



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE TECNOLOGIA DEPARTAMENTO DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E
AMBIENTAL**

**MODELOS UNIVARIADOS E MULTIVARIADOS
PARA ESTIMATIVA DE CARACTERÍSTICAS DO
CRESCIMENTO E PRODUTIVIDADE DO TIFTON85
UTILIZANDO AERONAVE REMOTAMENTE
PILOTADA**

VITÓRIA CÔRTES DA SILVA SOUZA DE OLIVEIRA

2024



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE TECNOLOGIA DEPARTAMENTO DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E
AMBIENTAL**

**MODELOS UNIVARIADOS E MULTIVARIADOS PARA ESTIMATIVA
DE CARACTERÍSTICAS DO CRESCIMENTO E PRODUTIVIDADE DO
TIFTON85 UTILIZANDO AERONAVE REMOTAMENTE PILOTADA**

VITÓRIA CÔRTES DA SILVA SOUZA DE OLIVEIRA

Sob a Orientação do Professor
Dr. Anderson Gomide Costa

e Coorientação do Professor
Dr. Gustavo Bastos Lyra

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Engenharia Agrícola e Ambiental** no Curso de Pós-Graduação em Engenharia Agrícola e Ambiental, Área de concentração em Sistemas Agrícolas.

Seropédica
Rio de Janeiro – Brasil
Maio de 2024

“É permitida a cópia parcial ou total desta Dissertação, desde que seja citada a fonte.”

**Universidade Federal Rural do Rio de Janeiro Biblioteca
Central / Seção de Processamento Técnico**

**Ficha catalográfica elaborada
com os dados fornecidos pelo(a) autor(a)**

O48m Oliveira, Vitória Côrtes da Silva Souza de, 1996-
Modelos univariados e multivariados para
estimativa de características do crescimento e
produtividade do tifton85 utilizando aeronave
remotamente pilotada / Vitória Côrtes da Silva Souza de
Oliveira. - Engenheiro Paulo de Frontin, 2024.
77 f.: il.

Orientador: Anderson Gomide Costa.
Coorientador: Gustavo Bastos Lyra.
Dissertação(Mestrado). -- Universidade Federal
Rural do Rio de Janeiro, Pós-Graduação em Engenharia
Agrícola e Ambiental, 2024.

1. Sensoriamento remoto. 2. culturas forrageiras.
3. índice de vegetação. I. Costa, Anderson Gomide, 1985
, orient. II. Lyra, Gustavo Bastos, -, coorient. III
Universidade Federal Rural do Rio de Janeiro. Pós
Graduação em Engenharia Agrícola e Ambiental. IV. Título.

“O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de
Nível Superior – Brasil (CAPES) – Código de Financiamento 001”

**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE TECNOLOGIA DEPARTAMENTO DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E
AMBIENTAL**

VITÓRIA CÔRTES DA SILVA SOUZA DE OLIVEIRA

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Engenharia Agrícola e Ambiental**, no Programa de Pós-Graduação em Engenharia Agrícola e Ambiental, área de concentração Sistemas Agrícolas.

DISSERTAÇÃO APROVADA EM 28/05/2024.

Dr. Anderson Gomide Costa (Orientador UFRRJ)

Dr. Murilo Machado de Barros (UFRRJ)

Dr. Rafael de Oliveira Faria (UFLA)



HOMOLOGAÇÃO DE DISSERTAÇÃO DE MESTRADO N° 92/2024 - PPGEAAMB (12.28.01.00.00.00.00.40)

(Nº do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 05/11/2024 14:32)

ANDERSON GOMIDE COSTA
PROFESSOR DO MAGISTERIO SUPERIOR
DEPTOENG (12.28.01.00.00.00.44)
Matricula: ###619#5

(Assinado digitalmente em 05/11/2024 15:00)

MURILLO MACHADO DE BARROS
PROFESSOR DO MAGISTERIO SUPERIOR
DEPTOENG (12.28.01.00.00.00.44)
Matricula: ###506#5

(Assinado digitalmente em 06/11/2024 17:06)

RAFAEL DE OLIVEIRA FARLA
ASSINANTE EXTERNO
CPF: ####.###.126-##

Visualize o documento original em <https://sipac.ufrrj.br/documentos/> informando seu número: 92, ano: 2024, tipo: HOMOLOGAÇÃO DE DISSERTAÇÃO DE MESTRADO, data de emissão: 05/11/2024 e o código de verificação: 303fc7bd1e

DEDICATÓRIA

*Este trabalho é dedicado à Deus e aos meus pais,
onde sem eles eu nada seria.*

AGRADECIMENTOS

Primeiramente, à Deus, por me abençoar com a vida, força e sabedoria para superar os desafios e alcançar essa conquista tão significativa.

Aos meus queridos pais, Ayrton e Roberta, meu eterno agradecimento pelo amor incondicional, apoio, por serem meu porto seguro e por acreditarem em mim desde sempre. Vocês são meus pilares de força e inspiração.

Ao meu marido, Hérik, que sempre esteve do meu lado com apoio, carinho, companheirismo e por me incentivar a perseguir meus sonhos. Pela paciência nos momentos difíceis, por entender minhas ausências pelo tempo dedicado aos estudos e aguentar tantas crises de ansiedade e estresse.

Aos meus orientadores, prof. Dr. Anderson Gomide Costa e prof. Dr. Gustavo Bastos Lyra, minha imensa gratidão por acreditarem em meu potencial e me guiarem com maestria durante a elaboração deste trabalho. Sem dúvidas sem vocês eu jamais conseguaria.

Aos professores Dr. Murilo e Dr. Rafael por aceitarem compor a banca examinadora deste trabalho e por suas valiosas contribuições.

Ao Grupo de pesquisa em Modelagem Ambiental e Atmosférica (GMAAT), Laboratório de Pesquisa Multisuários do Grupo de Energias Renováveis e Alternativas Rurais (LabGERAR) e Prof. Ricardo Vilar por todo apoio para que eu pudesse mensurar e analisar os dados desta pesquisa.

Aos meus amigos que a pós-graduação e o GMAAT me presentearam: Cristiano, Francisco, Julia, Mariana e Samuel, obrigada por toda ajuda durante os campos e apoio para a elaboração desta pesquisa.

As minhas amigas quase irmãs Jéssica e Mylena, pela ajuda no campo, por suas amizades, por sempre me ouvirem e apoarem. Jéssica, obrigada por tornar essa jornada mais leve e divertida,

pelo companheirismo e por tudo que aprendemos juntas.

À Universidade e a todos os seus colaboradores, meu reconhecimento pelo trabalho dedicado que garante o bom funcionamento da instituição.

E por fim, mas não menos importante, a mim mesma, por nunca ter desistido dos meus sonhos, por ter persistido nos momentos difíceis e por ter acreditado que era capaz de alcançar meus objetivos.

RESUMO

OLIVEIRA, Vitória Côrtes da Silva Souza de. Modelos univariados e multivariados para estimativa de características do crescimento e produtividade do tifton85 utilizando aeronave remotamente pilotada, 2024. 77p Dissertação (Mestrado em Engenharia Agrícola e Ambiental). Instituto de Tecnologia, Departamento de Engenharia, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2024.

Com avanço tecnológico e a necessidade de aumentar a eficiência do processo produtivo, a agricultura de precisão surge como uma alternativa para melhor planejamento e manejo da produção, pois, fornece infinitos benefícios com boa produtividade, sustentabilidade e desenvolvimento econômico. Neste sentido, técnicas de sensoriamento remoto têm sido amplamente utilizadas de forma instantânea e baixo custo desempenhando importante papel em diagnósticos como a estimativa da produtividade e atributos da cultura. O objetivo desta pesquisa foi avaliar as respostas espectrais do Tifton85 em diferentes estágios de crescimento e gerar modelos capazes de estimar atributos da forrageira a partir de técnicas de sensoriamento remoto. O experimento ocorreu em um intervalo de 48 dias contados a partir do corte de uniformização da cultura, com coletas rotineiras totalizando 5 épocas de avaliação (EA). Em cada EA foram coletados em 39 pontos georreferenciados os seguintes atributos: índice de área foliar (IAF), altura e clorofila da planra. Concomitantemente foram obtidas imagens com uma aeronave remotamente pilotada DJI Phantom 4 Advanced com um sensor multiespectral a bordo e calculados os índices de vegetação (IVs) para cada ponto em cada EA. Ao final do período deste experimento foi coletada a biomassa da cultura em cada ponto. De forma univariada, os atributos da cultura foram relacionados aos graus-dias acumulados ao longo dos dias do experimento por meio de modelos de regressão. O coeficiente de Pearson foi utilizado para avaliar a correlação entre os IVs e atributo da cultura. Os IVs que apresentaram maior correlação foram selecionados para gerar modelos lineares de estimativa dos atributos da cultura. A biomassa final foi correlacionada com os IVs, obtidos em cada EA possibilitando avaliar a qualidade de modelos de estimativa da produtividade do Tifton85 antes da colheita. A biomassa final da cultura apresentou maior relação com o índice GNVI obtido aos 33 dias (3EA) de avaliação da cultura, demonstrando ser possível estimar a produtividade da cultura em períodos antes a colheita em campo. A partir da análise multivariada dos componentes principais foi avaliada a porcentagem explicativa de cada componente principal (CP) e a correlação dos índices espectrais com cada CP relevante com seus respectivos coeficientes. Os coeficientes associados aos CPs relevantes foram utilizados para compor um índice de crescimento da cultura que foi utilizado gerar modelos lineares de estimativa dos atributos da cultura. Os resultados demonstraram que de forma univariada, os modelos apresentaram melhor desempenho quando associados ao índice VARI para estimativa da clorofila ($R^2 = 0,7202$), índice GNDVI para estimativa da altura ($R^2 = 0,5744$), índice NDVI para estimativa do IAF ($R^2 = 0,7539$) e índice GNDVI ($R^2 = 0,5744$). Ao avaliar de forma multivariada, foi possível reduzir o comportamento dos IVs em um único componente CP1 (poder explicativo de 99,94%). O índice de crescimento da cultura proposto e gerado a partir dos coeficientes associados ao CP1 demonstrou grande aplicabilidade, especialmente em lavouras onde devido à grande variabilidade os modelos univariados gerados pelos IVs apresentam baixa relação com os atributos da cultura.

Palavras-chave: Sensoriamento remoto, culturas forrageiras, índice de vegetação.

