLSR method presented the most satisfactory results for the variables chlorophyll-a, SST and transparency, with RPD = 2.95, 2.64 and 2.17 and  $R^2 = 0.84, 0.82$  and  $0.89$ , respectively.



**Keywords:** water quality; hyperspectral sensors; predictive model

## 4.1 Introdução

A água é um elemento vital para os seres vivos, não apenas para suprir suas necessidades fisiológicas, mas também para o desenvolvimento de atividades como transporte, geração de energia, produção de alimentos, dentre outras. Embora seja um recurso renovável, a água pode ser considerada como limitada, uma vez que a porção de água doce disponível no mundo é de aproximadamente 2,5% (TELLES; COSTA, 2010).

Segundo Pinheiro *et al.* (2014) a qualidade da água de uma bacia hidrográfica pode ser afetada por diferentes fatores antrópicos ou naturais. Em regiões semiáridas, faz-se uso de reservatórios artificiais superficiais para armazenar água, em vista das condições de distribuição pluviométrica da região e, a redução da qualidade da água nesses reservatórios provoca problemas de abastecimento que interferem no desenvolvimento (YU *et al.*, 2018).

Diante disso é imprescindível que haja um monitoramento da qualidade da água na região semiárida, uma vez que permite identificar variações espaço-temporais e a relação entre as bacias de drenagem e os diversos mecanismos dos sistemas hídricos (LOPES, 2013) e, a partir disso, funcionar como instrumento de gestão ambiental.

Uma ferramenta que está sendo cada vez mais utilizada para o gerenciamento dos recursos hídricos é o sensoriamento remoto, entretanto tem sido um desafio, uma vez que esses ecossistemas apresentam propriedades variáveis dentro do mesmo corpo hídrico (PALMER; KUTSER; HUNTER, 2015).

Aplicando técnicas de sensoriamento remoto pode-se avaliar as respostas decorrentes de perturbações provocadas por ações antrópicas e/ou naturais, estimando as concentrações de componentes opticamente ativos na água (COA's), de modo a relacionar a reflectância registrada por sensores com os COA's (AUGUSTO-SILVA *et al.*, 2014).

## 4.2 Hipótese

A avaliação e monitoramento do estado qualitativo da água, assim como a estimativa da concentração de clorofila-a, sólidos suspensos totais e transparência em reservatórios artificiais do semiárido podem ser realizadas por meio de modelos ajustados a partir da relação entre dados espectrais e parâmetros de qualidade.

### **4.3 Objetivos**

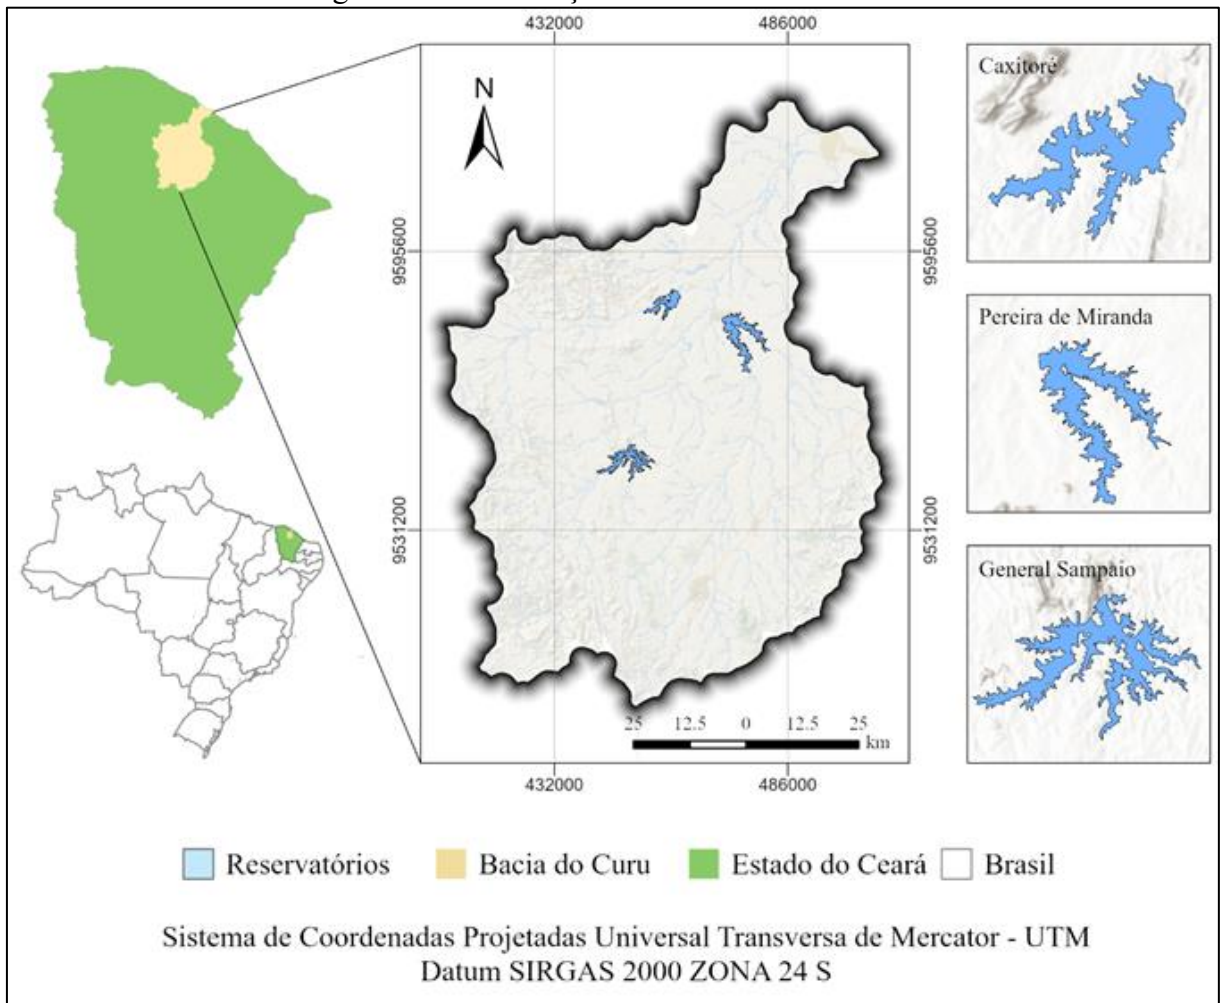
Avaliar a qualidade das águas de reservatórios artificiais no semiárido brasileiro e estimar as concentrações de clorofila-a, sólidos suspensos totais e transparência a partir de dados de sensoriamento remoto.

### **4.4 Metodologia**

#### ***4.4.1 Caracterização da área de estudo***

A área de estudo corresponde aos reservatórios Caxitoré, General Sampaio e Pereira de Miranda, localizados na Bacia Hidrográfica do Curu (BHC) (Figura 23). Esta bacia hidrográfica tem uma área de drenagem de 8.534 km<sup>2</sup>, correspondente a 5,76% do território cearense e é pioneira em ações de gerenciamento de recursos hídricos, sendo a primeira a constituir e implantar um Comitê de Bacia Hidrográfica, em 1997 (CEARÁ, 2009). Apresenta relevância em termos econômicos, devido sua elevada capacidade para realização de atividades como a irrigação e aos grandes investimentos em obras hídricas nela realizados.

Figura 23 - Localização da área de estudo



Fonte: Elaboração da autora.

A bacia do Curu está localizada no centro-norte do Estado e tem como limites as bacias: Metropolitanas, a lestes; as bacias do Acaraú e do Litoral, a oeste e a sub-bacia do rio Banabuiú, ao sul.

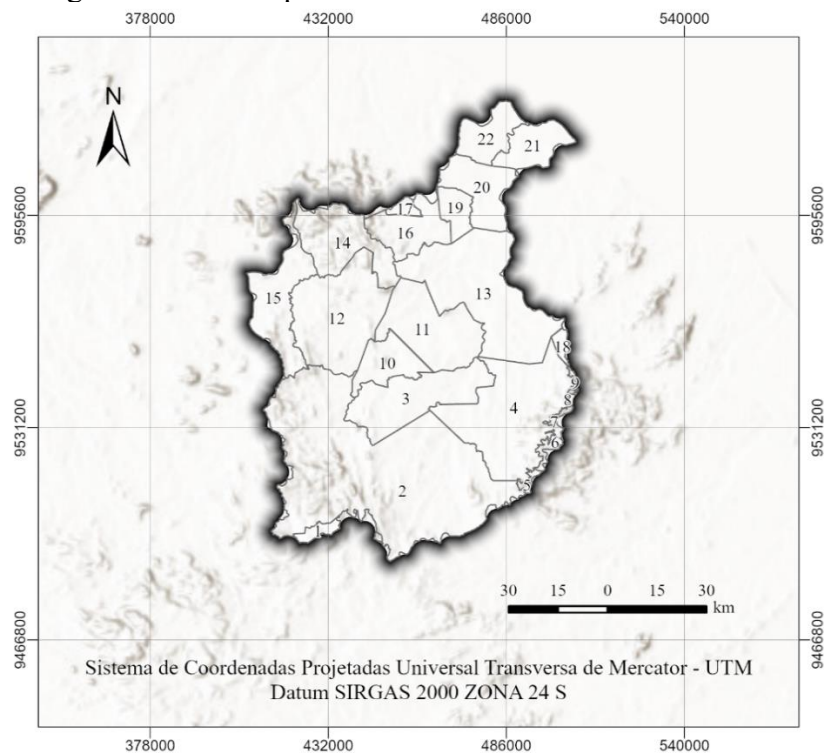
Os municípios de Itatira (1), Paramoti (3), Caridade (4), General Sampaio (10), Apuiarés (11), Tejuçoca (12), Itapajé (14) e São Luís do Curu (19) e são totalmente drenados pela bacia, enquanto que os seguintes municípios são parcialmente drenados (Tabela 8) (Figura 24).

Tabela 8 – Municípios parcialmente drenados pela bacia do Curu.

Identificação	Município	Percentual Drenado (%)
2	Canindé	79,90
5	Aratuba	16,60
6	Mulungu	34,96
7	Guaramiranga	17,76
8	Pacoti	4,95
9	Palmácia	5,34
13	Pentecoste	70,97
15	Irauçuba	28,77
16	Umirim	90,36
17	Tururu	27,29
18	Maranguape	5,97
20	São Gonçalo do Amarante	35,54
21	Paracuru	82,20
22	Paraipaba	78,25

Fonte: Elaboração da autora.

Figura 24 - Municípios da bacia do Curu e seus afluentes



Fonte: Elaboração da autora.

#### 4.4.1.1 Caracterização hidroclimatológica

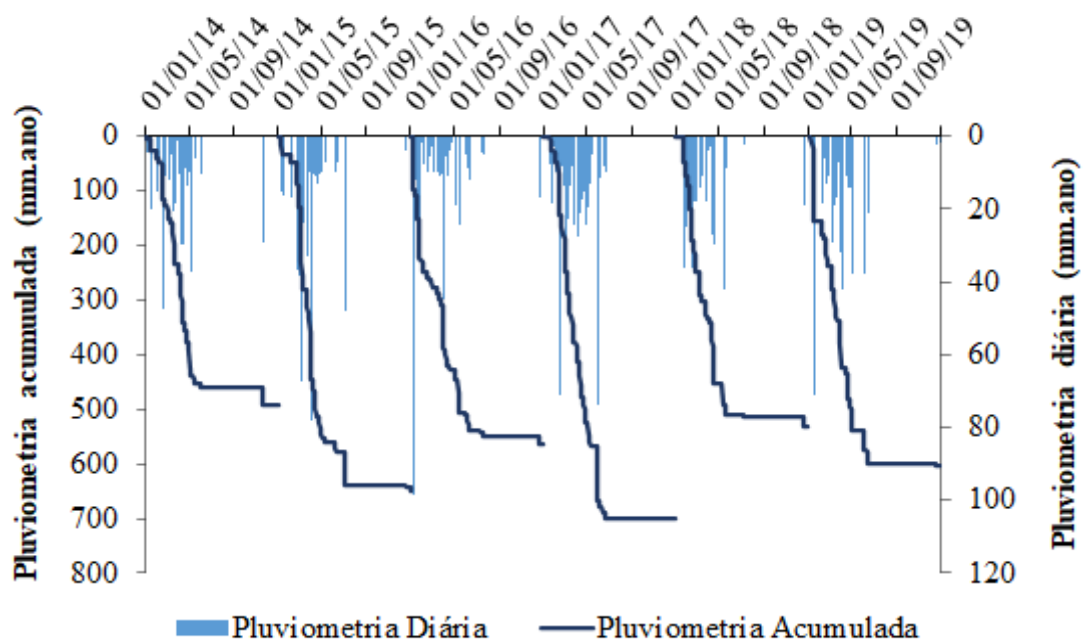
##### 4.4.1.1.1 Clima

O clima é classificado como BSw'h, segundo Köppen (1948). Essa classificação caracteriza a região como quente e semiárida, com pluviosidades máximas ocorrendo no outono, e temperatura média mensal sempre superior a 18 °C. Por outro lado, Palácio *et al.* (2009) afirmam que na parte baixa da Bacia do Curu, o clima é classificado como Aw', caracterizando a região como quente e úmida, com precipitação anual média de 1.020 mm e temperatura média anual superior a 18°C. Embora haja duas classificações distintas para o clima na Bacia do Curu, ressalta-se que os três reservatórios estão localizados na parte superior da bacia, ou seja, na região semiárida.

##### 4.4.1.1.2 Precipitação

Souza; Santos; Oliveira (2012) afirmam que a bacia do Curu é, em quase que sua totalidade, sujeita às consequências da irregularidade pluviométrica do semiárido e aos baixos índices de balanço hídrico durante quase todo o ano. A Figura 25 exibe o comportamento pluviométrico da região no período estudado.