ABSTRACT

OLIVEIRA, Vitória Côrtes da Silva Souza de. Univariate and multivariate models for estimating growth and productivity characteristics of tifton85 using remotely piloted aircraft, 2024. 77p Dissertation (Master in Agricultural and Environmental Engineering). Institute of Technology, Department of Engineering, Federal Rural University of Rio de Janeiro, Seropédica, RJ, 2024.

With technological advancement and the need to increase the efficiency of the production process, precision agriculture emerges as an alternative for better planning and management of production, as it provides infinite benefits with good productivity, sustainability and economic development. In this sense, remote sensing techniques have been widely used instantly and at low cost, playing an important role in diagnostics such as estimating productivity and crop attributes. The objective of this research was to evaluate the spectral responses of Tifton85 at different growth stages and generate models capable of estimating forage attributes from remote sensing techniques. The experiment took place over a 48-day interval counted from the crop standardization cut, with routine collections totaling 5 evaluation times (EA). In each EA, the following attributes were collected at 39 georeferenced points: leaf area index (LAI), height and chlorophyll of the planra. Concomitantly, images were obtained with a DJI Phantom 4 Advanced remotely piloted aircraft with a multispectral sensor on board and vegetation indices (VIs) were calculated for each point in each EA. At the end of the experiment period, crop biomass was collected at each point. In a univariate manner, crop attributes were related to the degree days accumulated over the days of the experiment through regression models. Pearson's coefficient was used to evaluate the correlation between IVs and crop attributes. The IVs that presented the highest correlation were selected to generate linear models to estimate crop attributes. The final biomass was correlated with the IVs obtained in each EA, allowing the evaluation of the quality of models to estimate Tifton 85 productivity before harvest. The final crop biomass showed a greater relationship with the GNDVI index obtained at 33 days (3EA) of crop evaluation, demonstrating that it is possible to estimate crop productivity in periods before harvest in the field. From the multivariate analysis of the principal components, the explanatory percentage of each principal component (PC) and the correlation of the spectral indices with each relevant PC and their respective coefficients were evaluated. The coefficients associated with the relevant PCs were used to compose a crop growth index that was used to generate linear models to estimate the crop attributes. The results demonstrated that in a univariate manner, the models presented better performance when associated with the VARI index to estimate chlorophyll ($R^2 = 0.7202$), GNDVI index to estimate height ($R^2 = 0.5744$), NDVI index to estimate LAI ($R^2 = 0.7539$) and GNDVI index ($R^2 = 0.5744$). When evaluating in a multivariate manner, it was possible to reduce the behavior of the IVs in a single component PC1 (explanatory power of 99.94%). The proposed crop growth index generated from the coefficients associated with CP1 demonstrated great applicability, especially in crops where, due to the great variability, the univariate models generated by IVs present a low relationship with the crop attributes.

Keywords: Remote sensing, forage crops, vegetation index.

LISTA DE TABELAS

Tabela 1. Datas de realização da avaliação da cultura por meio do uso de ARPS e monitoramento dos atributos.....	14
Tabela 2. Índices de vegetação calculados utilizando dados espectrais obtidos por ARP.....	15
Tabela 3. Acúmulo de graus-dias ao longo do experimento	27
Tabela 4. Análise descritiva dos dados dos índices de vegetação calculados	30
Tabela 5. Autovalores (Autov), Percentual explicativo (PE) e percentual explicativo acumulado (PEAc) associada aos componentes principais gerados	32
Tabela 6. Correlação e coeficientes entre os índices espectrais (IVs) e Componente Principal 1	32
Tabela 7. Correlação entre atributos da cultura e índices de vegetação	35
Tabela 8. Correlação entre a biomassa final e os índices de vegetação	48

LISTA DE FIGURAS

Figura 1. Assinatura espectral da vegetação, água e solo.....	6
Figura 2. Localização da área de experimental – Fazenda FenoRio/UFRRJ	13
Figura 3. Demarcação dos pontos com RTK	13
Figura 4. ARP utilizada para aquisição das imagens.	15
Figura 5. Aferição da altura do Tifton85.....	17
Figura 6. Ceptômetro utilizado na medição do IAF na cultura.	18
Figura 7. Aferição do IAF com o ceptômetro.	19
Figura 8. Clorofilômetro utilizado para mensuração de clorofila.	20
Figura 9. Gabarito utilizado e coleta de massa fresca do Tifton85.	21
Figura 10. Estufa utilizada para secagem da massa fresca.	21
Figura 11. Balança utilizada para medição da biomassa.....	22
Figura 12. Climograma das médias das variáveis meteorológicas registradas durante o período de condução do experimento.....	26
Figura 13. a) Relação entre clorofila e graus-dias acumulados no crescimento do Tifton85. b) Relação entre altura e graus-dias acumulados no crescimento do Tifton85. c) Relação entre IAF e graus-dias acumulados no crescimento do Tifton85.	28
Figura 14. Dispersão no plano bidimensional dos scores do primeiro e segundo componente principal (CP1 e CP2) do grupo de dados.	33
Figura 15. Regressão entre Clorofila e VARI (a); Regressão entre Altura e GNDVI (b); Regressão entre IAF e NDVI (c).....	37
Figura 16. Regressão entre Clorofila e ICC (a); Regressão entre Altura e ICC (b); Regressão entre IAF e ICC (c).....	39
Figura 17. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de Clorofila em função dos índices de vegetação VARI para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de Clorofila em função dos índices de vegetação VARI para 3EA (d); Imagem obtida pelo ARP na 5EA (e); Mapa de estimativa de Clorofila em função dos índices de vegetação VARI para 5EA (f).	41
Figura 18. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de Altura em função dos índices de vegetação GNDVI para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de Altura em função dos índices de vegetação GNDVI para 3EA (d); Imagem obtida pelo ARP na 5EA (e); Mapa de estimativa de Altura em função dos índices de vegetação GNDVI para 5EA (f).....	42
Figura 19. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de IAF em função dos índices de vegetação NDVI para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de IAF em função dos índices de vegetação NDVI para 3EA (d); Imagem obtida pelo ARP na 5EA (e); Mapa de estimativa de IAF em função dos índices de vegetação NDVI para 5EA (f).	43
Figura 20. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de Clorofila em função do ICC para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de Clorofila em função do ICC para 3EA (d); Imagem obtida pelo ARP na 5EA (e); Mapa de estimativa de Clorofila em função do ICC para 5EA (f).....	45
Figura 21. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de Altura em função do ICC para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de Altura em função do ICC para 3EA (d); Imagem obtida pelo ARP na 5EA (e); Mapa de estimativa de Altura em função do ICC para 5EA (f).	46
Figura 22. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de IAF em função do ICC	

para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de IAF em função do ICC para 3EA (d); Imagem obtida pelo ARP na 5EA (e); Mapa de estimativa de IAF em função do ICC para 5EA (f)	47
Figura 23. Regressão polinomial entre GNDVI e Biomassa do Tifton obtida após 48 dias de experimento.	49
Figura 24. Comparativo entre (a) a imagem do ortomosaico aos 48 dias (5EA) e; (b) os valores de biomassa do Tifton85 estimados pelo modelo com base no GNDVI.....	50

Sumário

1. INTRODUÇÃO	1
2. OBJETIVOS	3
2.1. Objetivo geral.....	3
2.2. Objetivo específico.....	3
3. REVISÃO BIBLIOGRÁFICA	3
3.1. A cultura Tifton85.....	3
3.2. Sensoriamento remoto aplicado ao monitoramento de lavouras	5
3.3. Aeronaves Remotamente Pilotadas e o processamento de imagens	6
3.4. Sensores ópticos proximais para mensurações em campo dos atributos da cultura	8
3.4.1. Ceptômetro.....	9
3.4.2. Clorofilômetro.....	10
3.5. Estimativa de atributos por meio de índices de vegetação	11
4. MATERIAL E MÉTODOS	12
4.1. Caracterização da área e disposição experimental	12
4.2. Caracterização do plano de voo e obtenção dos índices espectrais.....	14
4.3. Obtenção dos atributos da cultura	16
4.4. Caracterização do ambiente e obtenção dos graus-dias	22
4.5. Análise dos dados.....	23
4.5.1. Resposta dos atributos do Tifton85 em função dos graus-dias	23
4.6. Predição da biomassa em função dos índices de vegetação	24
5. RESULTADOS E DISCUSSÃO	25
5.1. Resposta dos atributos em função dos graus-dias	25
5.2. Avaliação da resposta dos índices de vegetação utilizando componentes principais.....	29
5.3. Estimativa dos atributos em função dos índices de vegetação	34
5.4. Predição da biomassa em função dos índices espectrais	48
6. CONCLUSÃO	51
7. REFERÊNCIAS BIBLIOGRÁFICAS	52

1. INTRODUÇÃO

A agropecuária é um dos pilares da economia brasileira como fonte de renda de diversos agricultores e pecuaristas na produção dos alimentos. Em constante crescente neste setor, em 2023 o Brasil alcançou recorde na exportação de carne bovina com 2,26 milhões de toneladas vendidas, superando 2021 em 22,6%, o tornando o maior exportador mundial. Diversos fatores influenciaram neste sucesso, incluindo a alta produção (cerca de 10,79 milhões de toneladas), a qualidade da carne brasileira com preços competitivos aliados a dificuldades sanitárias e climáticas em alguns países produtores tornam a carne brasileira mais atrativa no mercado (ABIEC, 2023).

Além disso, com o segundo maior rebanho bovino do mundo, o Brasil é um importante produtor de leite (FAO, 2023), garantindo o sustento e alimento de milhares de pessoas que dependem da pecuária. O país possui cerca de 18,72% da área nacional dedicada a pastagens utilizadas para produção animal e se mantém como grande produtor e exportador mundial de carne bovina demonstrando a relevância do setor para a economia e o desenvolvimento do país (EMBRAPA, 2021).

No Brasil, a sazonalidade da produção de forragem é uma das razões pelas quais a maioria dos sistemas pecuários depende de planejamento (PINHEIRO et al., 2021; İLERİ, 2022; CUNHA, 2020). Como a alimentação dos animais tem que ser rica em nutrientes e bem controlada ao longo de todo ano, a conservação de forrageiras por meio da ensilagem ou fenação, é uma alternativa utilizada para manter altos índices nutricionais da forragem produzida e minimizar os problemas causados pela deficiência alimentar em época de indisponibilidade de material diretamente no campo, onde é fundamental a utilização de técnicas capazes de garantir o aproveitamento de toda a (DE CASTRO et al., 2020).

Uma das principais culturas forrageiras usadas e conservadas como feno é o capim Tifton85 (*Cynodon spp.*) pois tem fácil adaptação em relação as condições climáticas, boa produtividade, bom valor nutritivo, alto teor proteico, ótima palatabilidade, facilidade de desidratação, além de elevado grau de resposta à adubação nitrogenada. A adubação nitrogenada é capaz de proporcionar maior produção através do maior desenvolvimento dos constituintes morfológicos e estruturais da planta (ANDRADE, 2017; MOMESSO et al., 2022).

Dada a necessidade de melhorar o controle e gerenciamento desse cultivo, o manejo via agricultura de precisão tem sido uma opção para ganhos de produtividade, sustentabilidade e desenvolvimento econômico. Esta forma de manejo, é vista como alternativa eficaz para melhorar

o controle e planejamento da produção de culturas, sendo capaz de gerar informações sobre a variabilidade de atributos do solo e da planta em campo, que servem de apoio para tomadas de decisão no manejo das pastagens (BASSOI et al., 2019).

Neste sentido, técnicas de sensoriamento remoto têm sido amplamente utilizadas como ferramentas de monitoramento de lavouras, fornecendo informações de forma instantânea, com menor custo e desempenhando importante papel em diagnósticos agrícolas como a estimativa da produtividade (TONG et al., 2019), detecção de pragas e doenças (BARROS et al., 2021) e avaliação nutricional (NAJI, 2018).

O avanço das tecnologias de agricultura de precisão em pastagem ocorre, dentre outros fatores, devido à integração de informações fornecidas por sensores de monitoramento de planta, com sensores de monitoramento de solo e o entendimento da dinâmica do pastejo (MURPHY et al., 2021). Estas medidas, aliadas a métodos tradicionais, permite que o produtor tenha uma compreensão melhor do sistema pecuário e possa formular uma estratégia de manejo mais adequada (BERNARDI & PEREZ, 2014).

Com as informações espectrais obtidas por aeronave remotamente pilotada (ARP) diversos Índices de Vegetação (IVs) podem ser calculados e utilizados para relação com parâmetros associados ao desenvolvimento de culturas (DE SOUZA, 2021; FILIPPI, 2020). Esses IVs são relacionados com as avaliações diretas de interesse, como formas de avaliar a produtividade (SPERANZA, 2018), biomassa de forragem (MESHESHA et al., 2020), teor de nitrogênio (SILVA, 2020), altura da cultura e índice de área foliar (FONSECA E GONZÁLEZ, 2022).

Conforme discutido em THÉAU et al. (2021), o uso de ARPs oferece uma combinação de alta resolução espacial, flexibilidade operacional e precisão nos dados, sendo uma ferramenta poderosa para estimar biomassa de forrageiras. Em seu trabalho, foi realizado o processamento de imagens adquiridas por uma ARP (Inspire 1 Pro da DJI, equipado com um sensor multiespectral visível-infravermelho da Parrot, modelo Sequoia) e calculados os índices de vegetação GNDVI, Datt1, NDVI, RVI, RDVI, OSAVI, MSAVI, SAVI e NDR a fim de estimar a biomassa e cobertura vegetal da pastagem. Foram calculadas regressões não-lineares entre esses índices e a biomassa coletada, tendo os IVs GNDVI e Datt1 apresentando os coeficientes de determinação mais altos (acima de 0,7), enquanto o NDVI, teve um coeficiente próximo de 0,5.

Diante do cenário descrito, estudos envolvendo a análise das relação entre IVs e atributos de culturas forrageiras (principalmente biomassa, níveis de clorofila, altura e índice de área foliar)

podem ajudar os produtores a gerenciarem suas pastagens com rapidez e precisão, além de auxiliar na avaliação do momento ideal para colheita da forragem, ajustar para disponibilidade de forragem através das taxas de lotação e melhor ajuste de composição do suplemento com base nas mudanças no valor nutricional da forragem ao longo do ano.

2. OBJETIVOS

2.1. Objetivo geral

O objetivo deste trabalho foi avaliar as respostas espectrais da forrageira Tifton85 (*Cynodon* spp.) em diferentes estágios de crescimento a partir de técnicas de sensoriamento remoto e gerar modelos capazes de estimar os atributos clorofila, altura e índice de área foliar da cultura.

2.2. Objetivo específico

- Obter índices de vegetação por meio de ARP para o Tifton85 visando caracterizar a cultura em diferentes épocas de crescimento;
- Mensurar os atributos do Tifton85 em diferentes épocas de crescimento da cultura;
- Obter índices de vegetação por meio de ARP e gerar modelos para estimar os atributos a partir de características espectrais.
- Gerar modelos de predição que possibilitem estimar a biomassa final por meio dos índices de vegetação obtidos em diferentes épocas de desenvolvimento da cultura.

3. REVISÃO BIBLIOGRÁFICA

3.1. A cultura Tifton85

A Agropecuária brasileira é uma importante fonte de renda para diversos agricultores e pecuaristas, sendo essencial para a economia nacional como também para a subsistência humana, com insumos que servem de base para alimentação mundial (DE FIGUEIREDO, 2019).

Como uma das fontes mais econômica para nutrição animal, o uso de pastagens está diretamente ligado à quantidade ingerida e aos nutrientes contidos na planta ofertada. Dentre as diversas cultivares com esta finalidade, destacam-se as forrageiras do gênero *Cynodon*, originadas da África Tropical. Este gênero tem como características elevado potencial produtivo e adaptação as regiões tropicais e subtropicais do Brasil (FIGUEIREDO et al., 2020).

Dentre as gramíneas do gênero *Cynodon*, a Tifton85 foi desenvolvida com o objetivo de obtenção de alta produtividade e qualidade da forrageira, sendo uma boa alternativa para pastejo e produção de feno. Por sua versatilidade, ela pode ser plantada tanto em climas tropicais ou subtropicais quanto regiões frias ou quentes. Esta cultura também pode ser cultivada em solos arenosos, mistos e argilosos, devidamente corrigidos e adubados, não suportando apenas terrenos encharcados e ambientes sombreados (DA SILVA et al., 2020).

O Tifton85 se destaca entre as forrageiras para alimentação animal por apresentar melhor digestibilidade, maior teor de proteína bruta, elevada produção de massa seca e elevado valor nutritivo, aumentando assim o desempenho animal reduzindo a necessidade de alimentação suplementar e consequentemente melhorando o custo de produção (SOUZA et. al., 2020).

Segundo TAIZ et al. (2017), o nitrogênio (N) é um dos elementos que mais influência no crescimento e desenvolvimento das plantas, representando de 20 a 40 g.kg⁻¹ da massa seca dos tecidos vegetais. A adubação nitrogenada indica o ritmo de crescimento, a qualidade da forragem e a produtividade do pasto, principalmente quando a forrageira tem boa resposta à aplicação desse nutriente (NUNES & NUNES, 2018).

O trabalho de SOUZA (2024) apresentou efeito positivo entre a adubação nitrogenada e o acúmulo de biomassa do capim Tifton85. Nas parcelas onde não houve adubação, foi observado os piores desempenhos em termos de produtividade do capim, em todas as épocas de coleta. Em contrapartida, dentre as doses usadas (100 kg. ha⁻¹, 200 kg. ha⁻¹ e 300 kg. ha⁻¹) a que apresentou melhor desempenho foi a de 300 kg. ha⁻¹), tendo o pico máximo de produção em 42 dias de experimento. Em OLIVO et al. (2019) foi avaliado a relação de doses de nitrogênio entre 100 e 200 kg. ha⁻¹ à forrageira Tifton85 sob condições de pastejo, onde obtiveram produções de forragem entre 11 e 14 t de matéria seca por hectare, com concentração de proteína próxima a 14 % e 17%, respectivamente, em ciclo de 29 dias.

A produção agrícola depende diretamente do estado nutricional das plantas e como o nitrogênio é um dos nutrientes mais exigidos pelas plantas, sua deficiência reduz o crescimento e produtividade das culturas, em contrapartida, a aplicação excessiva pode ter um impacto negativo tanto no ambiente natural quanto nas finanças agrícolas. O monitoramento frequente de N de campo é impraticável devido ao tempo e custo necessários para análises laboratoriais. Com isso, dados de sensoriamento remoto surge como alternativa para avaliar e monitorar o estado nutricional das culturas ao longo da estação de crescimento (PEREIRA et al., 2022).

O ciclo do Tifton85 dura em média de 30 a 60 dias a depender do clima, manejo e altura de corte. Regiões com maior calor e umidade, o ciclo tende a ser mais rápido, plantio com irrigação e/ou adubação nitrogenada pode acelerar o crescimento, além de que se pode cortar o capim em alturas mais baixas resultando assim, ciclos mais curtos (CASAGRANDE, 2021). Com rendimentos de matéria seca, em sistemas não-irrigados, entre 20.000 e 30.000 kg ha⁻¹ ano⁻¹ com bom valor nutritivo, a cultura atinge entre 11% e 13% de proteína bruta (PB) e 58% a 65% de digestibilidade (ROSA, 2023; LIMA, 2023).

Estudos têm explorado a relação entre o intervalo de corte e a produtividade do Tifton85. Em sua pesquisa, VIÇOSI et al. (2020) examinaram como o capim responde a diferentes níveis de adubação nitrogenada e a cortes realizados a cada 30 dias. Foi observado que à medida que o número de cortes aumenta, a proporção de folhas para colmos cresce, enquanto a massa seca por perfilho diminui. Entretanto, a produtividade do Tifton85 tende a diminuir conforme o número de cortes aumenta, devido ao seu rápido crescimento, que favorece cortes mais frequentes.

3.2. Sensoriamento remoto aplicado ao monitoramento de lavouras

Desde a década de 1970, o Sensoriamento Remoto vem sendo estudado para aplicações na agricultura para identificação de produtividade da mesma (FORMAGGIO & SANCHES, 2017). Ele é caracterizado pelo conjunto de atividades como: detecção, aquisição e análise da energia eletromagnética emitida ou refletida pelos objetos terrestres e registradas por sensores remotos que permitem a obtenção de informações de um objeto sem contato físico direto com o mesmo e geralmente, a longas distâncias.