Figura 25 – Pluviometria da Bacia do Curu entre os anos de 2014 e 2019



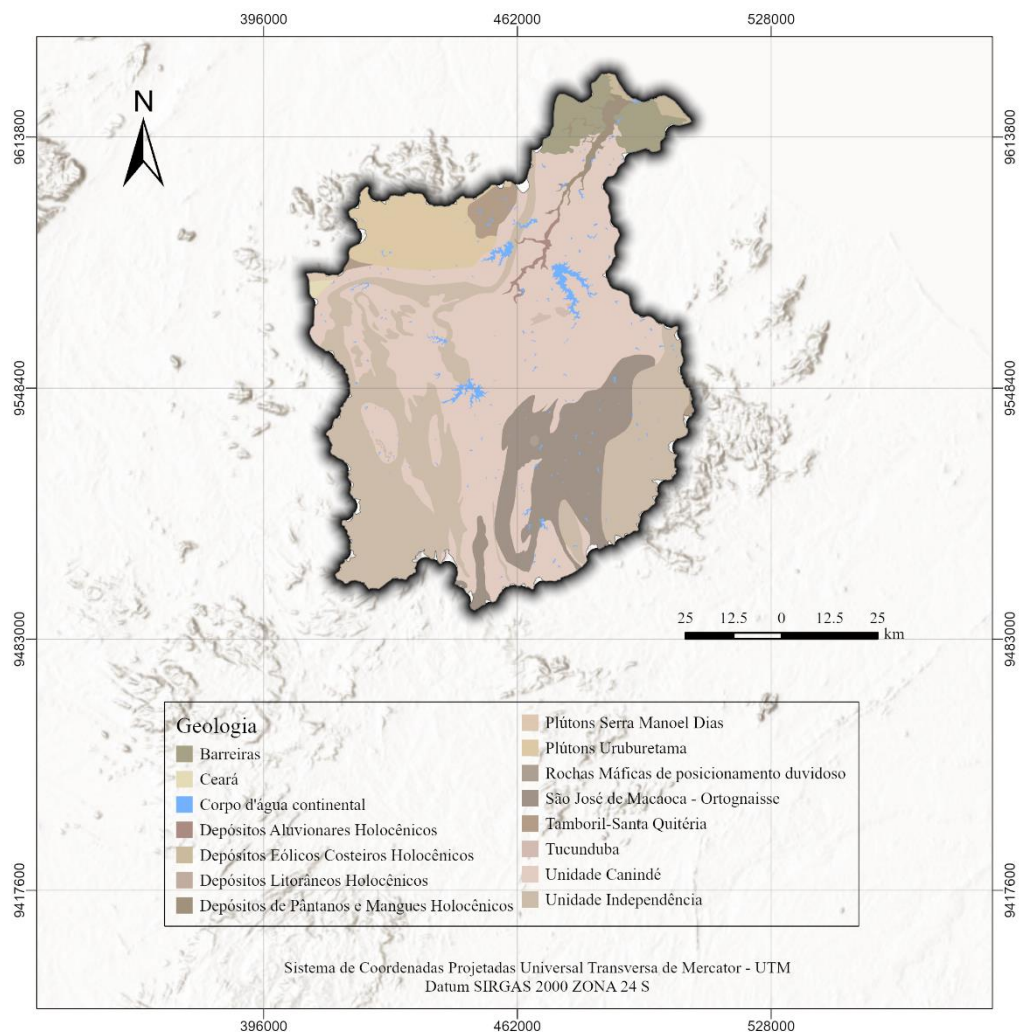
Fonte: Elaboração da autora.

#### 4.4.1.2 Caracterização fisiográfica

##### 4.4.1.2.1 Geologia

A geologia da bacia é composta predominantemente por rochas cristalinas, havendo ocorrência dos sedimentos da formação barreiras e dos depósitos quaternários de aluviões e dos sedimentos de praias apenas no baixo do vale (Figura 26) (CEARÁ, 2009).

Figura 26 - Geologia da Bacia do Curu



Fonte: Elaboração da autora a partir de dados do IGBE.

##### 4.4.1.2.2 Relevo

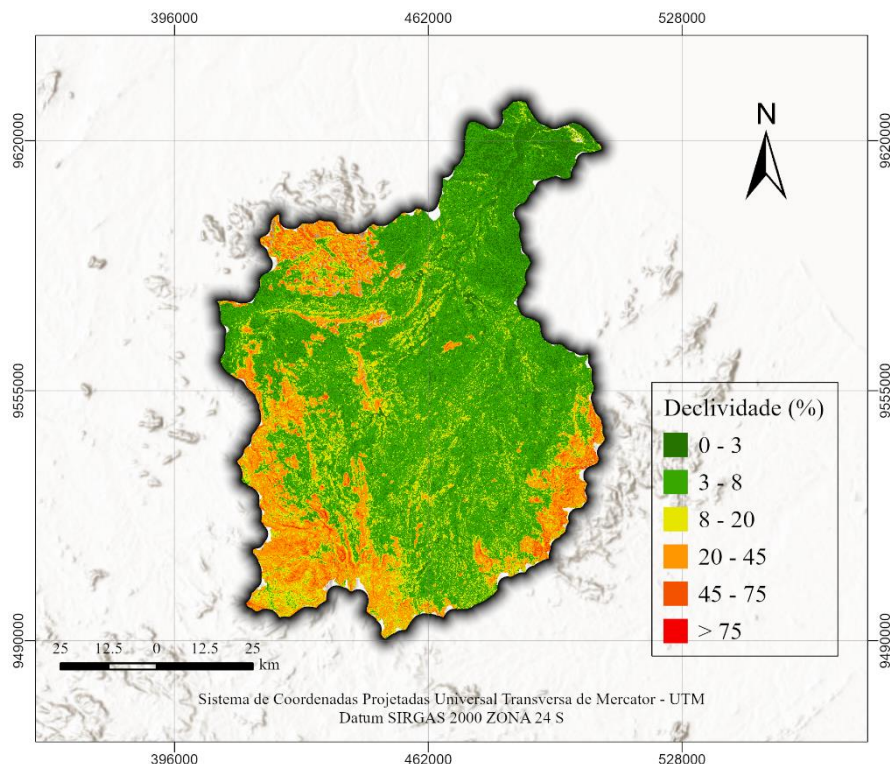
Verifica-se na Figura 27, a classificação das declividades da bacia do Curu, conforme a metodologia da Embrapa (1999), que separa a declividade de uma área em 6 classes

distintas, variando de 0-3% (relevo plano), 3-8% (relevo suave ondulado), 8-20% (relevo ondulado), 20-45% (relevo forte ondulado), 45-75% (relevo montanhoso); >75% (relevo escarpado).

A classificação da declividade indica que 19% de toda a área da bacia apresentam declividade entre 0 e 3%, classificando o relevo como plano; 43,53% da área apresentam declividade entre 3 e 8%, o que classifica o relevo como suave ondulado; 21% da área da bacia apresentam declividade entre 8 e 20%, classificando o relevo como ondulado; 12,91% da área apresentam declividade entre 20 e 45%, classificando o relevo como forte ondulado; 3,41% da área apresentam declividade entre 45 e 75%, classificando o relevo como montanhoso e apenas 0,20% da área apresenta declividade entre acima de 75%, classificando o relevo como escarpado.

Observa-se que se que 64,5% da área total da bacia do Curu classificam-se como suave ondulado e ondulado, cuja declividade varia entre 3 e 20%.

Figura 27 - Declividade da bacia do Curu

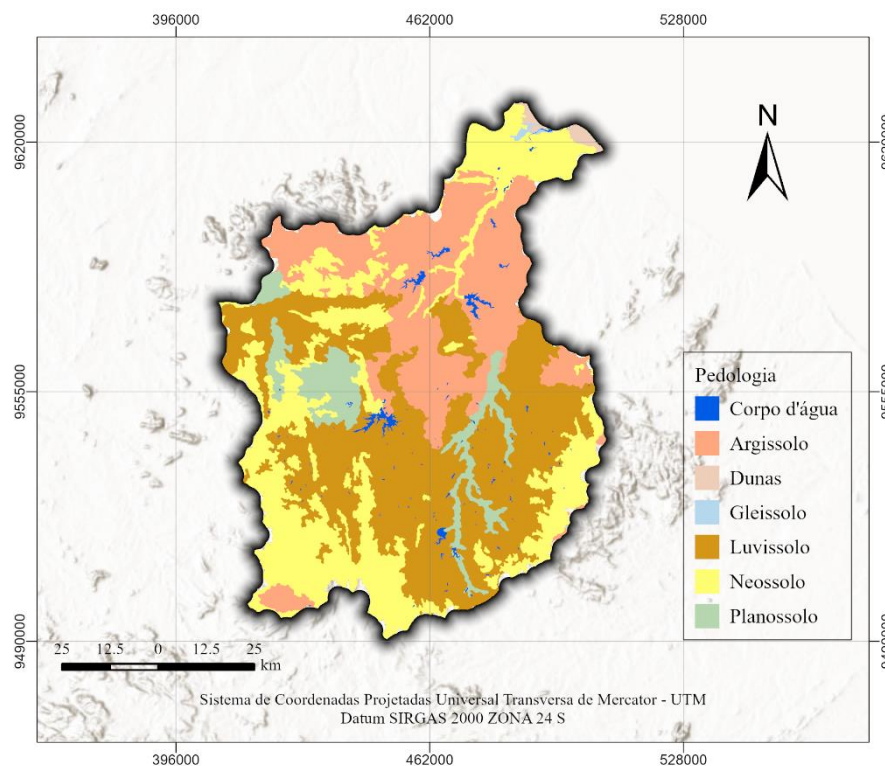


Fonte: Elaboração da autora a partir de dados do SRTM.

#### 4.4.1.2.3 Pedologia

A região da bacia hidrográfica do rio Curu apresenta solos rasos, com eventuais afloramentos rochosos e são classificados como Neossolos Quartzarênicos, Neossolos Litólicos, Planossolos, Luvisolos e Argissolos (Figura 28), apresentando características como fertilidade natural de baixa a média e extrema vulnerabilidade às condições de aridez e lixiviação (FRANÇA *et al.*, 2013).

Figura 28 - Classes de solos da bacia do Curu



Fonte: Elaboração da autora a partir de dados do Jacomine

Os Planossolos compreendem solos minerais imperfeitamente ou mal drenados, normalmente são encontrados em áreas de cotas baixas, planas a suave onduladas, apresentando características como pouca profundidade e horizonte superficial de cores claras e de textura média, argilosa ou muito argilosa. Os Neossolos apresentam em sua constituição, materiais minerais ou orgânicos pouco espessos, que não apresenta alterações expressivas em relação ao material originário devido à baixa intensidade de atuação dos processos pedogenéticos. Argissolos são solos constituídos por material mineral, apresentando textura predominantemente argilosa, possuem baixa fertilidade natural e cores avermelhas ou

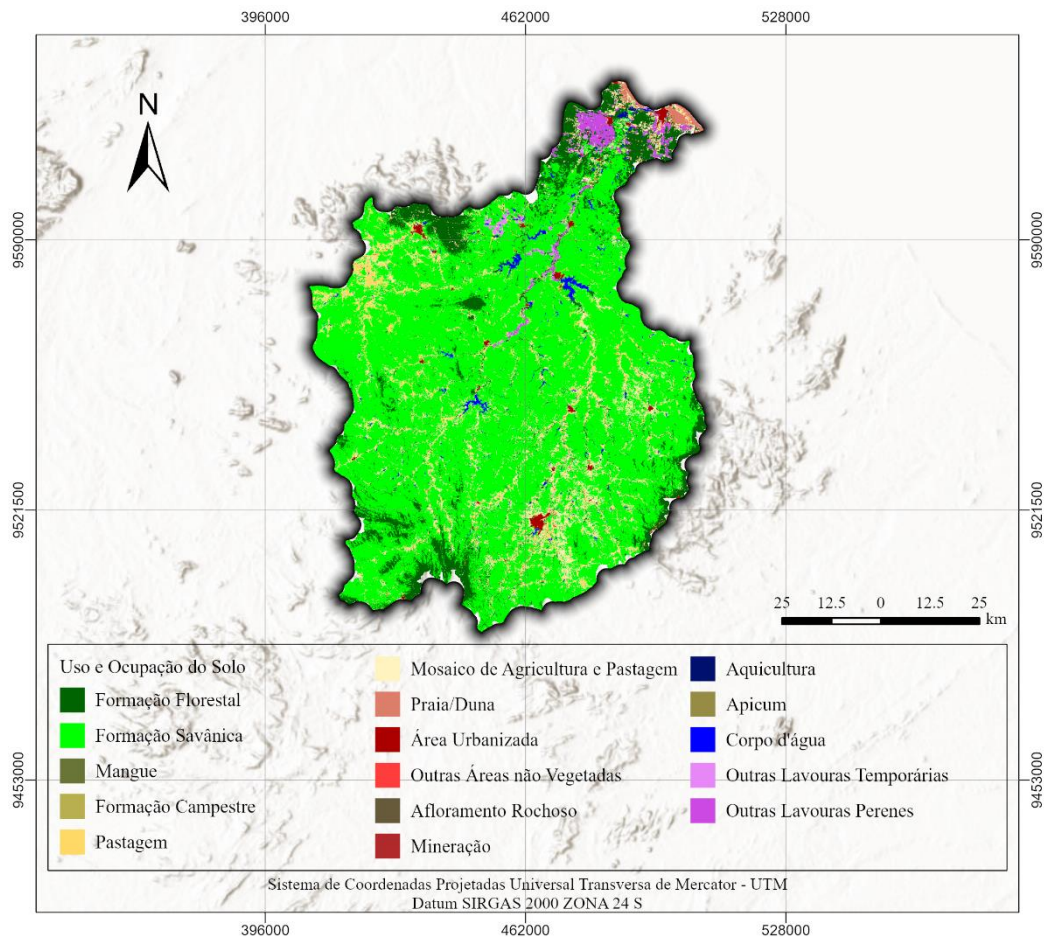


amareladas. Os Luvisolos compreendem solos minerais, com argila de atividade alta e variam de bem a imperfeitamente drenados, sendo normalmente pouco profundos (EMBRAPA, 2018).

#### 4.4.1.2.4 Uso e ocupação do solo

A vegetação presente na área da bacia é representada pelo Complexo Vegetacional da Zona Litorânea ao norte, Caatinga Arbustiva Densa no centro e sudeste da bacia, Mata Seca a sudoeste, na Serra do Machado, e Mata Ciliar às margens do leito do baixo curso do rio Curu (CEARÁ, 2009). O uso e ocupação do solo na bacia do Curu está disposto na Figura 29.

Figura 29 - Uso e Ocupação do solo da bacia do Curu

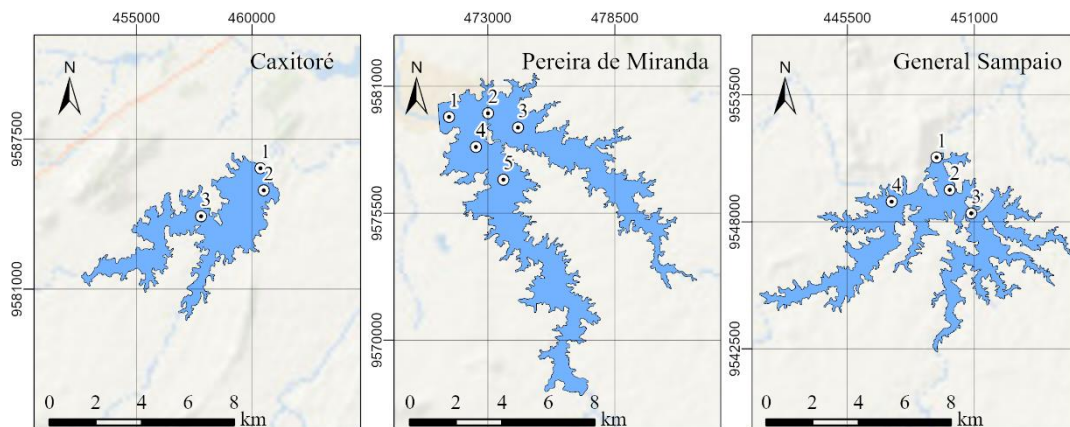


Fonte: Elaboração da autora a partir do MapBiomias.

#### 4.4.2 Localização dos pontos de coleta

A área de estudo corresponde aos reservatórios Caxitoré, Pereira de Miranda e General Sampaio, nos quais foram selecionados três, quatro e cinco pontos para realização das coletas, respectivamente (Figura 30). Verifica-se na Tabela 9, as informações de localização e barragem dos açudes em estudo.

Figura 30 - Localização dos pontos de coleta



Sistema de Coordenadas Projetadas Universal Transversa de Mercator - UTM  
Datum SIRGAS 2000 ZONA 24 S

Fonte: Elaboração da autora.