A quantidade e qualidade da energia eletromagnética refletida e emitida pelos objetos terrestres resulta das interações entre eles e a energia eletromagnética. Cada objeto tem sua curva singular de energia no espectro eletromagnético, chamada assinatura espectral. Essas interações podem ser identificadas nos dados obtidos por sensores remotos. A energia eletromagnética refletida e emitida pelos objetos é a base de dados para todo o processo de sua identificação, pois ela permite quantificar a energia espectral refletida e/ou emitida por estes, e assim avaliar suas principais características (BARROS, et al., 2021).

Casos de objetos como vegetação, água e solo refletem, absorvem e transmitem radiação eletromagnética com proporções que variam com o comprimento de onda e possuem singularidades próprias, de acordo com suas características biofísicas e químicas. Essas curvas espectrais (**Erro!**

Fonte de referência não encontrada.) permitem distinguir os objetos da superfície terrestre nas imagens obtidas por sensores remotos (HERNÁNDEZ, 2021).

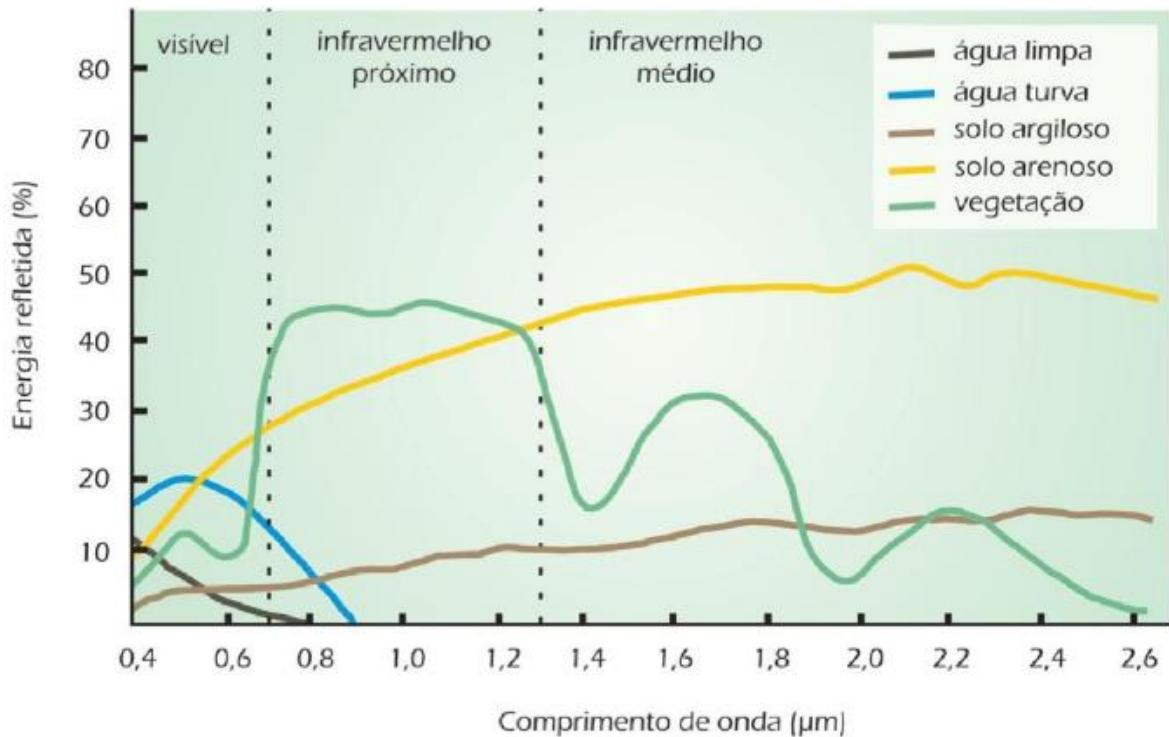


Figura 1. Assinatura espectral da vegetação, água e solo.

Fonte: FLORENZANO (2011)

Estudos como HOTT et al. (2019); ALMEIDA (2022); ROCHA et al. (2022); MAGALHÃES (2022) mostram como o uso de técnicas de sensoriamento remoto tem sido comumente utilizada para relacionar atributos e índices de vegetação para modelos de estimativas com metodologias precisas e capazes de identificar a variabilidade dos campos de produção.

3.3. Aeronaves Remotamente Pilotadas e o processamento de imagens

A necessidade agilidade no monitoramento dos cultivos fez com que uso de aeronaves remotamente pilotadas seja cada vez mais frequente na agricultura visto que a rapidez, eficiência e precisão na geração de dados permitem a execução de trabalhos de campo com excelente qualidade a um custo relativamente baixo, facilitando detectar diversos aspectos biofísicos da planta com periodicidade nessas coletas a escolha do produtor e de acordo com o ciclo fenológico (SOBRINHO et al., 2018).

Aeronaves remotamente pilotadas (ARPs) são equipamentos conduzidos de forma remota por um usuário à distância com auxílio de controle ou de maneira autônoma (através de um plano de voo, previamente elaborado em um aplicativo específico para esta finalidade).

O uso do ARP na agricultura tem sido amplamente utilizado para controle do cultivo (DOS SANTOS et al., 2018), de pragas (FERREIRA et al., 2017) e estimativa de produção (PRESTES et. al., 2020). Com sensores embarcados no equipamento, as câmeras podem abranger a região do espectro do visível ou até mesmo no infravermelho próximo baseado na espectroscopia de reflectância, ou seja, medidas de reflexão da radiação eletromagnética após interação com diferentes superfícies em diferentes comprimentos de onda (CLERCQ et al., 2018).

Ao sobrevoar a área de interesse, os sensores abordo das ARPs vão capturando as imagens com sobreposição definida pelo usuário para que haja pontos homólogos entre as cenas. Após todas as imagens capturadas, é realizado o processamento das imagens em softwares específicos, onde as fotos sobrepostas são alinhadas e unidas, formando um único mosaico, chamado ortomosaico.

Diversos estudos sobre cultura, têm-se utilizado índices de vegetação calculados a partir de dados obtidos por RPAs em suas análises (SANTOS et al., 2022; DE SOUZA et al., 2021; AHMAD et al., 2020). Neste caso, técnicas de correção radiométrica se faz necessário, visto que essa correção atua como um calibrador para que os dados coletados representem fielmente a reflectância real da superfície terrestre, garantindo que os valores de pixel sejam consistentes e comparáveis entre diferentes imagens.

De acordo com RADOČAJ, et al (2023), levando em consideração o número de artigos científicos no Web of Science Core Collection (WoSCC) desde o ano 2000, o Índice de Vegetação por Diferença Normalizada (NDVI) foi identificado como o mais utilizado, com um total de 2.200 estudos registrados, representando o histórico mais longo de aplicação dentre os IVs. Ainda se destacou os cinco principais índices de vegetação que mais têm sido empregados desde o ano 2000 como: NDVI, Índice de Vegetação Excessiva (EVI), Índice de Vegetação Normalizado por Diferença Verde-NIR (GNDVI), Índice de Vegetação do Solo Ajustado (SAVI) e Índice de Vegetação Vermelha (RVI).

De forma análoga, no que diz respeito aos principais índices de vegetação baseados em sensores RGB, o Índice Normalizado de Diferença Verde-Vermelho (NGRDI) emergiu como o índice predominantemente empregado durante a última década. Dentre os cinco principais índices RGB incluem NGRDI, Excesso de Índice Verde (ExG), Excesso de Índice Vermelho (ExR), Vari

e MGRVI (Índice de Vegetação Verde-Vermelho Modificado).

Em GIOVOS et al. (2021) foi investigado 97 índices de vegetação com aplicações em várias escalas, seja regional ou local. O estudo ressaltou a variabilidade espacial observada nos índices de vegetação, com o uso de imagens de ARPs, demonstrando como esses índices são sensíveis a diversas características das plantas, como clorofila, pigmentos, biomassa e teor de água nas folhas. Além disso, foi enfatizado que o Índice de Vegetação por Diferença Normalizada (NDVI) é o índice mais frequentemente aplicado.

No trabalho de FERREIRA et al. (2023), foi analisado a variabilidade espacial e de produtividade em vinhedos utilizando índices de vegetação calculados a partir de imagens obtidas por um ARP. Os índices MPRI e RED/GREEN apresentaram correlações moderadas com produtividade, 0,67 e -0,66 ($p<0,05$) respectivamente.

Já no estudo de MORGAN et al. (2021), os autores utilizaram um ARP com câmera RGB para estimar a produtividade e biomassa da vegetação pantanosa de maré através de índices de vegetação na região do visível, tendo os modelos de estimativa de biomassa com melhor desempenho os que relacionaram os índices TGI ($R^2 = 0,39$) e ExG ($R^2= 0,376$).

3.4. Sensores ópticos proximais para mensurações em campo dos atributos da cultura

A estimativa de atributos pode ser realizada através de dois métodos: direto (destrutivo) e indireto (não destrutivo). Os métodos diretos geralmente são demorados, sendo necessário o corte de folhas ou biomassa da cultura para sua determinação, limitando sua aplicação devido a morosidade e efeito deletério no cultivo. Já os métodos indiretos inferem características a partir de medições ou observações relacionadas. Estes podem ser realizados em poucos minutos, oferecendo facilidade de determinação, sem necessidade de envio de amostras para laboratório, economia de tempo e dinheiro, sendo possível coletar amostras de acordo com a necessidade sem implicar na destruição das folhas (ALBUQUERQUE et al., 2020).

Dentre diversos equipamentos são utilizados para monitoramento por método indireto, destaca-se os sensores de princípios ópticos que realizam a medida indireta da radiação solar interceptada pelo dossel das plantas caso do ceptômetro para a determinação do índice de área foliar ou da diferença de atenuação da luz entre 650nm e 940 nm, caso do clorofilômetro para obtenção da clorofila (ALI et al., 2024).

3.4.1. Ceptômetro

A radiação solar é de grande relevância para os seres vivos considerando o processo de transferência de energia por meio da fotossíntese. Conforme DA PONTE et al. (2017), a faixa espectral da radiação solar entre 400 e 710 nm é utilizada pelas plantas no seu processo fotossintético, denominada de Radiação Fotossinteticamente Ativa (PAR).

O aproveitamento da radiação solar pelas plantas é de grande importância para obtenção de um bom resultado em seu desenvolvimento. Um parâmetro comumente utilizado na agricultura para representar a eficiência fotossintética da planta é o índice de área foliar (IAF), onde este representa a relação entre a área foliar e a área de solo ocupada pelo cultivo. Este índice pode ser utilizado para análise do crescimento e, também, como fator condicionante da produtividade, pois através do IAF, é definida a capacidade do dossel em interceptar a radiação solar, converter em matéria seca através da fotossíntese, e determinar o potencial produtivo da cultura (TAGLIAPIETRA et al., 2018).

Dentre os métodos de obtenção do IAF, têm-se o ceptômetro, onde de forma indireta (não destrutiva) o aparelho possui sensores que medem a radiação fotossintética do dossel e calcula precisamente o IAF (Equação 1 e 2) em tempo real, utilizando a diferença na incidência luminosa entre os sensores o equipamento calculando a interceptação luminosa e assim estimando o IAF (SOUZA et al., 2019).

Para a coleta do IAF com um ceptômetro deve-se primeiramente configurá-lo com a data, hora e local. Em seguida, deve-se posicionar a haste do aparelho acima da copa e realizar a leitura para medir a incidência acima do dossel e posteriormente repetir o processo abaixo da copa da cultura. Há a possibilidade de acoplar um sensor PAR externo que pode ser usado para fazer medições PAR simultâneas acima e abaixo da copa como referência para luz interceptada em condições de céu claro, parcialmente nublado ou mesmo nublado. Vale ressaltar, que em ambas as situações deve-se atentar para a direção do sol a fim de não fazer sombra no dossel na hora da coleta dos dados.

$$L = \frac{[(1 - \frac{1}{2K}) f_b - 1] \ln \tau}{A (1 - 0,47 f_b)} \quad (1)$$

$$K = \frac{\sqrt{\chi^2 + \tan \theta}}{\chi + 1,744 (\chi + 1,182)^{-0,733}} \quad (2)$$

onde: τ é a proporção de PAR transmitido e incidente e é calculada usando medições de PAR transmitido próximo à superfície do solo e PAR incidente acima do dossel

θ é a elevação angular do sol no céu em relação ao zênite, ou o ponto diretamente acima de sua cabeça e é calculado automaticamente usando informações de hora local, data, latitude e longitude; f_b é a fração do feixe e é calculado automaticamente comparando os valores medidos do PAR incidente com a constante solar, que é um valor conhecido da energia luminosa do sol (assumindo condições de céu claro) em qualquer momento e local na superfície da Terra;

χ é a distribuição do ângulo da folha, onde possui o valor de 1 como padrão;

K é o coeficiente de extinção que descreve quanta radiação é absorvida pelo dossel em um determinado ângulo zenital solar e distribuição do ângulo foliar do dossel.

No trabalho de BEZERRA (2022), um ceptômetro AccuPAR LP-80 foi empregado para medir o IAF do capim-zuri e, juntamente com informações sobre temperatura, radiação solar, precipitação e balanço hídrico, objetivou-se validar um modelo agrometeorológico proposto e analisar os efeitos dos diferentes regimes de manejo nutricional sobre a produtividade da biomassa do capim-zuri. Concluiu-se que o modelo foi capaz de predizer a produção do capim-zuri de forma eficiente com erro médio de -437,90, -370,72 e -353,14 para manejo nutricional de 500 kg de N.ha⁻¹.ano⁻¹, 250 kg de N.ha⁻¹.ano⁻¹ e 100 kg de N.ha⁻¹.ano⁻¹, respectivamente.

3.4.2. Clorofilômetro

Um dos fatores ligados à eficiência fotossintética de plantas e consequentemente ao crescimento e adaptabilidade a diversos ambientes é a clorofila. A clorofila é um pigmento com maior presença na natureza e seu principal papel é converter a absorção da luz solar em energia química durante a fotossíntese (NETO et al., 2021).

O teor de clorofila indica a saúde geral da vegetação, e alterações no conteúdo do pigmento foliar podem ter uma relação direta com mudanças na resposta espectral da folha (DELL'ORTO et al., 2019). Os clorofilômetros são instrumentos que aferem de forma indireta e não destrutiva, os teores de clorofila com base nas propriedades óticas das folhas (SILVA et al., 2019).

A concentração de clorofila varia com o crescimento da vegetação. Estimativas de clorofila para o cultivo em diferentes estágios de crescimento pode fornecer ao agricultor informações

críticas sobre a área, servindo de auxílio na tomada de decisões ao monitorar plantações e gerenciar atividades agrícolas para atingir a produção máxima.

O manejo da adubação nitrogenada é fundamental onde há diminuição da concentração dos pigmentos clorofilado, (ocasionada pela carência em N) levando a planta ao estresse nutricional. Essa diminuição interfere na reflectância espectral na região do espectro visível, sendo facilmente identificado através de dados obtidos por um clorofilômetro (COELHO et al., 2018).

Em VENDRUSCULO et al. (2019), por meio de imagens de ARP (RGB) foi calculado o índice MPRI e o correlacionado com as clorofitas A e B de folhas em arvores de citrus obtidas pelo clorofilômetro Clorofilog da Falker. Neste estudo, os autores encontraram similaridade nos valores médios de clorofila A e B (0,62) e valor médio de MPRI de 0,37, porém obtiveram fraca correlação entre as variáveis estudadas.

3.5. Estimativa de atributos por meio de índices de vegetação

Dentre diversas aplicações do SR, das principais contribuições na agricultura destacam-se aquelas relacionadas com o monitoramento e a estimativa de atributos das culturas agrícolas. Os Índices de vegetação podem ser definidos como funções matemáticas entre duas ou mais bandas espectrais, obtidos por sensores remotos, selecionadas com o objetivo de melhorar a relação desses dados com características da vegetação representando com fidedignidade variações da planta e são considerados base do sensoriamento remoto na análise agrícola da vegetação (FORMAGGIO E SANCHES, 2017).

Alguns índices de vegetação foram desenvolvidos com o intuito de encontrar relação entre atributos como biomassa, a quantidade de vegetação e o solo. Pesquisadores como GUO et al. (2021); LIANG et al. (2022); MAIMAITIJIANG, et al. (2019); SAMPAIO (2020) mostram que estimativa de atributos com índices de vegetação tem sido comumente utilizados e tendo modelos de tendência com bons desempenhos.

Em SHAFIAN et al. (2018) foi mostrado que as relações de índices de vegetação com os parâmetros biofísicos das culturas são úteis para prever as características de crescimento do plantio. Quatro índices de vegetação foram calculados usando as imagens de ARPs e dentre esses índices, o índice de vegetação de diferença normalizada (NDVI) mostrou a maior correlação com IAF, fração de cobertura e produtividade com R^2 de 0,91, 0,89 e 0,58, respectivamente.

No trabalho de PEZZOPANE et al. (2019) o objetivo era estimar a massa de forragem do

capim-piatã por meio de índices de vegetação obtidos com um sensor de refletância terrestre. Foram realizadas análises de regressão linear entre índices de vegetação e massa total de forragem. As equações geradas por essas análises foram utilizadas para estimar essas variáveis da pastagem. As melhores estimativas foram obtidas pelo índice SRI (R^2 entre 0,55 e 0,84) para os sistemas a pleno sol, MSR (R^2 de 0,67 a 0,93) para os sistemas sombreados e NDVI (R^2 entre 0,65 e 0,91).

Em HUNT et al. (2005), foi usado o *Normalized Green-Red Difference Index* (NGRDI) para estimar as condições de nutrientes do milho, biomassa da cultura de milho, alfafa e soja. Neste trabalho os autores verificaram que o NGRDI seria sensível à biomassa antes do fechamento do dossel e que as variações na concentração de clorofila nas folhas não seriam detectáveis.

No estudo de ZHOU et al. (2021) o VDVI (índice de vegetação de diferença de luz visível) desempenha um papel melhor e tem melhor aplicabilidade na extração de informações de vegetação de imagem de ARP's apenas na banda visível, para estimar a taxa de cobertura da vegetação do deserto.

4. MATERIAL E MÉTODOS

4.1. Caracterização da área e disposição experimental

O experimento foi conduzido na fazenda FenoRio em uma área de produção comercial de capim Tifton85 (*Cynodon* spp.) localizada na Universidade Federal Rural do Rio de Janeiro, em Seropédica-RJ, Brasil ($22^{\circ} 47' 05''$ S e $43^{\circ} 40' 44''$ W), com solo predominante classificado como argissolo vermelho-amarelo distrófico típico (SANTOS et. al., 2018) e clima segundo a classificação de Köppen (1948), é do tipo Aw, caracterizado por um clima tropical com estação chuvosa no verão e estação seca no inverno.

A área experimental possuiu 0,7 hectares (Figura 2) e o experimento ocorreu em um período de 48 dias a partir do corte de uniformização da forrageira, entre os meses de maio e junho (outono) com coletas em 5 épocas de avaliação. No interior da área experimental foram demarcados 39 pontos georreferenciados com o auxílio do receptor GNSS (Global Navigation Satellite System) de alta precisão Topcon GNSS Hiper e materializados em formas de piquetes com numeração (Figura 3). O aparelho possui 226 canais com precisão horizontal de 5mm + 0,5ppm e vertical de 10mm + 0,8ppm.