Tabela 9 - Caracterização dos reservatórios

Características Técnicas	Reservatórios		
	Caxitoré	Pereira de Miranda	General Sampaio
Capacidade (m <sup>3</sup> )	202.000.000	395.638.000	322.200.000
Localização	Pentecoste - Ce	Pentecoste - Ce	General Sampaio - Ce
Rio Barrado	Caxitoré	Canindé	Curu
Bacia Hidrográfica (km <sup>2</sup> )	1.430	2.840	1.720
Bacia Hidráulica (ha)	4.574	5.700	3.300
Precipitação Média Anual (mm)	670	681,9	900
Vazão Regularizada (m <sup>3</sup> /s)	2470	3,500	3,150
Extensão pelo coroamento (m)	425	1.274	222
Largura do Coroamento (m)	8	6	8
Cota do Coroamento (m)	77,50	62	128,50
Altura Máxima (m)	41	29,40	37,60

Fonte: Adaptado de DNOCS e SRH (2019).

#### 4.4.3 Aquisição de dados limnológicos

As coletas dos dados limnológicos foram realizadas nos pontos previamente selecionados (Figura 31), a fim de representar os maiores aportes dentro dos reservatórios. O grupo MASSA realiza campanhas desde o ano de 2014, as quais foram reduzidas nos anos de 2020 e 2021, em virtude da pandemia do COVID-19 e, diante disso, foram utilizados dados das campanhas realizadas nos anos de 2014 a 2019.

As amostras foram coletadas em garrafas plásticas de 1,0 L (Figura 31) a uma profundidade de 30 cm da superfície da água, para análises de clorofila-a e em garrafas de 1,5 L para análises dos sedimentos em suspensão, pH e condutividade elétrica (CE).

Após a coleta as amostras foram conservadas em isopor com cubos de gelo a fim de preservar as amostras, que foram levadas para laboratório para serem processadas. Em campo também foram medidos pH, CE, temperatura, transparência de secchi e profundidade, medidos a 30 cm da superfície da água.

Figura 31 - Coleta de amostras de água em garrafas plásticas



Fonte: Grupo MASSA (2019).

As metodologias utilizadas para realizar a análise das variáveis em questão, estão descritas na Tabela 10, juntamente com suas respectivas referências.

Tabela 10 - Atributos analisados, metodologias e referências

ATRIBUTOS	METODOLOGIA	REFERÊNCIAS
Clorofila-a ( $\mu\text{g L}^{-1}$ )	Espectrofotométrico – Extração a quente com Metanol	JONES, (1979)
pH	Potenciométrico	
CE ( $\text{dS m}^{-1}$ )	Condutivimétrico	
Transparência (m)	Disco de Secchi	
Temperatura ( $^{\circ}\text{C}$ )	Termômetro com filamento de mercúrio $0^{\circ}$ - $60^{\circ}\text{C}$	
SST ( $\text{mg L}^{-1}$ )	Filtração a vácuo com membrana de fibra de vidro $0,45\mu\text{m}$ de porosidade – Secagem a $103^{\circ}\text{C}$ – $105^{\circ}\text{C}$	APHA <i>et al.</i> (2005)
SSF ( $\text{mg L}^{-1}$ )	Filtração a vácuo com membrana de fibra de vidro $0,45\mu\text{m}$ de porosidade – Ignição $500$ – $550^{\circ}\text{C}$	
SSV ( $\text{mg L}^{-1}$ )	Filtração a vácuo com membrana de fibra de vidro $0,45\mu\text{m}$ de porosidade – Ignição $500$ – $550^{\circ}\text{C}$	

Fonte: Elaboração da autora.

#### 4.4.4 Aquisição e tratamento de dados radiométricos

Para aquisição dos dados radiométricos, utilizou-se o espectrorradiômetro Field Spec 3 Hi-Res, com campo de visada de  $25^{\circ}$ , que opera na região de 350 a 2500 nm e com resolução espectral de 3 nm em 700 nm, 8,5 nm em 1400 nm e 6,5 nm em 2100 nm. Como padrão de referência absoluta, foi utilizada uma placa spectralon branca de alta reflectância, calibrada (Figura 32). O espectrorradiômetro foi posicionado com eixo de visada de  $45^{\circ}$  de inclinação em relação à vertical e de  $90^{\circ}$  de azimute em relação a posição do sol. O sensor estava posicionado à 1 m da superfície da água e a área imageada foi de, aproximadamente,  $0,7 \text{ m}^2$ . Os valores de radiância espectral foram convertidos em fator de reflectância bidirecional conforme a Equação 1:

$$\text{FBR } \lambda = L_{a,\lambda} / L_{r,\lambda} \quad (1)$$

em que:

$FRB_{\lambda}$  - fator de reflectância bidirecional (adimensional)

$L_{a,\lambda}$  - radiância espectral do alvo ( $W\ cm^{-2}\cdot sr^{-1}\cdot\mu m^{-1}$ )

$L_{r,\lambda}$  - radiância espectral da placa de referência ( $W\ cm^{-2}\cdot sr^{-1}\cdot\mu m^{-1}$ )

Figura 32 - Calibração com placa spectralon



Fonte: Grupo MASSA (2019).

A coleta dos dados radiométricos *in situ* (Figura 33), foi realizada conforme a metodologia de Milton (1987), obtendo-se dez medidas de radiância, no horário de 10 às 14 horas, uma vez que esse período proporciona melhor condição de ângulo de inclinação solar, o que favorece um maior fluxo de energia no campo de irradiação.

Figura 33 - Coleta de dados radiométricos



Fonte: Grupo MASSA (2019).

#### 4.4.5 Calibração dos modelos de estimativa de dados limnológicos

Foram testados modelos empregando-se três tipos distintos de técnicas matemáticas: banda única (correlação simples), razão de duas bandas (correlação 2D) e regressão por mínimos quadrados parciais (PLSR).

Os dados de trabalho foram divididos em dois grupos distintos, em que 70% das observações foi utilizada para calibrar os modelos e 30% foi empregado da validação dos modelos calibrados.

Para obtenção do modelo com bandas únicas realizou-se uma análise de correlação simples entre os dados espectrais e os resultados das análises dos dados limnológicos coletados em campo, a fim de selecionar as bandas úteis a serem empregadas no estudo, as quais foram selecionadas aquelas com o coeficiente de correlação ( $r$ ) mais próximos de  $-1$  e  $+1$ , sugerindo-se uma correlação mais forte.

Após a escolha da banda com valor de  $r$  mais próximo de  $|1|$ , correlacionou-se a resposta espectral da água (grupo de calibração – 70%) com os dados limnológicos medidos.

Para obtenção do modelo utilizando-se razão de bandas, gerou-se um gráfico de correlação 2D para selecionar as bandas significativas a serem empregadas, a partir do uso de uma ferramenta estatística para análise de colinearidade, disponível na plataforma online do Instituto Nacional de Pesquisas Espaciais (INPE) (OGASHAWARA *et al.*, 2014).

Selecionada a razão entre as bandas que apresentaram valores de  $r$  mais próximos de  $|1|$ , a razão da resposta espectral da água (grupo de calibração – 70%) foi correlacionada com os dados limnológicos medidos.

Por fim, visando a realização da regressão por mínimos quadrados parciais foram utilizados os comprimentos de onda entre 400 – 900 nm, intervalo em que é possível estudar o comportamento espectral da água. O PLSR foi realizado utilizando o software The Unscrambler®, no qual foram adicionados os valores do fator de reflectância para cada comprimento de onda ( $X$ ) e os valores das respostas variáveis ( $Y$ ), que se referiam às concentrações de cada dado limnológico.

Para seleção dos comprimentos de onda significativos, foi utilizado o do software IBM SPSS Statistics®, a partir do método Stepwise, posteriormente foi utilizado o software The Unscrambler® (CAMO AS, 2021) em versão de teste, para construir os modelos de predição dos dados limnológicos.

## 4.5 Resultados e Discussão

### 4.5.1 Estatística descritiva

Observa-se nas Tabelas 11, 12 e 13 as estatísticas descritivas das concentrações de clorofila-a e SST, bem como da transparência dos reservatórios Caxitoré, General Sampaio e Pereira de Miranda, respectivamente, para o período avaliado. Verifica-se que os valores de desvio padrão e CV foram mais altos para clorofila-a e SST do que para a transparência em todos os reservatórios, isso pode ser explicado devido a maior variabilidade de concentrações desses dois componentes.

Tabela 11 - Estatística descritiva para as variáveis analisadas no reservatório Caxitoré

Variáveis descritivas	Clorofila-a	SST	Transparência
Média	74,54	7,03	0,63
Erro padrão	12,12	0,95	0,07
Mediana	57,29	6,44	0,51
Desvio padrão	60,63	4,55	0,35
CV (%)	81,33	64,71	54,83
Curtose	1,03	-0,52	-0,32
Assimetria	1,24	0,63	0,95
Máximo	231,44	16,66	1,27
Mínimo	1,87	1,33	0,18
K-S (p-value)	(-)	(-)	(-)
Contagem	25	23	23

CV (%): Coeficiente de Variação; K-S: Teste de normalidade por Kolmogorov-Smirnov; (-): não normal.

Fonte: Elaborado pela autora.

Tabela 12 - Estatística descritiva para as variáveis analisadas no reservatório General Sampaio

Variáveis descritivas	Clorofila-a	SST	Transparência
Média	31,82	10,00	0,63
Erro padrão	4,68	1,50	0,06
Mediana	25,90	8,00	0,51
Desvio padrão	27,26	8,84	0,34
CV (%)	85,68	88,37	54,10

Curtose	1,16	3,17	-0,21
Assimetria	1,23	1,67	0,85
Máximo	106,80	40,00	1,45
Mínimo	4,18	0,29	0,20
K-S (p-value)	(-)	(-)	(-)
Contagem	34	35	36

CV (%): Coeficiente de Variação; K-S: Teste de normalidade por Kolmogorov-Smirnov; (-): não normal.  
Fonte: Elaborado pela autora.

Tabela 13 - Estatística descritiva para as variáveis analisadas no reservatório Pereira de Miranda

Variáveis descritivas	Clorofila-a	SST	Transparência
Média	73,25	28,87	0,42
Erro padrão	14,44	4,92	0,05
Mediana	50,20	23,43	0,27
Desvio padrão	90,15	30,74	0,34
CV (%)	123,05	106,49	80,87
Curtose	5,44	4,03	-0,99
Assimetria	2,38	1,97	0,80
Máximo	379,67	127,00	1,07
Mínimo	1,34	1,00	0,09
K-S (p-value)	(-)	(-)	(-)
Contagem	39	39	39

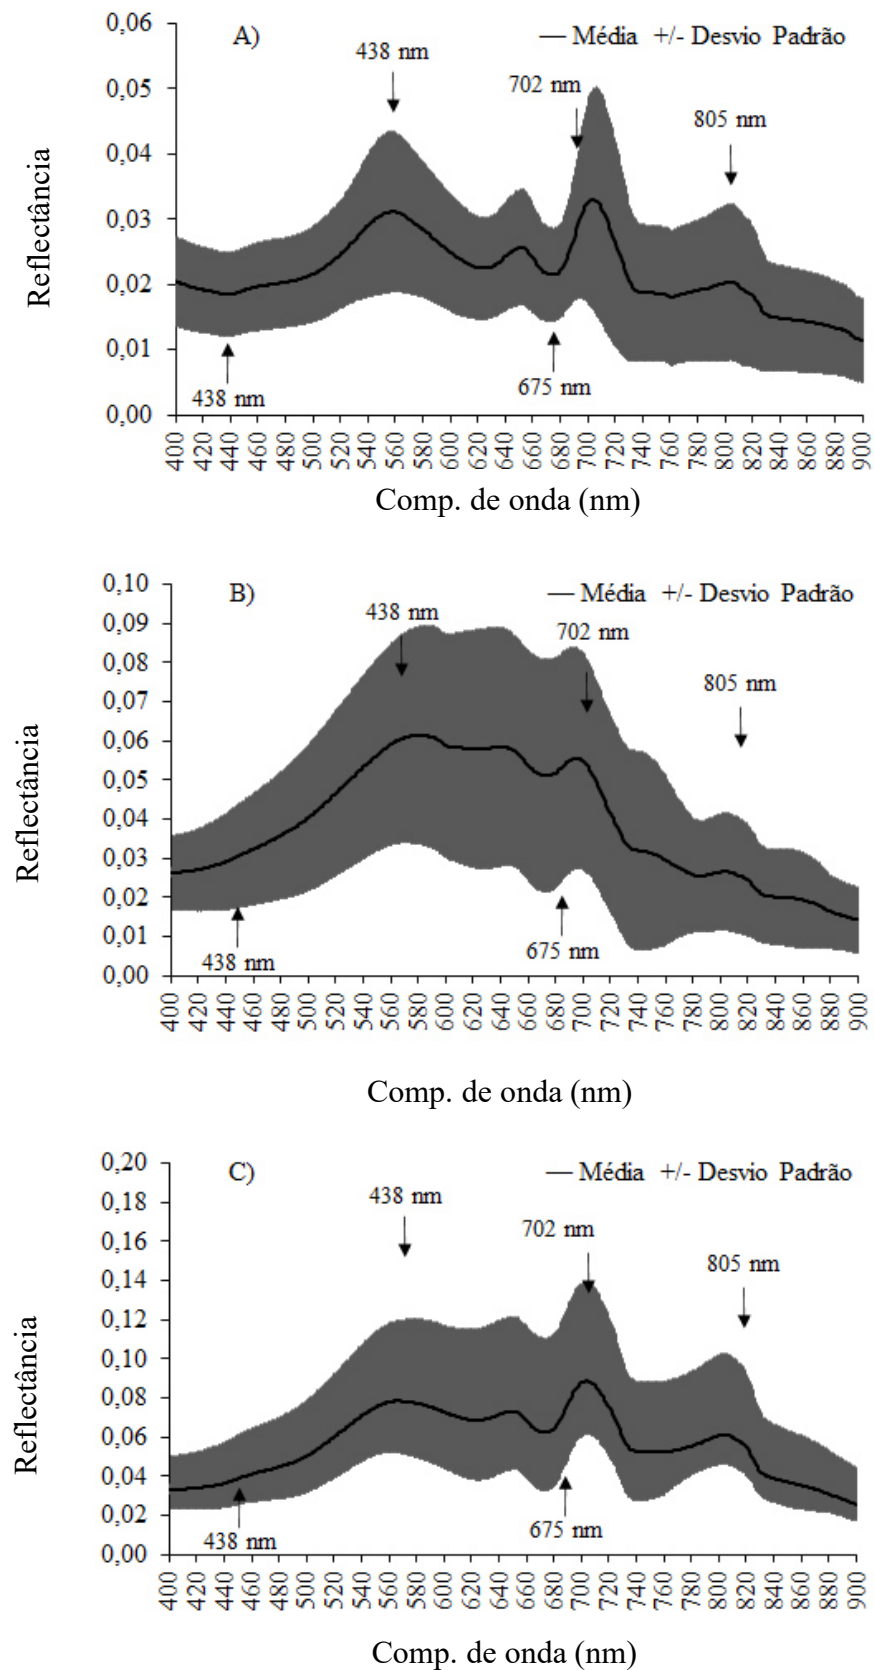
CV (%): Coeficiente de Variação; K-S: Teste de normalidade por Kolmogorov-Smirnov; (-): não normal.  
Fonte: Elaborado pela autora.