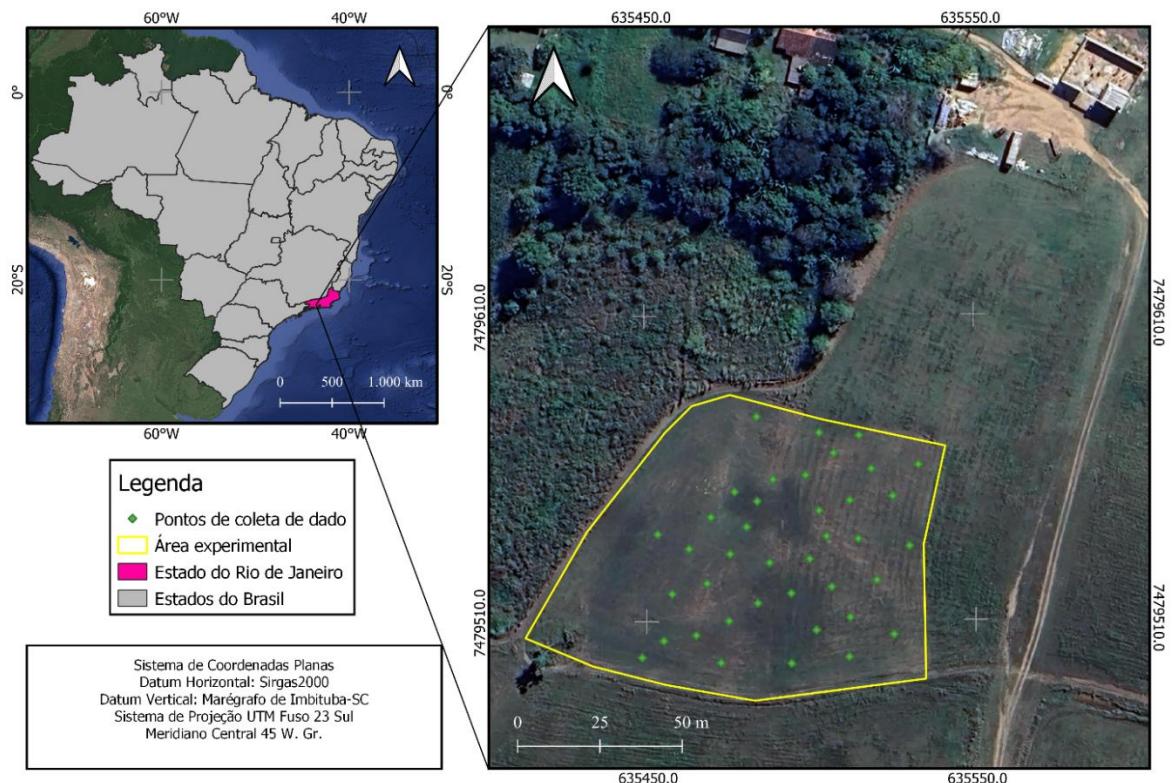


Figura 2. Localização da área de experimental – Fazenda FenoRio/UFRRJ

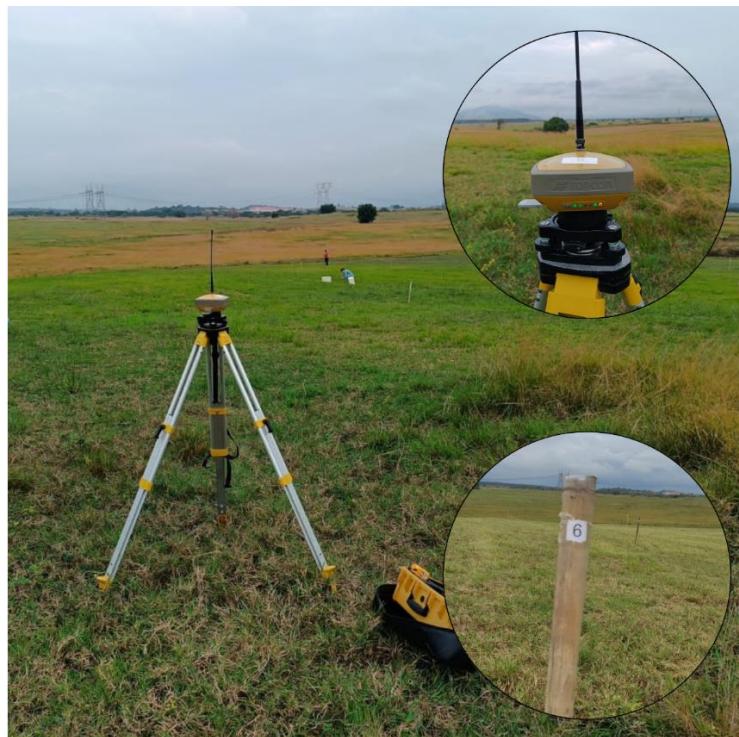


Figura 3. Demarcação dos pontos com RTK.

Para padronizar o crescimento da cultura foi realizado um corte para uniformização do Tifton 85 já cultivado na área, a 0,05 m do solo utilizando uma máquina roçadora Maqtron acoplada ao sistema de levante hidráulico e a tomada de potência (540rpm) do trator John Deere modelo 5403 e potência 65CV. A adubação foi realizada em uma única etapa, 5 dias após o corte de uniformização com 100kg.ha⁻¹ de ureia fórmula 46-00-00 (NPK) com máquina distribuidora de calcário Pinheiro modelo DCP600 light com discos rotativos acoplada a um trator Massey Ferguson modelo 4275 e potência 75CV.

4.2. Caracterização do plano de voo e obtenção dos índices espectrais

As imagens foram coletadas em 5 épocas de avaliação, sendo o primeiro voo realizado ao décimo dia após o corte de uniformização. Os voos seguintes foram realizados em intervalos conforme as datas apresentadas na Tabela 1. Os intervalos foram definidos de modo que as coletas ocorressem em instantes onde houvesse evidente alterações físicas na cultura (altura e volume de biomassa).

Tabela 1. Datas de realização da avaliação da cultura por meio do uso de ARPS e monitoramento dos atributos

Época de avaliação (EA)	Dias após o corte de uniformização	Intervalos entre épocas de avaliação	Data da avaliação
1 ^a EA	10 dias	---	15/05/2023
2 ^a EA	17 dias	7 dias	22/05/2023
3 ^a EA	33 dias	16 dias	07/06/2023
4 ^a EA	40 dias	7 dias	14/06/2023
5 ^a EA	48 dias	8 dias	22/06/2023

Para a coleta das imagens, foi utilizado um ARP modelo DJI Phantom 4 Advanced (Figura 4) que possuiu uma câmera multiespectral de 20 Mp acoplada no interior do equipamento nas seguintes bandas: Banda 1 – Azul ($450\text{nm} \pm 16\text{nm}$), Banda 2 – Verde ($560\text{nm} \pm 16\text{nm}$), Banda 3 – Vermelho ($650\text{nm} \pm 16\text{nm}$), Banda 4 – Borda do Vermelho ($730 \pm 16\text{nm}$) e Banda 5 – Infravermelho Próximo ($840\text{nm} \pm 16\text{nm}$). Este aparelho possui sensor solar espectral integrado no topo da

aeronave para captura de radiação solar, o que possibilitou a correção radiométrica dos dados.



Figura 4. ARP utilizada para aquisição das imagens.

Com auxílio do aplicativo Drone Deploy, foi realizado o planejamento de voo e as configurações da porcentagem de sobreposição entre as faixas longitudinais de 80% e laterais de 70%, altura de 90 metros e sendo obtidas 305 imagens (61 imagens em cada banda) com resolução espacial de 4,8 cm/pixel em 5 minutos de voo.

Após todas as imagens capturadas, foi realizado a ortorretificação, aerotriangulação e a correção radiométrica com as configurações padrões do software Metashape Agisoft®, para montagem do mosaico de fotos para cada dia de voo.

Os ortomosaicos foram inseridos no software QGis, onde foram calculados os índices de vegetação conforme a Tabela 2 utilizando a ferramenta “*raster calculator*”. Após o cálculo dos índices de vegetação, com a ferramenta “*buffer*”, foi criado uma zona de interesse de raio de 1 metro em torno de 39 pontos georreferenciados demarcados previamente. Em seguida, obteve-se o valor médio dos índices de vegetação para cada zona de interesse utilizando a ferramenta “*statistic zonal*”.

Tabela 2. Índices de vegetação calculados utilizando dados espectrais obtidos por ARP.

Índice	Fórmula	Autor
--------	---------	-------

Green Normalized Difference Vegetation	$GNDVI = \frac{(NIR - G)}{(NIR + G)}$	GITELSON et al. (1996)
Normalized Difference Vegetation Index	$NDVI = \frac{(NIR - R)}{(NIR + R)}$	ROUSE JR et al. (1973)
Normalized Green-Red Difference Index	$NGRDI = \frac{(G - R)}{(G + R)}$	HUNT et al. (2005)
Ratio Vegetation Index	$RVI = \frac{(NIR)}{(R)}$	JORDAN (1969)
Soil-Ajusted Vegetation Index	$SAVI = \frac{(NIR - R)}{(NIR + R + L) * (1 + L)}$	HUETE (1988)
Visible atmospherically resistant index	$VARI = \frac{(G - R)}{(G + R - B)}$	GITELSON et al. (2002)
Visible Difference Vegetation Index	$VDVI = \frac{(2 * G - R - B)}{(2 * G + R + B)}$	XIAOQIN et al. (2015)

Onde: R é a reflectância proveniente do canal vermelho da região do visível; G é a reflectância proveniente do canal verde da região do visível; B é a reflectância proveniente do canal azul da região do visível; NIR é a reflectância proveniente do canal do infravermelho próximo da região do infravermelho próximo; L é uma constante com o objetivo de minimizar o efeito do solo, seus valores variam de 0 a 1, sendo 1 para baixas densidades de vegetação, 0.5 para médias densidades e 0.25 altas densidades. Neste estudo foi escolhido L=1, já que pastagens possuem baixas densidades (DE ALMEIDA et al., 2019).

4.3. Obtenção dos atributos da cultura

As mensurações dos atributos altura da planta, índice de área foliar (IAF) e clorofila foram realizadas nos 39 pontos georreferenciados. As medidas ocorreram nas 5 épocas de avaliação, em conjunto com a obtenção das imagens pelo ARP, totalizando um universo amostral de 195 mensurações para cada atributo biofísico nos 48 dias de experimento.

Para a mensuração da altura da planta foram realizadas 5 aferições (leitura visual de uma régua graduada com precisão milimétrica) em torno de cada ponto georreferenciado, sendo obtido o valor médio, o qual representou a mensuração associada a cada ponto, conforme Figura 5.



Figura 5. Aferição da altura do Tifton85.

Para a coleta do IAF, foi utilizado o ceptômetro AccuPAR LP-80 (Figura 6), para determinação do crescimento do dossel e a sua interceptação de luz. A técnica combina medidas tomadas com o sensor acima do dossel com medidas tomadas sob o dossel próximas ao nível do solo. Este aparelho possui uma barra de 80cm com 80 sensores PAR (Radiação Fotossinteticamente Ativa) linearmente espaçados e um sensor PAR externo.