#### 4.5.2 Análise dos dados hiperespectrais

A partir dos comprimentos de onda de 350-900 nm localizados na região VNIR, pode-se observar, na Figura 34 os resultados espectrais médios para os reservatórios amostrados. Este intervalo foi utilizado por apresentar menor quantidade de ruídos, além de representar a faixa de resposta espectral na identificação dos COA's da água (BARBOSA *et al.*, 2019).



Figura 34 - Espectros médios de reflectância e os respectivos desvios padrões de cada reservatório (A) Caxitoré (B) General Sampaio (C) Pereira de Miranda.



Fonte: Elaborado pela autora.

A água natural apresenta baixo coeficiente de absorção na região entre 400 e 600 nm, elevando-se na região do infravermelho e, devido ao processo físico-químico da fotossíntese, pigmentos fotossintetizantes interagem fortemente com a radiação da faixa do azul (400 a 500 nm) e do vermelho (600 a 700 nm) (BERNARDO, 2016). Na região do verde, em torno de 550 nm, há um aumento da reflectância, correspondente ao espalhamento interno dos organismos fitoplanctônicos (NOVO, 2001).

Na Figura 34 observa-se a presença de clorofila-a devido ao vale de absorção localizado nos comprimentos de onda de 438 nm e 675 nm (RUNDQUIST *et al.*, 1996), por outro lado, o deslocamento do pico de reflectância de 550 nm para 563 nm indica a presença de SST na água (JENSEN, 2009). Verificou-se a presença de ficocianina nos reservatórios, por meio do vale de absorção em 625 nm, conforme Simis; Peters; Gons (2005), o que pode ser utilizado como indicador da presença de cianobactérias nos corpos hídricos. Watanabe *et al.* (2015) relataram um pico de reflexão na região do verde bem como uma forte absorção entre 620 nm e 630 nm que se associam à ficocianina. O pico máximo de reflectância está localizado no comprimento de onda de 702 nm, correspondendo ao segundo pico da clorofila-a e, por fim, verifica-se o menor pico de reflectância no comprimento de onda de 805 nm, que, segundo Novo (2001), está possivelmente relacionado ao retroespalhamento de matéria orgânica.

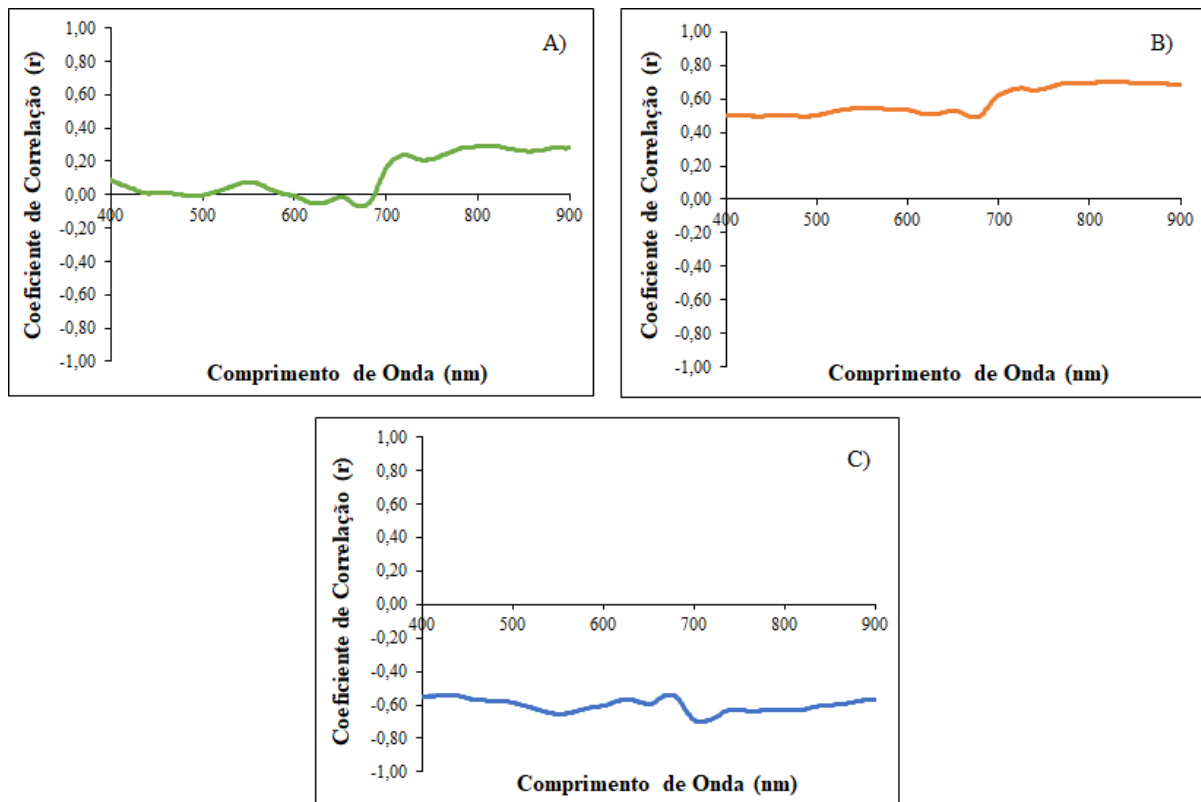
Após a análise laboratorial dos dados limnológicos, verificou-se alta variação da concentração para um mesmo reservatório, o que pode ser evidenciado pelo desvio padrão exposto na Figura 34.

#### **4.5.3 Correlação simples entre a reflectância e as variáveis limnológicas**

A reflectância espectral foi correlacionada com as variáveis limnológicas medidas, a fim de identificar as posições espectrais de maior correlação. As variáveis limnológicas utilizadas foram: clorofila-a, SST e transparência e estão apresentadas na Figura 35.

É possível observar que para as concentrações de clorofila-a não foram apresentadas fortes correlações com a reflectância, sendo os maiores picos em 720 nm e em torno de 810 nm, com  $r = 0,21$  e  $0,29$ , respectivamente. Assim como no presente estudo, Toniolo (2016) obteve baixa correlação entre clorofila-a e dados radiométricos, com  $r = 0,20$  em torno de 700 nm. Lopes *et al.* (2021) obtiveram resultados semelhantes, em que houve baixa correlação para a variável clorofila-a. Desse modo, não foram selecionadas bandas úteis, a partir da correlação simples, para a obtenção de um modelo de estimativa desta variável.

Figura 35 - Correlogramas entre o fator de reflectância e variáveis medidas: (A) clorofila-a em  $\mu\text{g L}^{-1}$ , (B) SST em  $\text{mg L}^{-1}$ , (C) transparência em m



Fonte: Elaboração da autora.

A variável SST (Figura 35B) apresentou correlações positivas ao longo de todo o espectro, com valores mais altos entre os comprimentos de onda de 700 nm a 900 nm, onde atingiu correlação máxima em 826 nm, com  $r = 0,50$ . Cabral; Pereira Filho (2018) obtiveram, em seus estudos, correlação positiva entre SST e a reflectância, que variavam conforme a estação em que as amostras foram coletadas.

Analisando a variável transparência (Figura 35C), observa-se que sua variação manifestou correlações negativas com os fatores de reflectância ao longo de todo o espectro eletromagnético, com pico máximo de correlação negativa em torno 721 nm, apresentando  $r = 0,55$ . A correlação negativa entre essa variável e a reflectância foi verificada em diversas pesquisas (LONDE *et al.*, 2011; PEREIRA, GALO, VELINI, 2011; LOPES *et al.*, 2014, TONIOLO, 2016).

#### 4.5.3.1 Calibração dos modelos de correlação simples

A construção dos modelos de predição das variáveis utilizando os dados espectrais foi realizada após seleção de bandas, que ocorreu por meio da correlação simples. É possível identificar na Tabela 14 as posições que apresentaram os maiores coeficientes de correlação entre o fator de reflectância e as variáveis limnológicas SST e transparência, tendo em vista que não foram selecionadas bandas úteis para clorofila-a.

Tabela 14 - Modelos para estimativas dos teores de nutriente na folha utilizando uma única banda espectral

Variável	Comprimento de onda (nm)	Equações	R <sup>2</sup>
SST	826	$y = 589,73x + 0,43$	0,56
Transparência	721	$y = -6,6214x + 0,8445$	0,44

Fonte: Elaboração da autora.

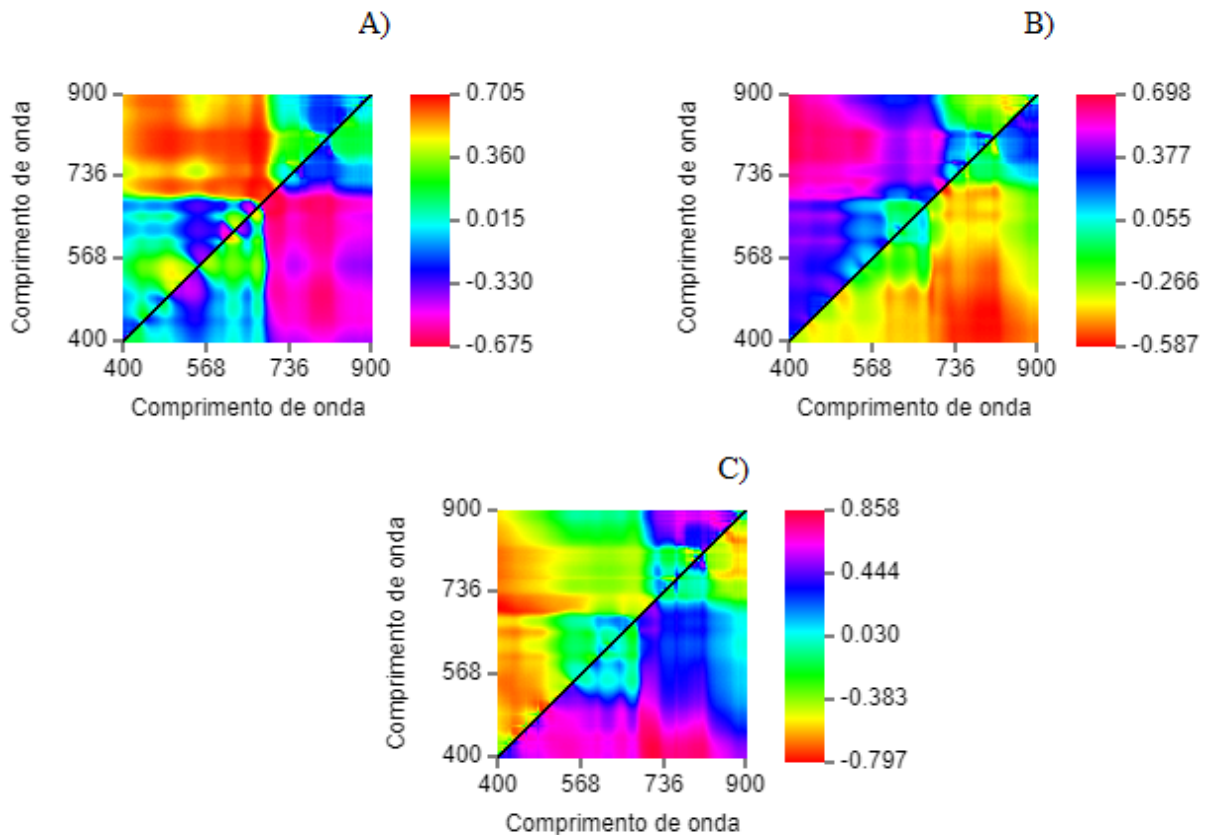
Os comprimentos de onda selecionados para obtenção dos modelos de estimativa de SST e transparência estão localizados na região do infravermelho próximo (NIR). A presença de sólidos suspensos na água promove o aumento no espalhamento de luz (BOOS, 2013), afetando assim, os valores de reflectância no comprimento de onda nas regiões do visível e infravermelho próximo.

#### 4.5.4 Correlação 2D entre a reflectância e as variáveis limnológicas

Usando a ferramenta de correlação 2D foram selecionadas e testadas todas as combinações de bandas no intervalo de 400 a 900 nm que apresentaram melhores valor de r para as variáveis clorofila-a, SST e transparência (Figura 36).

Verifica-se que para as concentrações de clorofila-a os valores de r variaram entre -0,675 e 0,705, o que corresponde à uma correlação moderada (MILTON, 1992). Valores inferiores foram observados para as concentrações de SST, com r variando de -0,587 a 0,698, contudo, a correlação enquadra-se como moderada. A correlação 2D entre a reflectância espectral e a variável transparência resultou em melhores resultados, em que o r variou entre -0,797 e 0,858 e, apesar de valores mais elevados, classificou-se como moderada, assim como as demais variáveis limnológicas.

Figura 36 - Correlograma 2D entre o fator de reflectância e variáveis medidas: (A) clorofila-a em  $\mu\text{g L}^{-1}$ , (B) SST em  $\text{mg L}^{-1}$ , (C) transparência em m



Fonte: Elaboração da autora.

#### 4.5.4.1 Calibração dos modelos de correlação 2D

Selecionados os comprimentos de onda cuja razão apresentou os melhores valores de  $r$ , prosseguiu-se para a construção dos modelos de predição das variáveis. Na Tabela 15 pode-se observar as razões de bandas que apresentaram os maiores coeficientes de correlação entre o fator de reflectância e as variáveis limnológicas clorofila-a, SST e transparência.

Tabela 15 - Modelos para estimativas dos teores de nutrientes nas folhas utilizando razão de bandas espectrais

Variável	Razão de bandas (nm)	Equações	$R^2$
Clorofila-a	721/665	$y = 114,04x - 61,567$	0,42
SST	830/400	$y = 34,666x - 12,872$	0,50
Transparência	410/712	$y = 1,0794x - 0,1212$	0,70

Fonte: Elaboração da autora.

Observa-se que, assim como para a criação dos modelos de predição com correlação simples, na correlação 2D também foram selecionados comprimentos de onda localizados na região do infravermelho próximo (NIR), contudo, a razão incluiu comprimentos de onda da região do visível.

#### 4.5.5 Regressão por Mínimos Quadrados Parciais (*Partial Least Square Regression – PLSR*)

##### 4.5.5.1 Calibração dos modelos de PLSR

Utilizando os dados de reflectância espectral, foram testados modelos que de predição das variáveis limnológicas clorofila-a, SST e transparência dos reservatórios Caxitoré, General Sampaio e Pereira de Miranda, localizados na Bacia hidrográficos do rio Curu. Os comprimentos de onda selecionados para geração dos modelos estão dispostos na Tabela 16 e as equações de calibração na Tabela 17.

Tabela 16 - Bandas espectrais selecionadas para a calibração dos modelos por PLSR

Variável	Bandas	n	R <sup>2</sup> -ajust
<b>Clorofila-a</b>	549, 599, 625, 671, 740, 870	66	0,51
<b>SST</b>	740, 759, 812, 829, 861, 884	69	0,52
<b>Transparência</b>	439, 479, 547, 599, 657, 671, 703, 728, 806	66	0,50

n: Número de dados utilizados para calibração dos modelos.

Fonte: Elaboração da autora.

Tabela 17 - Equações utilizadas na calibração dos modelos por PLSR

Variável	Equação
<b>Clorofila-a</b>	Clorofila-a = 45,45 - 1674,65 (FRB 549 nm) - 15,21 (FRB 599 nm) - 1370,50 (FRB 625 nm) - 2574,65 (FRB 671 nm) + 1809,30 (FRB 740 nm) + 1956,92 (FRB 870 nm)
<b>SST</b>	SST = - 0,09 + 118,65 (FRB 740 nm) + 119,51 (FRB 759 nm) + 132,59 (FRB 812 nm) + 100,03 (FRB 829 nm) + 80,53 (FRB 861 nm) + 66,73 (FRB 884 nm)

**Transparência**

$$\text{Transparência} = 1,00 + 11,57 (\text{FRB } 439 \text{ nm}) + 6,79 (\text{FRB } 479 \text{ nm}) - 13,20 (\text{FRB } 547 \text{ nm}) - 7,85 (\text{FRB } 599 \text{ nm}) + 4,96 (\text{FRB } 657 \text{ nm}) + 12,79 (\text{FRB } 671 \text{ nm}) - 18,77 (\text{FRB } 703 \text{ nm}) - 1,88 (\text{FRB } 728 \text{ nm}) + 11,56 (\text{FRB } 806 \text{ nm})$$

PLSR: Partial Least-Squares Regression (Regressão por Mínimos Quadrados Parciais);  $\lambda$ : Fator de reflectância

Fonte: Elaboração da autora.

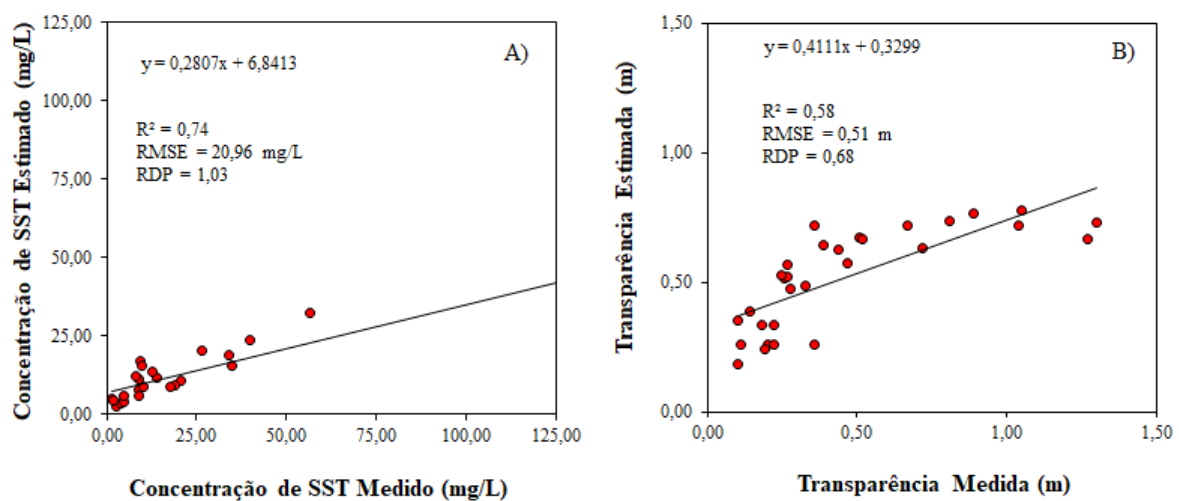
#### 4.5.6 Validação dos modelos

Os gráficos referentes à validação dos modelos utilizando correlação simples, correlação 2D e PLSR estão dispostos nas Figuras 37, 38 e 39, respectivamente.

Os comprimentos de onda utilizados na modelagem usando correlação simples (Figura 37) foram: 826 e 721 nm, para SST e transparência, respectivamente. Ambos os modelos foram classificados como inadequados, por apresentarem valores de RPD < 1,4 além dos moderados coeficiente de determinação das variáveis clorofila-a ( $r = 0,74$ ) e SST ( $r = 0,58$ ).

Pode-se observar que o modelo subestima as concentrações de SST à medida que os teores dessa variável ficam mais altos e, o modelo de transparência, superestima valores de até 0,70 m e, a partir disso, passa a subestimar as demais profundidades.

Figura 37 - Relações entre os valores medidos e estimados de SST (A) e Transparência (B) usando o modelo de correlação simples

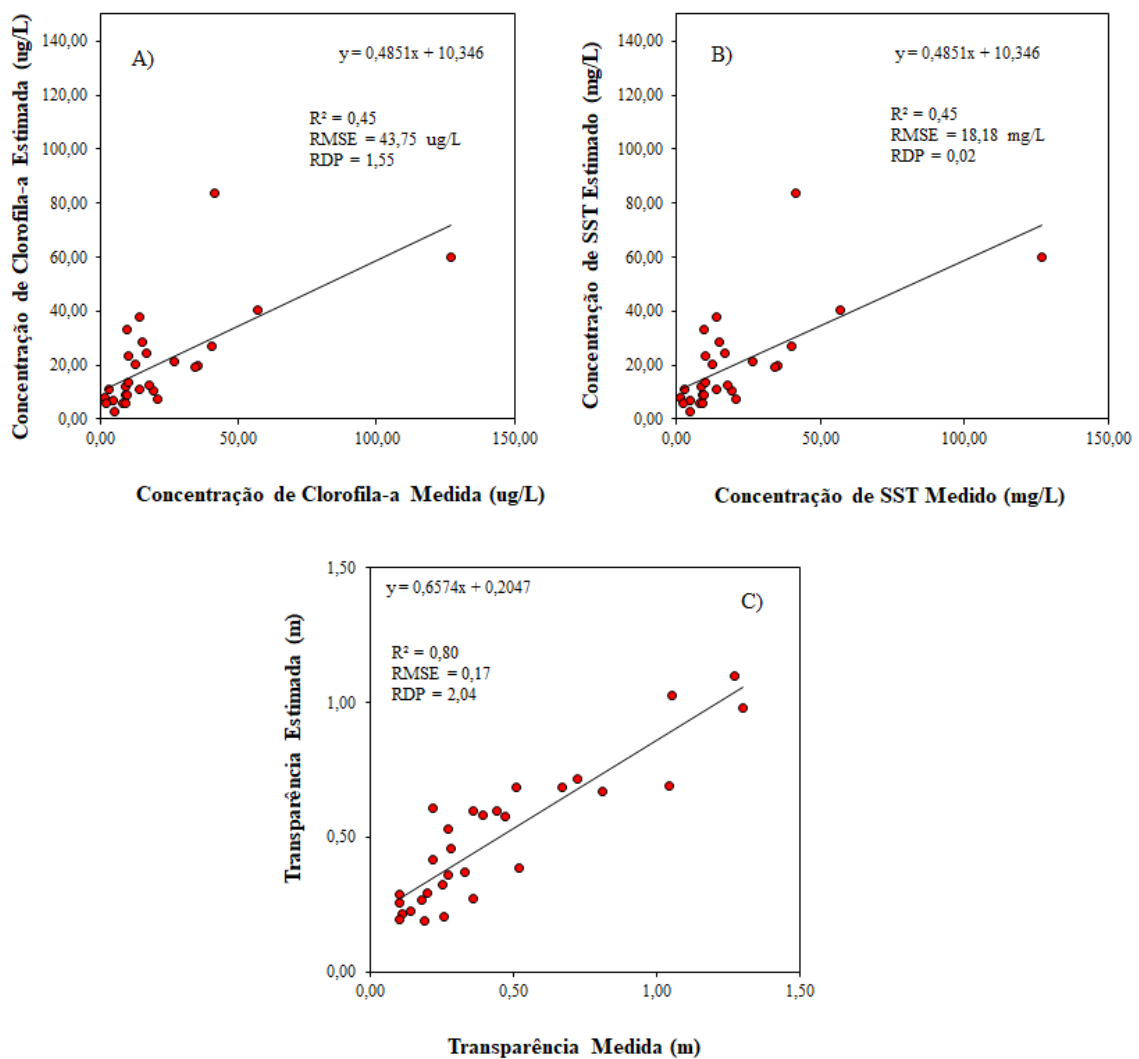


Fonte: Elaboração da autora.

O modelo de correlação 2D (Figura 38) foi criado a partir das razões entre as bandas 721/665, 830/400 e 410/712 para as variáveis clorofila-a, SST e transparência, respectivamente. Os modelos para predição de clorofila-a e SST foram considerados positivos, por apresentarem  $RPD < 1,4$  e moderado coeficiente de determinação de ambas as variáveis, com  $R^2 = 0,45$ . Por outro lado, o modelo para predição da transparência necessita de ajustes, segundo Chang *et al.* (2001), por apresentar  $RPD$  entre 1,4 e 2,0 e, assim como os demais, apresentou moderado coeficiente de determinação, com valores de  $R^2 = 0,80$ .

Verificou-se que os modelos de estimativa das variáveis limnológicas usando correlação 2D tendem a subestimar os valores dos parâmetros avaliados.

Figura 38 - Relações entre os valores medidos e estimados de Clorofila-a, (A), SST (B) e Transparência (C) usando o modelo de correlação 2D.



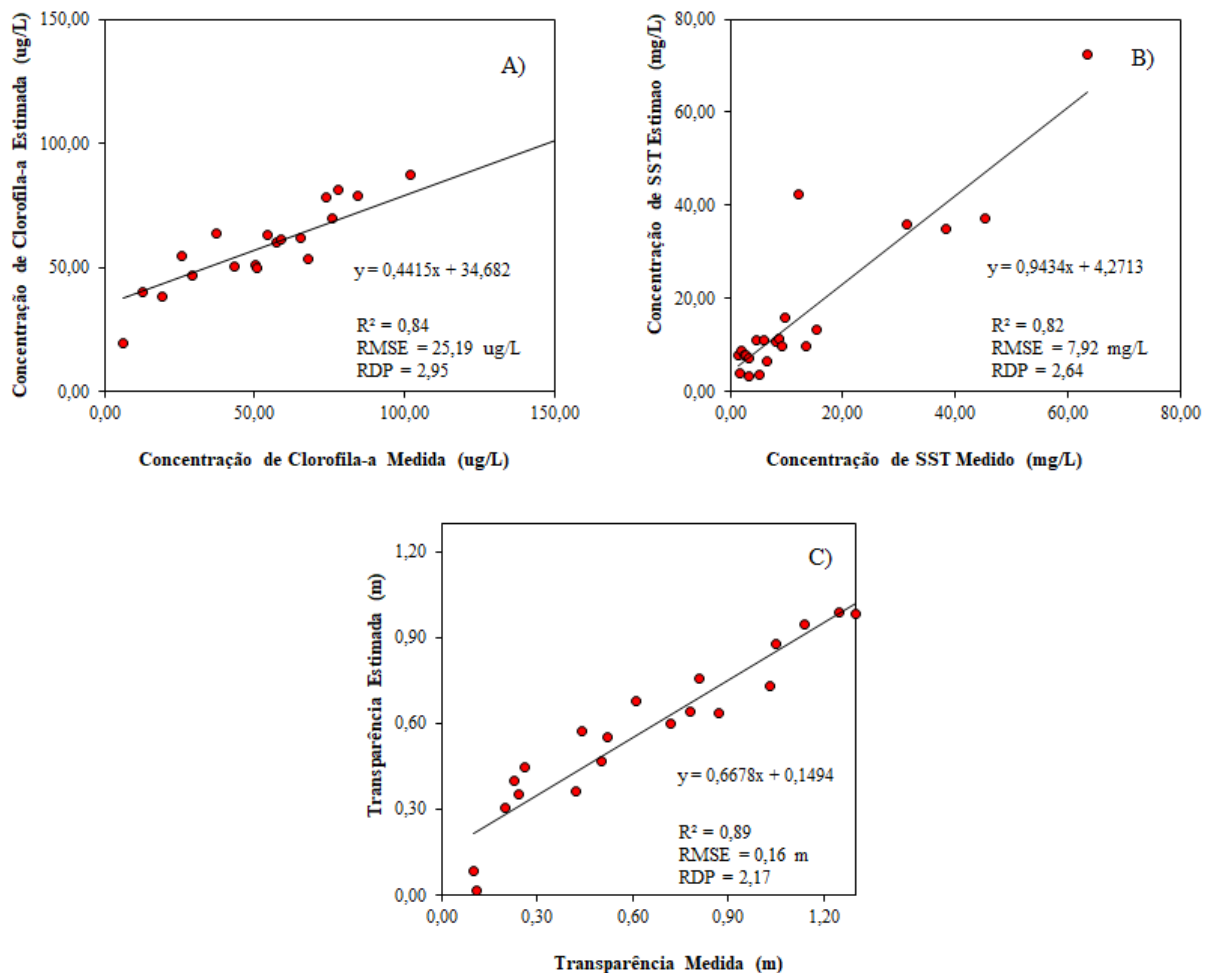
Fonte: Elaboração da autora.



As bandas espectrais utilizadas na modelagem para a clorofila-a, usando PLSR foram: 549, 599, 625, 671, 740 e 870 nm. Conforme Chang *et al.* (2001), o modelo é classificado como excelente, apresentando RPD > 2,00, além de um forte coeficiente de determinação ( $R^2 = 0,84$ ). Do mesmo modo, os modelos para predição de SST e transparência resultaram em classificação excelente e forte coeficiente de determinação, apresentando valor de RPD de 2,64 e 2,17 e  $R^2$  de 0,82 e 0,89, respectivamente.

Os modelos PLSR tendem a subestimar as variáveis clorofila-a e transparência, enquanto que os valores de SST acima de 60 mg/L, tendem a ser superestimados.

Figura 39 - Relações entre os valores medidos e estimados de clorofila-a (A), SST (B), Transparência (C) usando o modelo PLSR.



Fonte: Elaboração da autora.

Alguns autores afirmam que a diversidade de fatores internos e externos ao corpo hídrico podem dificultar as estimativas de clorofila-a quando se faz uso do método de correlação simples, uma vez que ele é aplicável quando uma variável independente afeta a variável dependente (DOWNING; CLARK, 2007; PALMER *et al.*, 2015; WATANABE *et al.*, 2017; DE CASTRO *et al.*, 2018; GROSS, 2019).

Gitelson (2000) afirma que diferentes abordagens devem ser aplicadas para um mesmo corpo d'água, sendo elaborado um algoritmo distinto para diferentes condições hídricas. Desse modo, pode-se inferir que não há um algoritmo padrão para a estimativa de variáveis limnológicas, conforme afirmaram Zheng; DiGiacomo (2017), ao ressaltarem que não há algoritmos universalmente aceitos para a predição de clorofila-a em águas costeiras utilizando-se reflectância espectral.

Ao utilizarem razão de bandas para estimar as concentrações de clorofila-a, Han; Rundquist (1997) observaram que para conjuntos de dados de diversas campanhas, o modelo não funcionou bem, diferente do que ocorreu ao utilizarem um conjunto de dados de cada data separadamente. Resultados semelhantes foram obtidos neste estudo, em que foram utilizados dados de reservatório distintos em diferentes datas e o modelo não apresentou bons resultados para o método da razão de bandas.

A quantidade de estudos visando a predição de SST é evidentemente inferior ao comparar-se com as pesquisas voltadas para a estimativa de clorofila. A especificidade dos sinais de sensoriamento remoto utilizado na determinação de SST é discutida por alguns autores (SINPELGAS *et al.*, 2006; DOXARAN *et al.*, 2009; BI *et al.*, 2011; MATTHEWS, 2011).

Ao utilizar modelo com uma única banda, Costa (2016) obteve  $RMSE = 6,43$  e, aplicando uma razão de bandas, o autor obteve  $RMSE = 4,78$ . Em ambos os modelos, os resultados diferem daqueles obtidos nesse estudo, em que foi encontrado  $RMSE = 0,51$  e  $18,18$  para o modelo de correlação simples e razão de bandas, respectivamente.