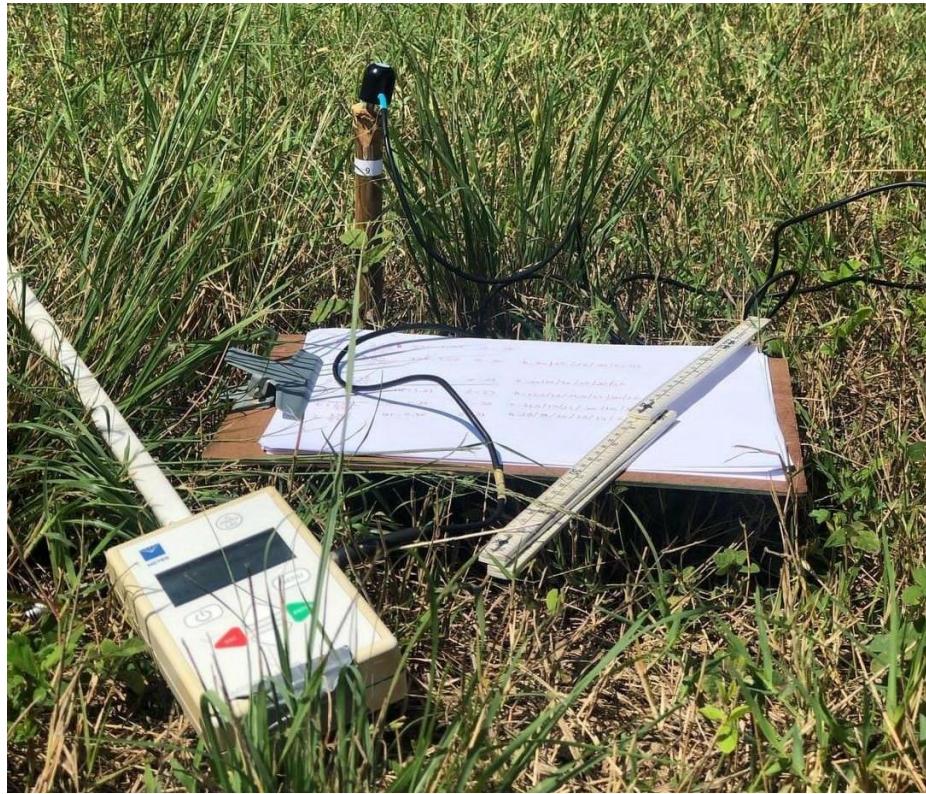


Figura 6. Ceptômetro utilizado na medição do IAF na cultura.

Inicialmente foi configurado a data, hora e local do experimento em cada dia de coleta. Em seguida, posicionou-se a barra do aparelho rente ao solo, abaixo do dossel e simultaneamente posicionado o sensor PAR externo acima do dossel para a realização de uma medição (Figura 7). Repetiu-se 5 vezes em cada ponto, alternando as posições do ceptômetro, onde cada amostra representa a média de 5 medições em torno do mesmo ponto. Vale ressaltar, que se atentou para a direção do sol, não fazendo sombra no dossel na hora da coleta dos dados.



Figura 7. Aferição do IAF com o ceptômetro.

A clorofila presentes nas folhas do Tifton85 foi mensurada utilizando um clorofilômetro Falker modelo clorofiLOG CFL1030 (Figura 8). Para esta aferição, utilizou-se as leituras associadas a Clorofila B, a qual possui picos de absorção em torno de 453 nm (azul) e 642 nm (alaranjado). Cada ponto representou a média de 5 medições em torno de cada ponto georreferenciado. Cada medição correspondeu à média de 5 leituras na mesma folha.



Figura 8. Clorofilômetro utilizado para mensuração de clorofila.

Ao final dos 48 dias de experimento, foi realizado o corte (colheita) da cultura nos 39 pontos georreferenciados para cálculo da biomassa. Para a coleta da massa vegetal fresca em campo, foi utilizado um gabarito quadrado de 0,0625 m² (Figura 9). A vegetação contida no interior do gabarito foi cortada rente ao solo com auxílio de uma tesoura. As amostras foram armazenadas em sacos de papel vedados e identificados, levadas ao Laboratório de Pesquisa Multiusuários do Grupo de Energias Renováveis e Alternativas Rurais (LabGERAR) onde passaram pelo processo de secagem na estufa (Figura 10), a uma temperatura forçada a 65°C por 72 horas. Posteriormente as amostras foram pesadas na balança semi analítica Marte AD200 (Figura 11), resultando na quantificação da matéria seca de forragem (biomassa) para cada ponto.



Figura 9. Gabarito utilizado e coleta de massa fresca do Tifton85.



Figura 10. Estufa utilizada para secagem da massa fresca.



Figura 11. Balança utilizada para medição da biomassa.

4.4. Caracterização do ambiente e obtenção dos graus-dias

O crescimento e desenvolvimento dos cultivos estão diretamente relacionados com a temperatura do meio ambiente. O monitoramento do plantio com graus-dia é uma ferramenta muito utilizada para o planejamento agrícola pois possibilita o acompanhamento em tempo real/térmico do desenvolvimento das culturas, sendo mais confiável que o tempo cronológico, o tempo necessário que cada cultura exige para atingir determinada fase fenológica em qualquer localidade.

Durante o período de realização do experimento, os dados de temperatura do ar e umidade relativa do ar (UR) foram monitorados pela estação meteorológica automática de superfície do Instituto Nacional de Meteorologia (INMET), localizada em Seropédica ($22^{\circ}45'13''$ S e $43^{\circ}40'23''$ W).

Para o cálculo de graus-dia foi utilizado o método do menor desvio padrão, proposto por ARNOLD (1959), também conhecido como método Residual (Equação 3). Para a obtenção dos graus-dias foram utilizadas as temperaturas máximas e mínimas do dia da aquisição das imagens pelo ARP.

$$GD = \sum_i^n \left[\left(\frac{T_{máx_i} + T_{mín_i}}{2} \right) - T_{base} \right] \quad (3)$$

Onde:

GD - Graus-dia ($^{\circ}\text{C}$);

Tmáx - temperatura máxima diária do ar ($^{\circ}\text{C}$);

Tmín - temperatura mínima diária do ar ($^{\circ}\text{C}$);

Tbase - temperatura base ($^{\circ}\text{C}$).

Nos trabalhos de CARLI (2009), MALLMANN (2007) e SILVA (2014) considerou-se a temperatura base para o crescimento do Tifton85 de 10°C . Portanto, esse foi o valor considerado para o acúmulo de graus-dia nesta pesquisa.

4.5. Análise dos dados

4.5.1. Resposta dos atributos do Tifton85 em função dos graus-dias

Os dados meteorológicos de temperatura e umidade relativa do ar foram organizados e tabulados em planilha eletrônica e plotados em função das datas de avaliação (climograma).

Em seguida, utilizando os dados de temperatura máxima e mínima, foi elaborada uma tabela para melhor compreensão do comportamento dos graus-dias ao longo dos dias do experimento. A data de início coincidiu com o dia de corte de uniformização da área (dia 0).

Os graus-dia foram calculados para cada intervalo, possibilitando obter a quantidade de calor acumulado durante esse período. Os graus-dia acumulados foram então determinados, somando os graus-dia de cada intervalo anterior. A proporção dos graus-dia acumulados em relação ao total previsto para o período inteiro foi calculada.

A partir da tendência de dispersão dos atributos da cultura, foi realizada análises de regressão simples para cada atributo em função dos graus-dias, associados a cada época de avaliação. Os valores de índice de área foliar, clorofila e altura foram as variáveis dependentes do modelo, e os graus-dias foram as variáveis independentes.

4.5.2. Avaliação da resposta dos índices de vegetação utilizando componentes principais

Neste item, utilizou-se o software R Studio 4.3.3 para aplicar a análise de componentes principais (ACP). Os dados foram organizados em uma matriz de 195 observações (leituras por ponto georreferenciado) e 7 variáveis (IVs). A ACP foi executada para investigar a estrutura dos

dados e identificar padrões subjacentes, com objetivo de reduzir o conjunto de informações e obter os índices mais relevantes.

Inicialmente foi avaliada a porcentagem explicativa e porcentagem explicativa acumulada de cada componente principal. O conjunto de CPs com poder explicativo acumulado maior que 70% da variância dos dados foi considerada o relevante para a redução do dimensionamento de variável. Ressalta-se que os dados não foram normalizados, uma vez que as combinações lineares geradas pela ACP foram obtidas pela matriz de correlação das variáveis originais.

A correlação dos índices espectrais com cada CP relevante e seus respectivos coeficientes (*loadings*) também foram avaliados. Os coeficientes associados aos CP relevantes foram utilizados para compor um índice de crescimento da cultura (ICC).

4.5.3. Estimativa dos atributos do Tifton85 em função dos índices de vegetação e geração dos mapas de estimativa

Devido à grande variabilidade das amostras observada, os dados obtidos foram dispostos em classes tendo como referência o erro de precisão do ceptômetro (erro=0,1) utilizado para mensurar a área foliar. Os demais atributos foram alocados de acordo com a classe do IAF. Desta forma, os 195 pontos amostrais coletados ao longo do experimento foram redistribuídos em 15 classes (novos pontos amostrais), as quais foram representadas pelos valores médios dos atributos, e dos índices de vegetação alocados em cada classe.

Em planilha eletrônica, foi calculado a correlação de Pearson dos índices de vegetação com os atributos e selecionou-se o IVs que apresentaram a maior correlação com cada atributo biofísico para geração dos modelos de estimativa. Os modelos de estimativa univariados foram gerados por meio de uma regressão linear simples associando cada IV com cada atributo da cultura. Também foi gerado um modelo multivariado para estimativa dos atributos da cultura com base na relação linear entre atributos e o ICC gerado pela ACP.

Após a definição de cada equação de estimativa para os atributos, utilizando a ferramenta “*raster calculator*”, as equações foram importadas e aplicadas para a elaboração dos mapas de estimativa dos atributos em função dos índices de vegetação. O mesmo processo foi realizado para a elaboração dos mapas de estimativa dos atributos em função do índice multivariado ICC.

4.6. Predição da biomassa em função dos índices de vegetação

Devido a grande variabilidade observada, os dados foram agrupados para realizar a análise da relação entre a biomassa seca e os índices de vegetação (IVs) ao longo do experimento. Inicialmente, em planilha eletrônica, os dados de biomassa seca final foram dispostos em classes em intervalos de 10 unidades, gerando assim 8 pontos (média dos valores dispostos em cada classe). Os IVs foram agrupados de acordo com os pontos previamente definidos pela biomassa e separados por épocas de avaliação.