Bi *et al.* (2011) aplicaram um modelo empírico exponencial para estimar a concentração de SST a partir de imagens do sensor MODIS. Doxaran *et al.* (2009), também utilizaram sensor óptico para estimar as concentrações de SST em água, a partir de um modelo de razão de bandas.

Pinheiro (2015) utilizou PLSR para estimar as concentrações de SST em amostras de águas residuais utilizando espectrofotômetros e apresentou  $RMSE = 56,1$  resultado que diverge do obtido no presente estudo, para águas de reservatórios artificiais ( $RMSE = 7,92$ ). Pode-se atribuir tal diferença aos teores de SST em cada estudo, variando de 0 a 400 mg/L na pesquisa de Pinheiro (2015) e de 0 a 80 mg/L no presente estudo.

Lopes *et al.* (2014), estudando a transparência da água no reservatório de Orós, utilizando espectrorradiometria de campo encontrou coeficiente de determinação ( $R^2$ ) de 0,92 para um modelo usando correlação simples. Toniolo (2016) estudando a transparência da água no Lago Guaiuba, Rio Grande do Sul, a partir de imagens do sensor LISS-III/ResourceSat-2 e espectrorradiometria de campo encontrou  $R^2 = 0,71$ .

Santos (2016), utilizando uma banda do sensor LISS-III/ResourceSat-2 obteve coeficiente de determinação ( $R^2$ ) de 0,86 para predição da transparência do reservatório Passo Real, bem como apresentou alta correlação entre a variável transparência e os dados espectrais de campo utilizando um modelo de razão de bandas.

Na literatura, a utilização de PLSR é comumente utilizada na predição de variáveis relacionadas à vegetação, como nutrientes foliares e aos componentes do solo, contudo, poucos estudos aplicando o método PLSR para a estimativa de variáveis limnológicas foram identificados.

#### **4.6 Conclusão**

De maneira geral, a concentração de clorofila-a não apresentou fortes correlações com os fatores de reflectância espectral das amostras, por outro lado, os dados de SST e transparência se correlacionaram de maneira moderada com os dados espectrais da água.

Não foi possível a obtenção de um modelo de predição de clorofila-a usando o método da correlação simples, contudo foram criados modelos a partir dos métodos de correlação 2D e PLSR, que foram considerados inadequado e excelente, respectivamente.

Para a predição de SST foi possível o desenvolvimento de modelos de correlação simples e correlação 2D, os quais foram classificados como inadequados, além doo modelo de PLSR, que se apresentou como excelente.

Os modelos desenvolvidos para estimativa da transparência, assim como na predição de SST, foram considerados inadequados quando utilizados os métodos de correlação, contudo, aplicando-se os métodos de correlação 2D e PLSR obteve-se resultados classificados como excelentes.

O método PLSR mostrou-se uma ferramenta importante e com potencial para a predição das variáveis limnológicas clorofila-a, SST e transparência.

## 5 CONSIDERAÇÕES FINAIS

A espectroscopia de reflectância é uma forte alternativa às análises laboratoriais utilizadas para a obtenção das concentrações de nutrientes foliares e dos parâmetros de qualidade de água, demonstrando potencial no monitoramento da vegetação e dos corpos hídricos. Contudo, este estudo utiliza os dados espectrais dos reservatórios sem tratamento, sendo necessária a realização da remoção do efeito *sunglint* para testar a hipótese de que dessa forma, sejam obtidos melhores resultados.

## REFERÊNCIAS

ABDELMALIK, K.W. (2018). Role of statistical remote sensing for Inland water quality parameters prediction. Egypt. **J. Remote Sens.** Sp. Sci. 21, 193-200. Disponível em: <https://doi.org/10.1016/J.EJRS.2016.12.002>.

ABDEL-RAHMAN, E. M. *et al.* Estimating Swiss chard foliar macro- and micronutrient concentrations under different irrigation water sources using ground-based hyperspectral data and four partial least squares (PLS)-based (PLS1, PLS2, SPLS1 and SPLS2) regression algorithms. **Computers and Electronics in Agriculture**, v. 132, p. 21-33, 2017.

ABDEL-RAHMAN, E.M.; AHMED, F. B.; BERG, M.V.D. Estimation of sugarcane leaf nitrogen concentration using in situ spectroscopy. **International Journal of Applied Earth Observation and Geoinformation**. Enschede v. 12, p. 52-57, 2010.

ABDULRIDHA, J.; BATUMAN, O.; AMPATZIDIS, Y. UAV-based remote sensing technique to detect citrus canker disease utilizing hyperspectral imaging and machine learning. **Remote Sens.** 2019, v. 11, p. 1373.

ALMEIDA, E. L. DE *et al.* Airborne hyperspectral remote sensing applied to determine the texture of a Cambisol in the Chapada do Apodi, Ceará. **Revista Ciência Agronômica**, v. 52, n. 2, p. 1-10, 2021.

APHA – AMERICAN PUBLIC HEALTH ASSOCIATION; AWWA – AMERICAN WATER WORKS ASSOCIATION; WEF – WATER ENVIRONMENT FEDERATION. **Standard methods for the examination of water and wastewater**. 21<sup>a</sup>. ed., Washington: APHA/AWWA/WEF, 2005, p. 1268.

ARAÚJO, E, M. **Investigação do processo de geração de escoamento usando análise estatística multivariada em uma grande bacia semiárida: o caso do Orós**, f. 87, 2013, Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal do Ceará, Fortaleza, 2013.

ASSEMBLEIA LEGISLATIVA DO CEARÁ. **Caderno regional da bacia do Curu / Conselho de Altos Estudos e Assuntos Estratégicos**. Assembleia Legislativa do Estado do Ceará. Eudoro Walter de Santana (Coordenador) – Fortaleza: INESP, 2009, p. 11: il – (Coleção Cadernos Regionais do Pacto das Águas, v. 4).

AUGUSTO-SILVA, P. B.; OGASHAWARA, I.; BARBOSA, C, C.; DE CARVALHO, L, A.; JORGE, D, S.; FORNARI, C, I.; E. STECH, J. L. 2014. Analysis of MERIS Reflectance Algorithms for Estimating Chlorophyll-a Concentration in a Brazilian Reservoir. **Remote Sensing**. 6 (12). 11689-11707.

BARBOSA, C, C, F. **Sensoriamento remoto da dinâmica de circulação da água do sistema planície de Curuai/Rio Amazonas**, Tese de Doutorado, São José dos Campos: Instituto Nacional de Pesquisas Espaciais (INPE), 2005, p. 282.

BARBOSA, C. Princípios físicos do sensoriamento remoto aquático. *In: Introdução ao Sensoriamento Remoto de Sistemas Aquáticos: Princípios e aplicações*. INPE, 2019, p. 24-52.

BARBOSA, M. R. *et al.* Geração e desintoxicação enzimática de espécies reativas de oxigênio em plantas. **Ciência Rural**, Santa Maria, v. 44, n. 3, p. 453-460, mar. 2014.

BERNARDO, N.; WATANABE, F.; RODRIGUES, T.; ALCÂNTARA, E. **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*, v. 4, p. 68-82, 2016.

BERNARDO, Nariane Marshelle Ribeiro. **Análise do potencial do sensor oli (operational land imager) a bordo do landsat-8 em estimar a concentração de sólidos totais em suspensão no reservatório de barra bonita**. 2015, f. 118. Dissertação (Mestrado em Ciências Cartográficas) – Universidade Estadual Paulista, Presidente Prudente, São Paulo, 2015.

BI, N.; YANG, Z.; WANG, H.; FAN, D.; SUN, X.; LEI, K. Seasonal variation of suspended-sediment transport through the Southern Bohai Strait. **Estuarine, Coastal and Shelf Science**, v. 93, n. 3, p. 239-247, 2011.

BOSS, E. **Scattering**: definition. *Ocean optics*. (2013). Disponível em: <http://www.oceanopticsbook.info/view/scattering/definitions>. Acesso em: 15 mar. 2022.

BRANDÃO, Z. N. **Estimativa da produtividade e estado nutricional da cultura do algodão irrigado via técnicas de sensoriamento remoto**. Tese (Doutorado em Recursos Naturais) – Universidade Federal de Campina Grande, Campina Grande, f. 152, 2009.

BÜLL L.T. *et al.* **Doses de fósforo e zinco na cultura do alho em condições de casa de vegetação**. *Bragantia*, Campinas, v. 67, n. 4, p. 941-949, 2008.

CABRAL, J.B.P.; PEREIRA FILHO, W. Técnicas de sensoriamento remoto aplicada análise da concentração de sólidos em suspensão na UHE Foz do Rio Claro – GO. **Revista Brasileira de Geografia Física** v. 11, n. 4, p. 1526-1541, 2018.

CALOU, V. B. C. *et al.* (2020). The use of UAVs in monitoring yellow sigatoka in banana. **Biosystems Engineering**, 193, 115-125. Disponível em: <https://doi.org/10.1016/j.biosystemseng.2020.02.016>.

CAMO Analytics AS, Unscrambler. Oslo, Norway. v. trial, 2021. Disponível em: <https://www.camo.com/unscrambler/>. Acesso em: 09 agosto 2021.

CAMPANHARO, M. *et al.* Doses de níquel em feijão caupi cultivado em dois solos. **Revista Caatinga**, 26(4), p. 10-18, 2013.

CAMPELO, D. H. **Uso do sensoriamento remoto para diagnóstico nutricional na cultura do milho irrigado**. Tese (doutorado) – Universidade Federal do Ceará, p. 182, 2018.

CAPOLUPO, A. *et al.* Estimating Plant Traits of Grasslands from UAV-Acquired Hyperspectral Images: A Comparison of Statistical Approaches. **ISPRS International Journal Geo-Inf** 4: 2792-2820, 2015. doi: 10.3390/ijgi4042792.

CARVALHO, A. P. F de. **Estudo de características foliares de espécies de lenhosas de cerrado e sua relação com os espectros de refletância**. Tese (Doutorado em Ecologia) – Universidade de Brasília. Brasília, p. 142, 2005.

CARVALHO, L. A. S de; BARBOSA, C. C.F.; NOVO, E. M. L. de M. Ajuste de bandas de modelos empíricos de estimativa de clorofila aplicados à região da planície de inundação do Lago Grande Curuai – PA. In: Simpósio Brasileiro de Sensoriamento Remoto, p. 16, 2013. Foz do Iguaçu. **Anais [...]** Foz do Iguaçu: INPE, 2013.

CARVALHO, M.; LINO-NETO, T.; ROSA E.; CARNIDE, V. Cowpea: a legume crop for a challenging environment. **J Sci Food Agric**. 2017, Oct 97(13): 4273-4284. doi: 10.1002/jsfa.8250. Epub 2017 Mar 17. PMID: 28182297.

CAVALCANTE, *et al.* Produção de maracujazeiro amarelo no solo com calcário e potássio sob irrigação com água salina. **Irriga**, Botucatu, v. 23, n. 4, p. 727-740, outubro-dezembro, 2018.

CHANG, C. W.; LAIRD, D. A.; MAUSBACH, M. J.; HURBURGH JR., C. R. Near-Infrared Reflectance Spectroscopy – Principal Components Regression Analyses of Soil Properties. **Soil Science Society of America Journal**, [s.l.], v. 65, n. 2, p. 480–490, 2001.

CHEN, Z.; WANG, X. Model for estimation of total nitrogen content in sandalwood leaves based on nonlinear mixed effects and dummy variables using multispectral images. **Chemometrics and Intelligent Laboratory Systems**, v. 195, n. October, p. 103874, 2019.

CHICATI, M. S. **Resposta espectral da cultura do feijão e sua relação com parâmetros biofísicos em diferentes doses de nitrogênio**/Mônica Sacioto Chicati. – Maringá, 2015, f. 93. Dissertação (Mestrado em Agronomia) – Universidade Estadual de Maringá.

CHU, X. *et al.* Comparison of different hyperspectral vegetation indices for estimating canopy leaf nitrogen accumulation in rice. **Agronomy Journal**, v. 106, n. 5, p. 1911-1920, 2014.

CICERELLI, R. E.; GALO, M. L. B. T. Sensoriamento remoto multifonte aplicado na detecção do fitoplâncton em águas interiores. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 19, n. 3, p. 259-265, 2015.  
**Ciência Rural**, v. 39, n. 9, dez. 2009.

CLARK, D.; MAYLAND, H.; LAMB, R. Mineral analysis of forages with near infrared reflectance spectroscopy 1. **Agron. J.** 79, 485-490, 1987.

COELHO, C.; HEIM, B.; FOERSTER, S.; BROSINSKY, A.; DE ARAÚJO, J.C., 2017. In situ and satellite observation of CDOM and chlorophyll-a dynamics in small water surface reservoirs in the brazilian semiarid region, **Water** (Switzerland) 9. Disponível em: <https://doi.org/10.3390/w9120913>.

COMINO *et al.* **Near-infrared spectroscopy and X-ray fluorescence data fusion for olive leaf analysis and crop nutritional status determination**. *Talanta*, p. 676-684, 2018.

COSTA, A. M. **Estimativa da concentração de sólidos suspensos em águas opticamente complexas a partir de sensores remotos**. 2016, f. 60. Dissertação (Mestrado em Recursos Hídricos e Saneamento) – Universidade Federal de Alagoas, Maceió, 2016.

CURRAN, P. J. *et al.* **The effect of a red leaf pigment on the relationship between red edge and chlorophyll concentration**, 1991.

DALL'OLMO, G.; GITELSON, A. A. Effect of bio-optical parameter variability on the remote estimation of chlorophyll-a concentration in turbid productive waters: experimental results. **Appl, Opt**, v. 44, p. 412-422, 2005.

DAUGHTRY, C. S. T.; WALTHALL, C. L.; KIM, M. S.; DE COLSTOUN, E. B.; MCMURTREY, J. E. Estimating corn leaf chlorophyll concentration from leaf and canopy reflectance. **Remote sensing of Environment**, v. 74, n. 2, p. 229-239, 2000.

DE CASTRO, P. H. M.; PEREIRA, A. C. de F.; BARROS, M. V. Modelos empíricos para inferência de componentes opticamente ativos em ambientes lóticos e semilóticos do rio Tibagi/PR, aplicados às imagens Landsat 8/OLI. **RAEGA O Espaço Geográfico em Análise**. Curitiba, v. 43. Temático de Geotecnologias, p. 75-92, 2018.

DEKKER, A.; PETERS, S. The use of the Thematic Mapper for the analysis of eutrophic lakes: a case study in the Netherlands. **Int. J. Remote Sens.**, v. 14, n. 5, 799-821, 1993.

DOURADO NETO, D.; FANCELLI, A. L. **Produção de feijão**. Guaíba: Agropecuária, p. 385, 2000.

DOWNING, D; CLARK, J. **Estatística Aplicada**. 2ª ed. São Paulo: Saraiva, 2007.

DOXARAN, D.; FROIDEFOND, J. M.; LAVENDER, S.; CASTING, P. Spectral signature of highly turbid Waters: Application with SPOT data to quantify suspended particulate matter concentrations. **Remote Sensing of Environment**, v. 81, p. 149-161, 2002b.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Sistema brasileiro de classificação de solos**. Brasília: EMPRAPA. Produção de Informação. EMPRAPA Solos, p. 412, 1999.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Sistema Brasileiro de Classificação de Solos**. 4ª ed. Rio de Janeiro: Centro Nacional de Pesquisa de Solos, p. 353, 2018.

EPIPHANIO, J.C.N.; GLERIANI, J.M.; FORMAGGIO, A.R.; RUDORFF, B.F.T. **Índices de vegetação no sensoriamento remoto da agricultura do feijão**. Pesquisa Agropecuária Brasileira, Brasília, v. 31, n. 6, p. 445-454, 1996.

FERREIRA, M. E.; SILVA, J. R. **Anais. XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR**, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE, p. 6727-6733, 2011.

FLETCHER, R. S.; REDDY, K. N. Random forest and leaf multispectral reflectance data to differentiate three soybean varieties from two pigweeds. **Computers and Electronics in Agriculture**, v. 128, p. 199-206, 2016.



FRANÇA, J. M. B.; WACHHOLZ, F.; NETO, J. A. C.; PAULINO, W. D. Comportamento das variáveis qualitativas do açude Pereira de Miranda – Pentecoste/CE, no período de estiagem. **Revista Geociências**, v. 32. n. 4. p. 586-599, 2013.

GALVEZ-SOLA, L. *et al.* Rapid estimation of nutritional elements on citrus leaves by near infrared reflectance spectroscopy. **Frontiers in Plant Science**, v. 6, n. JULY, 2015.

GAMA, T. *et al.* Hyperspectral imaging for non-destructive prediction of total nitrogen concentration in almond kernels. **Acta Horti**, 2018, 1219, 259-264. DOI: 10.17660/ActaHortic.2018.1219.40.

GE, Y. *et al.* High-throughput analysis of leaf physiological and chemical traits with VIS–NIR–SWIR spectroscopy: a case study with a maize diversity panel. **Plant methods**, v. 15, n. 1, p. 66, 2019.

GHOLIZADEH, M. H.; MELESSE, A. M.; REDDI, L. A Comprehensive review on water quality parameters estimation using remote sensing techniques. **Sensors**, 1298, p. 2-43, 2016.

GITELSON, A. A.; YACOBI, Y. Z.; SCHALLES, J. F.; RUNDQUIST, D. C.; HAN, L.; STARK, R.; & ETZION, D. Remote estimation of phytoplankton density in productive waters, Archive Hydrobiological Special Issue. **Advances in Limnology**, 55, 121-136, 2000.

GONG, X. *et al.* Cerium relieves the inhibition of photosynthesis of maize caused by manganese deficiency. **Biological Trace Element Research**, Clifton, v. 141, n. 1/3, p. 305-316, June 2011.

GONZÁLEZ-MARTÍN, I.; HERNÁNDEZ-HIERRO, J. M.; GONZÁLEZ-CABRERA, J. M. Use of NIRS technology with a remote reflectance fibre-optic probe for predicting mineral composition (Ca, K, P, Fe, Mn, Na, Zn), protein and moisture in alfalfa. **Analytical and Bioanalytical Chemistry**, v. 387, n. 6, p. 2199-2205, 2007.

GROSS, J. A. **Efeitos de diferentes componentes opticamente ativos na reflectância da água para a estimativa remota das concentrações de clorofila-a fitoplanctônica**, 2019, f. 172. Tese (Doutorado) – Universidade Federal de Santa Maria, RS, 2019.

HALGERSON, J.L. *et al.* Nearinfrared reflectance spectroscopy prediction of leaf and mineral concentrations in alfalfa. **Agron. J.** 96, 344–351, 2004.

HAMADA, Emília. **Desenvolvimento fenológico do trigo (cultivar iac 24 - tucuruí), comportamento espectral e utilização de imagens noaa-avhrr**, 2000, f. 175, Tese (Doutorado em Engenharia Agrícola) – Universidade Estadual de Campinas, Campinas, 2000.

HAN, L. Spectral Reflectance with Varying Suspended Sediment Concentrations in Clear and Algae-Laden Waters. **Photogrammetric Engineering & Remote Sensing**. Vol. 63, n. 6, June 1997, p. 701-705, 1997.

INPE – Instituto Nacional de Pesquisas Espaciais. **Processamento Digital de Imagens**. Disponível em: <[http://www.dpi.inpe.br/~carlos/Academicos/Cursos/Pdi/pdi\\_cores.html](http://www.dpi.inpe.br/~carlos/Academicos/Cursos/Pdi/pdi_cores.html)>, Acesso em: 19 dez 2021.

JENSEN, J. R. **Sensoriamento Remoto do ambiente**: uma perspectiva em recursos terrestres, 2ª ed. São José dos Campos: Parênteses, 2009, p. 672.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente**: Uma Perspectiva em Recursos Terrestres. São José dos Campos-SP: Parêntese, 2011, p. 582.

JIANG, D.; MATSUSHITA, B.; SETIAWAN, F.; VUNDO, A. (2019). An improved algorithm for estimating the Secchi disk depth from remote sensing data based on the new underwater visibility theory. *ISPRS J. Photogramm. Remote Sens.* 152, 13-23. <https://doi.org/10.1016/J.ISPRSJPRS.2019.04.002>.

JONES, J. G. **A guide to methods for stimating microbial numbers and biomass in fresh waters**. London: Fresh Waters Biological Association, 1979.

KEMKER, C. Turbidity, Total Suspended Solids and Water Clarity, *Fundamentals of Environmental Measurements*, **Fondriest Environmental**, Inc, 2014. Disponível em: <http://www.fondriest.com/environmentalmeasurements/parameters/waterquality/turbidity-total-suspended-solids=water-clarity/>. Acesso em: 22 abr, 2021.

KIRK, J, T, O. **Light and photosynthesis in aquatic ecosystems**, 3rd ed, New York: Cambridge University Press, 2011.

KÖPPEN, W. **Climatologia**: com um estúdio dilos climas de La tierra, Mexico: Fondo de Cultura Economica, 1948.

LE, C. *et al.* A four-band semi-analytical model for estimating chlorophyll a in highly turbid lakes: The case of Taihu Lake, China. **Remote Sensing of Environment**, v. 113, n. 6, p. 1175-1182, 2009.

LI, Q. *et al.* Enhancement of endogenous SA accumulation improves poor-nutrition stress tolerance in transgenic tobacco plants overexpressing a SA-binding protein gene. **Plant Science**, v. 292, n. December 2019, p. 110384, 2020.

LI, Z. *et al.* Comparison of Four Chemometric Techniques for Estimating Leaf Nitrogen Concentrations in Winter Wheat (*Triticum Aestivum*) Based on Hyperspectral Features. **Journal of Applied Spectroscopy** 83(2):240-247, 2016. Russian Original. DOI:10.1007/s10812-016-0276-3.

LIANG, S. **Quantitative remote sensing of land surfaces**. John Wiley & Sons, 2005.

LIAO, H. *et al.* Rapid diagnosis of nutrient elements in fingered citron leaf using near infrared reflectance spectroscopy. *J. Plant Nutr.* 35, 1725-1734, 2012.

LING, B. *et al.* Hyperspectral analysis of leaf pigments and nutritional elements in tallgrass prairie vegetation. **Frontiers in Plant Science**, v. 10, n. February, p. 1-13, 2019.

LIU, J.; HAN, J.; XIE, J.; WANG, H.; TONG, W.; BA, Y. Assessing heavy metal concentrations in earth-cumulic-orthicanthrosols soils using Vis-NIR spectroscopy transform coupled with chemometrics. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, [s.l.], v. 226, 117639, 2020. DOI: <https://doi.org/10.1016/j.saa.2019.117639>.

- LIU, J.; MENG, Y.; CHEN, J.; LU, F.; MA, Y.; CHEN, B.; OOSTERHUIS, D. M. Effect of late planting and shading on cotton yield and fiber quality formation. **Field Crops Research**, 183, p.1-13, 2015.
- LIU, L.; SONG, B.; ZHANG, S.; & LIU, X. A Novel Principal Component Analysis Method for the Reconstruction of Leaf Reflectance Spectra and Retrieval of Leaf Biochemical Contents. **Remote Sensing**, v. 9, n. 11, p. 1113, 2017.
- LONARDI, S. *et al.* The genome of cowpea (*Vigna unguiculata* [L.] Walp.). **Plant J**, 98: 767-782, 2019. Disponível em: <https://doi.org/10.1111/tpj.14349>.
- LONDE, L. R. **Comportamento espectral do fitoplâncton de um reservatório brasileiro eutrofizado** – Ibitinga (SP). (2008), p. 223. Tese (Doutorado em Sensoriamento Remoto). Instituto Nacional de Pesquisas Espaciais, 2008.
- LONDE, L. R.; NOVO, E. M. M. L.; CALIJURI, M. C. **Aplicação de técnicas de sensoriamento remoto ao estudo de fitoplâncton de águas interiores**. *In*: Novas tecnologias para o monitoramento e estudo de reservatórios hidrelétricos e grandes lagos. Organizadores: Enner Herenio Alcântara; Evlyn Márcia Leão de Moraes Novo; José Luiz Stech. Rio de Janeiro, Editora Parêntese, p. 219-253, 2011.
- LOPES, F. B.; ANDRADE, E. M.; MEIRELES, A. C. M.; BECKER, H.; BATISTA, A. A. Assessment of the water quality in a large reservoir in semiarid region of Brazil, **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 18, p. 437-445, 2014a.
- LOPES, F. B.; BARBOSA, C. C. F.; NOVO, E. M. L. M.; CARVALHO, L. A. S.; ANDRADE, E. M.; TEIXERA, A. S. Modeling the concentration of chlorophyll-a in a continental aquatic ecosystem of the Brazilian semiarid region based on remote sensing. **Revista Ciência Agronômica**, v. 52, p. e20207210, 2021.
- LOPES, F.B.; BARBOSA, C. C. F.; NOVO, E. M. L. M.; ANDRADE, E. M.; CHAVES, L. C. G. Modelagem da qualidade das águas a partir de sensoriamento remoto hiperespectral. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v. 18, p. 13-19, 2014b.
- LOPES, Fernando Bezerra. **Uso de sensoriamento remoto como suporte ao monitoramento da qualidade das águas superficiais da região semiárida do Brasil**. (2013), f. 202. Tese (Doutorado em Engenharia Agrícola) – Departamento de Engenharia Agrícola, Universidade Federal do Ceará, Fortaleza, 2013.
- LORENZZETI, J. A. **Princípios físicos de sensoriamento remoto**. São Paulo: Blucher, 2015.
- MAGALHÃES, A. C. M. de. **Adubação orgânica com base na taxa de mineralização de nutrientes do composto orgânico**. 2018, f. 83. Dissertação (Mestrado em Ciência do Solo) – Universidade Federal do Ceará, Fortaleza, 2018.
- MALAVOLTA, E. 2006. **Manual de nutrição mineral de plantas**. São Paulo: Editora Agronômica Ceres, p. 638.
- MALMIR, M. *et al.* Prediction of macronutrients in plant leaves using chemometric analysis and wavelength selection. **J. Soils Sediments**, 2019.

- MANTOVANI, J, E. **Comportamento espectral da água: faixas espectrais de maior sensibilidade ao fitoplâncton na presença de matéria orgânica dissolvida e matéria inorgânica particulada.** 1993, f 119. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos.
- MAO, H. *et al.* Nondestructive measurement of total nitrogen in lettuce by integrating spectroscopy and computer vision. **Scientia Horticulturae**, 184, 1-7, 2015.
- MARSCHNER, P. Marschner's mineral nutrition of higher plants. 3<sup>a</sup> ed. **Academic Press**, p. 649, 2012.
- MARTINEZ, H. *et al.* (2003). Faixas críticas de concentrações de nutrientes e avaliação do estado nutricional de cafeeiros em quatro regiões de Minas Gerais. **Pesquisa Agropecuária Brasileira**, 38(6), 703-713. Disponível em: <https://doi.org/10.1590/s0100-204x2003000600006>.
- MATSUSHITA, B. *et al.* A hybrid algorithm for estimating the chlorophyll-a concentration across different trophic states in Asian inland waters, **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 28-37, 2015.
- MATTHEWS, M. A current review of empirical procedures of remote sensing in inland and near-coastal transitional Waters. **International Journal of Remote Sensing**, n. 32, p. 6855-6899, 2011.
- MEE, C. Y.; BALASUNDRAM, S. K. & MOHD HANIF, A. H. Detecting and monitoring plant nutrient stress using remote sensing approaches: A review. **Asian Journal of Plant Sciences**, 16(1), 1-8, 2017. Disponível em: <https://doi.org/10.3923/ajps.2017.1.8>.
- MENESES, P. R.; NETTO, J. S. M. **Sensoriamento remoto: reflectância dos alvos naturais.** Brasília, DF: UnB; Planaltina: Embrapa Cerrados, 2001.
- MILTON, E. J. Principles of field spectroscopy. **International Journal of Remote Sensing**, v. 8, n. 12, p. 1807-1827, 1987.
- MILTON, J. S. **Statistical methods in the biological and health sciences.** 2<sup>a</sup> ed. New York: McGraw-Hill, p. 526, 1992.
- MOBLEY, C. D. **Light and water Radiative transfer in natural waters.** Academic Press, p. 593, 2004.
- MOREIRA, L. C. J.; TEIXEIRA, A. dos S. & GALVÃO, L. S. (2014). Laboratory salinization of Brazilian alluvial soils and the spectral effects of gypsum. **Remote Sensing**, 6(4), 2647-2663. Disponível em: <https://doi.org/10.3390/rs6042647>.
- MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e metodologias de aplicação.** Viçosa, MG: Ed. UFV, 4<sup>a</sup> edição, p. 422, 2011.
- MUÑOZ-AMATRIÁN, M. *et al.* Genome resources for climate-resilient cowpea, an essential crop for food security. **Plant Journal**. 89, 1042-1054, 2017. DOI: 10.1111/tpj.13404.

NANNI, M. R. **Comportamento espectral de milho submetido a diferentes doses de nitrogênio.** (2015). January.

NETO, M. C. P. Perspectivas da açudagem no semiárido brasileiro e suas implicações na região do Seridó potiguar. **Sociedade & Natureza**, [s, l,], v. 29, n. 2, p. 285-294, 2017.

NETO, O. C. R. *et al.* Hyperspectral remote sensing for detecting soil salinization using ProSpecTIR-VS aerial imagery and sensor simulation. **Remote Sensing**, v. 9, n. 1, 2017.

NO, I. June; H.-C.; SON, S.; KIM, Y.H.; KHIM, J.S.; NAM, J.; CHANG, W.K.; LEE, J.-H.; LEE, C.-H.; RYU, J. (2017). **Remote sensing and water quality indicators in the Korean West coast:** Spatio-temporal structures of MODIS-derived chlorophyll-a and total suspended solids. *Mar. Pollut. Bull.* 121, 425–434. Disponível em: <https://doi.org/10.1016/J.MARPOLBUL.2017.05.026>.

NOVO, E. M. L. de MORAES, **Sensoriamento remoto: princípios e aplicações/** Evlyn M. L. de Moraes Novo, 4ª ed, São Paulo: Blucher, 2010.

NOVO, E. M. L. M. **Sensoriamento remoto: princípios e aplicações**, 3ª ed., São Paulo: Blucher, p. 363, 2008.

NOVO, E. M. L. M; PONZONI, F. J. **Introdução ao Sensoriamento Remoto, Instituto Nacional de pesquisas Espaciais, Divisão de Sensoriamento Remoto.** (2001). Disponível em: < [http://www.dpi,inpe.br/Miguel/AlunosPG/Jarvis/SR\\_DPI7.pdf](http://www.dpi,inpe.br/Miguel/AlunosPG/Jarvis/SR_DPI7.pdf) >. Acesso em: 19 fev 2022.

O'CONNELL, J. L.; BYRD, K. B.; KELLY, M. **Remotely-sensed indicators of N-related biomass allocation in Schoenoplectus acutus.** PLoS ONE, v. 9, n. 3, 2014.

OGASHAWARA, I. *et al.* Interactive Correlation Environment (ICE) – A Statistical Web Tool for Data Collinearity Analysis. **Remote Sens.** 6, 3059-3074, 2014.

OLIVEIRA, D. M. de; FONTES, L. M.; PASQUINI, C. Comparing laser induced breakdown spectroscopy, near infrared spectroscopy, and their integration for simultaneous multi-elemental determination of micro- and macronutrients in vegetable samples. **Analytica Chimica Acta**, v. 1062, p. 28-36, 2019.

OLIVEIRA, M. R. R. DE. *et al.* (2020). Reflectance spectrometry applied to the analysis of nitrogen and potassium deficiency in cotton. **Revista Ciência Agronômica**, 1-10. <https://doi.org/10.5935/1806-6690.20200074>.

OSCO, L. P. *et al.* A machine learning framework to predict nutrient content in valencia-orange leaf hyperspectral measurements. **Remote Sensing**, v. 12, n. 6, 2020.

OSCO, L. P. *et al.* Improvement of leaf nitrogen content inference in Valencia-orange trees applying spectral analysis algorithms in UAV mounted-sensor images. **International Journal of Applied Earth Observation and Geoinformation**, v. 83, n. July, p. 101907, 2019.

PALÁCIO, H. A. Q.; ANDRADE, E. M.; LOPES, F. B.; ALEXANDRE, D. M. B.; ARRAES, F. D. D. Similaridade da qualidade das águas superficiais da bacia do Curu, Ceará.

PALMER, S. C. J.; KUTSER, T.; HUNTER, P. D., Remote sensing of inland waters: Challenges, progress and future directions, **Remote Sensing of Environment**, v. 157, p. 1-8, 2015.

PAPA, R. de A. *et al.* Comportamento espectral da cultura do feijão, por meio de dados obtidos por espectroradiometria e imagem ASTER, no Distrito Federal. **Anais XV Simpósio Brasileiro de Sensoriamento Remoto – SBSR**, p. 4696-4703, 2010.

PEDROSA, M.V. B. **Qualidade fisiológica de sementes de feijão (*Phaseolus vulgaris* L.) em função da maturação e adubação com enxofre, nitrogênio e zinco**. Dissertação (Mestrado em Produção Vegetal) – Universidade Federal do Espírito Santo. Espírito Santo, p. 87, 2017.

PENG, Z. *et al.* **Estimating total leaf chlorophyll content of gannan navel orange leaves using hyperspectral data based on partial least squares regression**. IEEE. Access 2019, 7, 155540-155551.

PEREIRA, A. C. F.; GALO, M. L. B. T.; VELINI, E. D. 2015. **Inferência da transparência da água** – reservatório de Itupararanga/ SP, a partir de imagens multiespectrais IKONOS e espectrorradiometria de campo. *Revista Brasileira de Cartografia* 1, n. 63. 179-190. Disponível em: <http://www.lsie.unb.br/rbc/index.php/rbc/article/view/370/362>. Acesso em: 15 jul. 2021.

PEREIRA, F. J. S.; COSTA, C. A. G.; FOERSTER, S.; BROSINSKY, A.; DE ARAÚJO, J.C. (2019) Estimation of suspended sediment concentration in an intermittent river using multi-temporal high-resolution satellite imagery, **Int, J, Appl, Earth Obs, Geoinf**, 79, 153-161, <https://doi.org/10.1016/j.jag.2019.02.009>.

PETISCO, C. *et al.* Use of near-infrared reflectance spectroscopy in predicting nitrogen, phosphorus and calcium contents in heterogeneous woody plant species. **Analytical and Bioanalytical Chemistry**, v. 382, n. 2, p. 458-465, 2005.

PINHEIRO, A. *et al.* Relação Entre o Uso do Solo e a Qualidade da Água em Bacia Hidrográfica Rural no Bioma Mata Atlântica. **Revista Brasileira de Recursos Hídricos**. v. 19, n. 3, p. 127-139, 2014.

PINHEIRO, A. S. **Intercalibração de espectrofotômetros UV-VIS em monitorização de redes de drenagem** (2015), f. 100. Dissertação (Mestrado em Engenharia do Ambiente) – Universidade Universidade de Lisboa – Instituto Superior Técnico, 2015.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. Edição 2010. São José dos Campos, SP: Editora Parêntese, p. 136, 2009.

PONZONI, F. J.; SHIMBUKURO, Y. E.; KUPPLICH, T. M. **Sensoriamento Remoto da Vegetação**. São José dos Campos, SP, Oficina de Textos, 2ª edição, p. 176, 2012.

PONZONI, F.; SHIMABUKURO, Y. E.; KUPPLICH, T. M. **Sensoriamento remoto no estudo da vegetação**. São José dos Campos: Parêntese, 2007.

PRANANTO, J. A.; MINASNY, B.; WEAVER, T. Near infrared (NIR) spectroscopy as a rapid and cost-effective method for nutrient analysis of plant leaf tissues. 1<sup>a</sup> ed. [s.l.] **Elsevier Inc.**, v. 164, 2020.

PULLANAGARI, R. R.; KERESZTURI, G.; YULE, I. J. Mapping of macro and micro nutrients of mixed pastures using airborne AisaFENIX hyperspectral imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 117, p. 1-10, 2016.

RAMOELO, A. *et al.* Non-linear partial least square regression increases the estimation accuracy of grass nitrogen and phosphorus using in situ hyperspectral and environmental data. **ISPRS J. Photogrammetry Remote Sens**, 82, 27-40, 2013.

ROSSATO, O. B.; ANDRÉ- SANCHEZ, P.; GUERRA, S. P. S.; CRUSCIOL, C. A. C. **Sensores de reflectância e fluorescência na avaliação de teores de nitrogênio, produção de biomassa e produtividade do algodoeiro.** Pesquisa Agropecuária Brasileira. Brasília, v. 47, n. 8, p. 1133-1141, 2012.

RUNDQUIST, D. C.; HAN, L.; SCHALLES, J. F.; PEAKE, J. S. Remote measurement of algal chlorophyll in surface waters: the case for the first derivative of reflectance near 690 nm. **Photogrammetric Engineering & Remote Sensing**, v. 62, n. 2, p. 195-200, 1996.

SANTOSO, H. *et al.* Predicting oil palm leaf nutrient contents in kalimantan, indonesia by measuring reflectance with a spectroradiometer. **International Journal of Remote Sensing**, v. 40, n. 19, p. 7581-7602, 2019.

SAYERS, M. J.; BOSSE, K. R.; SHUCHMAN, R. A.; RUBERG, S. A.; FAHNENSTIEL, G. L.; LESHKEVICH, G. A.; STUART, D. G.; JOHENGEN, T. H.; BURTNER, A. M.; PALLADINO, D. (2019) Spatial and temporal variability of inherent and apparent optical properties in western Lake Erie: Implications for water quality remote sensing. **J. Great Lakes Res.** 45, 490-507. <https://doi.org/10.1016/J.JGLR.2019.03.011>.

SCHLEMMER A. M.; GITELSON, A.; SCHEPERS, J.; FERGUSON, R.; PENG, Y.; SHANAHAN, J.; RUNDQUIST, D. Remote estimation of nitrogen and chlorophyll contents in maize at leaf and canopy levels. **International Journal of Applied Earth Observation and Geoinformation**, vol. 25, p. 47-54, 2013.

SESTINI, M. F. **Variáveis geomorfológicas no estudo de deslizamentos em Caraguatatuba – SP** utilizando imagens TM-LANDSAT e SIG. São José dos Campos. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, p. 140, 1999.

SHAO, Y.; HE, Y. Visible/near infrared spectroscopy and chemometrics for the prediction of trace element (Fe and Zn) levels in rice leaf. **Sensors** (Switzerland), v. 13, n. 2, p. 1872-1883, 2013.

SILVA JUNIOR, Manoel Batista da. **Fertilizantes foliares no manejo da mancha de phoma de cafeeiro.** 2013, f. 50. Dissertação (Mestrado em Agronomia) – Universidade Federal de Lavras, Lavras, 2013.

SILVA, A. dos SANTOS da; SILVA GALEN, L. Caracterização da Pesca Artesanal em Municípios da Baixada Maranhense – Brasil. **Trainee de processos, Cooperativa Agrária Agroindustrial** – Entre Rios – PR – Brasil, v. 1, n. 1, p. 1-26, 2016.

SIMIS, S. G. H.; PETERS, S. W. M. & GONS, H. J. (2005). Remote sensing of the cyanobacterial pigment phycocyanin in turbid inland water. **Limnology and Oceanography**, 50(1), 237-245. doi:10.4319/lo.2005.50.1.0237.

SIPELGAS, L.; RAUDSEPP, U.; KÔUTS, T. Operacional monitoring of suspended matter distribution using MODIS imagens and numerical modelling. **Advances in Space Research**, v. 38, n. 10, p. 2182-2188, 2006.

SOUZA, M. J. N.; SANTOS, J. O.; OLIVEIRA, V. P. V. Sistemas ambientais e capacidade de suporte na bacia hidrográfica do Rio Curu – Ceará. **Revista Continentes**, n. 1, p. 119-143, 2012.

STEIN, B. R., V. A.; THOMAS, L. J.; LORENTZ, and B. D. STRAHM. (2014). “Predicting Macronutrient Concentrations from Loblolly Pine Leaf Reflectance across Local and Regional Scales.” **GIScience & Remote Sensing** 51 (3): 269-287. DOI:10.1080/15481603.2014.912875.

SUN, P.; WU, Y.; XIAO, J.; HUI, J.; HU, J.; ZHAO, F.; QIU, L.; LIU, S. (2019). Remote sensing and modeling fusion for investigating the ecosystem water-carbon coupling processes. **Sci. Total Environ.** 697, 134064. Disponível em: <https://doi.org/10.1016/J.SCITOTENV.2019.134064>.

SWAIN, P.H.; DAVIS, S.M. **Remote sensing: a quantitative approach**. McGraw-Hill, New York, NY, p. 396, 1978.

TAIZ, L.; ZEIGER, E. **Fisiologia vegetal**. Porto Alegre: Artmed, p. 449-484, 2004.

TELLES, DIRCEU D’ALKMIN; COSTA, R. H. P. GUIMARÃES (Orgs.), **Reuso da água: conceitos, teorias e práticas**, 2ª ed. ver., atual., e ampl, São Paulo: Edgard Blucher, 2010.

TIAN, Y.C. *et al.* Assessing newly developed and published vegetation indices for estimating rice leaf nitrogen concentration with ground- and space-based hyperspectral reflectance. **Field Crops Research**, Amsterdam, v. 120, p. 299-310, 2011.

TIERNY, J.; VANDEBORRE, J.; DAOUDI, M. **The Visual Computer**, v. 24, n. 3, p. 155-172, 2008.

TOBIAS, Randall D. *et al.* An introduction to partial least squares regression. In: Proceedings of the twentieth annual SAS users group international conference. **SAS Institute Inc.** Cary, NC, p. 1250-1257, 1995.

TONIOLO, G. R. **Identificação de constituintes opticamente ativos na água do Lago Gaúiba, a partir de sensores orbitais e espectrorradiometria de campo**. (2016). 103 f. Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.



VAZQUEZ DE ALDANA, B.R. B.; GARCIA-CRIADO, A.; GARCIA-CRIADO, and M.E. PEREZ-CORONA. (1995). Estimation of mineral content in natural grasslands by near infrared reflectance spectroscopy. **Commun. Soil Sci. Plant Anal.** 26:1383-1396.

VENTURA, D. L. T. (2013). **Uso do sensoriamento remoto para monitoramento da concentração de clorofila a em açudes do semiárido**. Dissertação (Mestrado) – Universidade de Brasília, Brasília, p. 53, 2013.

WALSHE, D. *et al.* Detecting nutrient deficiency in spruce forests using multispectral satellite imagery. **International Journal of Applied Earth Observation and Geoinformation**, v. 86, n. November 2019, p. 101975, 2020.

WATANABE, F. S. Y.; ALCÂNTARA, E.; RODRIGUES, T. W. P.; IMAI, N. N.; BARBOSA, C. C. F. e ROTTA, L. H. S. Estimation of Chlorophyll-a Concentration and the Trophic State of the Barra Bonita Hydroelectric Reservoir Using OLI/Landsat-8 Images. **International Journal of Environmental Research and Public Health**, v. 12, p. 10391-10417, 2015.

WATANABE, F.; ALCÂNTARA, E.; RODRIGUES, T.; ROTTA, L.; BERNARDO, N.; IMAI, N. Remote sensing of chlorophyll-a based on OLI/Landsat-8 and MSI/Sentinel-2A (Barra Bonita reservoir, Brazil). **Anais da Academia Brasileira de Ciências**, 90 (2 suppl. 1), 1987-2000, 2017.

WEN, P. F. *et al.* Estimating leaf nitrogen concentration considering unsynchronized maize growth stages with canopy hyperspectral technique. **Ecological Indicators**, v. 107, n. March, p. 105590, 2019.

WILCOX, G.E.; FAGERIA, N.K. **Deficiências nutricionais do feijão, sua identificação e correção**. Goiânia: Embrapa/ CNPAF, p. 22, 1976. (Boletim Técnico, 5).

WOLD, S.; SJOSTROM, M.; ERIKSSON, L. PLS-regression: a basic tool of chemometrics. **Chemometrics and Intelligent Laboratory Systems**, [s.l.], v. 58, p. 109-13, 2001. DOI: [https://doi.org/10.1016/S0169-7439\(01\)00155-1](https://doi.org/10.1016/S0169-7439(01)00155-1).

YARCE, C. J.; ROJAS, G. **Near infrared spectroscopy for the analysis of macro and micro nutrients in sugarcane leaves**. *Zuckerindustrie*, v. 137, n. 11, p. 707-710, 2012.

YU, X.; LU, H.; LIU, Q. Deep-learning-based regression model and hyperspectral imaging for rapid detection of nitrogen concentration in oilseed rape (*Brassica napus* L.) leaf. **Chemometrics and Intelligent Laboratory Systems**, v. 172, n. October 2017, p. 188-193, 2018.

ZHENG, G.; DIGIACOMO, P. M. Remote sensing of chlorophyll-a in coastal waters based on the light absorption coefficient of phytoplankton. **Remote Sensing of Environment** 201, 2017.

ZHENG, H. *et al.* A comparative assessment of different modeling algorithms for estimating leaf nitrogen content in winter wheat using multispectral images from an unmanned aerial vehicle. **Remote Sensing**, v. 10, n. 12, 2018.

ZHOU, X. *et al.* Remote estimation of canopy nitrogen content in winter wheat using airborne hyperspectral reflectance measurements. **Advances in Space Research**, v. 58, n. 9, p. 1627-1637, 2016.

ZUCARELI, C. **Adubação fosfatada, produção e desempenho em campo de sementes de feijoeiro CV. Carioca Precoce e IAC Carioca Tybatã.** (2005), f. 183. Dissertação (Mestrado em Agronomia/Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, 2005.