Em seguida, foi feito a correlação entre os IVs e a biomassa final para cada EA, permitindo assim, um estudo sobre qual época de avaliação apresentava a correlação mais forte com a biomassa final. Para a predição de biomassa, foi feita a regressão polinomial de grau 2 entre os valores de biomassa e o índice de vegetação que obteve maior correlação com a biomassa dentre todas as épocas de avaliação. Por fim, foi gerado o mapa de predição da biomassa final no software QGis utilizando a ferramenta “*raster calculator*” com a equação de regressão obtida.

5. RESULTADOS E DISCUSSÃO

5.1. Resposta dos atributos em função dos graus-dias

Conforme observado na Figura 12, ao longo do período do experimento (05/05/2023 à 22/06/2023) a temperatura do ar média diária observada na estação meteorológica automática do INMET foi de 21 °C, com temperaturas mínima e máxima absolutas de 17,5 °C (20/06/2023 - próximo a 5EA) e 25 °C (06/05/2023 - próximo a 1EA). A umidade relativa do ar média (UR média) registrada pela estação meteorológica ao longo do período do experimento variou entre 64 e 90%. A menor UR média observada (64%) ocorreu no dia 10/06/2023 (próximo a 3EA).

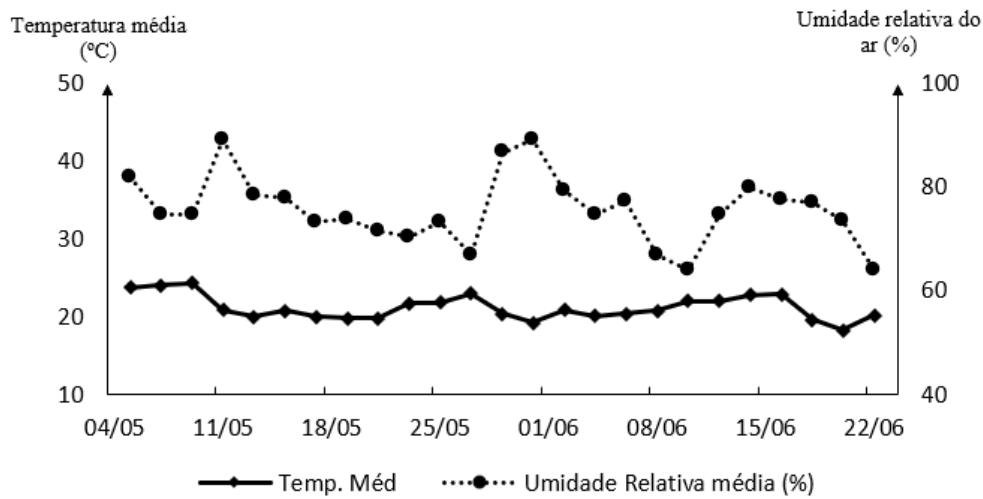


Figura 12. Climograma das médias das variáveis meteorológicas registradas durante o período de condução do experimento.

Durante o experimento, constatou-se que os dias com os níveis mais altos de umidade relativa estavam associados a períodos de chuva. Especificamente no dia 30/05/2023 onde obteve-se a umidade relativa mais elevada 89,25% e registrou-se um total de 22 mm de precipitação. Um período contínuo de chuvas foi observado entre os dias 25 de maio e 02 de junho (entre a 2EA e 3EA). O excesso de umidade pode afetar tanto a produtividade quanto a qualidade das culturas agrícolas.

A umidade relativa do ar e a temperatura são dois dos principais fatores climáticos que influenciam a produtividade das forrageiras. Em CRUZ et. al. (2021) os autores alertaram que a temperatura exerce influência sobre diversas atividades metabólicas das plantas, destacando que variações nesse fator ambiental têm impacto direto no processo de desenvolvimento. Além disso, os autores enfatizam que a amplitude térmica presente no ecossistema de pastagem desencadeia efeitos na produção de biomassa do dossel forrageiro, resultando em modificações na dinâmica de acúmulo de forragem e em diversos atributos.

Na Tabela 3, os resultados apresentados revelam um panorama detalhado do acumulado térmico ao longo do experimento. Observou-se um acúmulo gradativo de graus-dias ao longo do período de coleta, culminando em um valor acumulado de 548,692 °C.dia. Destaca-se, o pico de graus-dias alcançado em 06/05/2023, logo no início do experimento (entre o corte e a 1EA), quando registrou-se o valor de 14,508 °C.dia. Além disso, é relevante salientar a identificação da época de maior acúmulo, evidenciada pela proporção de 32,233% na 3EA, indicando o período de maior

ganho proporcional de graus-dias durante o experimento.

Tabela 3. Acúmulo de graus-dias ao longo do experimento

Período	Corte	1 EA	2 EA	3 EA	4 EA	5 EA
Número de dias	0	10	17	33	40	48
GDD	13,863	10,879	10,917	9,746	12,858	10,258
GDD ac	13,863	136,544	205,031	381,892	465,479	548,692
Proporção (%)	2,526	22,359	12,482	32,233	15,234	15,166
Proporção ac (%)	2,526	24,885	37,367	69,600	84,834	100,000

GDD: Graus dias; GDD_{ac}: Graus-dias acumulado; Prop_{ac}: Proporção acumulada.

O conceito de graus-dia considera que para completar uma determinada fase fenológica ou seu ciclo total, a planta necessita acumular um determinado somatório térmico, a partir de uma temperatura base favorável ao desenvolvimento sendo esta variável com cada planta (SANCHES, 2018). Para entender o desenvolvimento dos atributos estudados em relação aos graus-dias, foi gerado um modelo de regressão polinomial de grau 2 para os atributos Clorofila (Figura 13a) e IAF (Figura 13c). A parábola que representa a linha de tendência tem a concavidade voltada para baixo, expressando que o coeficiente da função é negativo ($a < 0$), ou seja, há uma crescente nas medidas dos atributos até aproximadamente 350 °C.dias e após isso há queda nas medidas. No caso da altura (Figura 13b), a parábola apresenta concavidade voltada para cima (coeficiente positivo, $a > 0$) demonstrando que há uma pequena queda até próximo a 250 °C.dias, mas que a partir de 300°C.dias há um crescimento em relação ao aumento do acúmulo de graus dias.

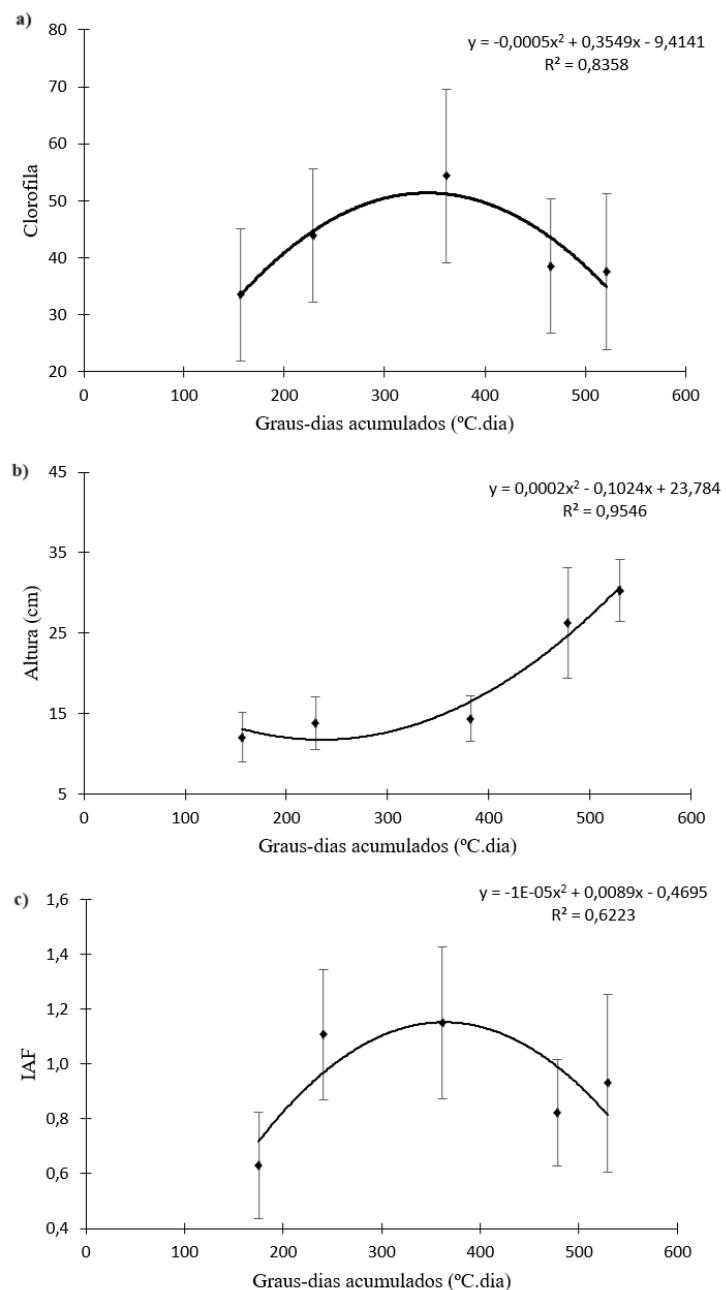


Figura 13. a) Relação entre clorofila e graus-dias acumulados no crescimento do Tifton85. b) Relação entre altura e graus-dias acumulados no crescimento do Tifton85. c) Relação entre IAF e graus-dias acumulados no crescimento do Tifton85.

Em seu estudo, BEZERRA (2022) encontrou uma relação linear entre o acúmulo de graus-dia ($^{\circ}\text{C}$) e o Índice de Área Foliar (IAF) para diferentes manejos nutricionais de cultura forrageira.

Os parâmetros do modelo agroclimático indicaram essa relação, com valores de 0,0061; 0,0045 e 0,003 para os manejos nutricionais alto, médio e baixo, respectivamente. Enquanto o estudo de Bezerra destaca uma relação direta, sugerindo que a cada grau acumulado, haverá um acréscimo constante no IAF, o presente trabalho explora essa relação não linear. Em todas as funções obteve-se R^2 acima de 0,6, indicando que os modelos gerados possuem um poder razoável de explicação, sendo significativos a um nível de 5%. O atributo que teve maior poder explicativo foi a altura ($R^2 = 0,95$) e o de menor poder explicativo foi o IAF ($R^2=0,64$).

O crescimento de forrageiras ao longo de 181 dias sob diferentes níveis de sombreamento durante o outono e inverno foi verificado por BORGES (2020) que obteve uma variação nos graus dias acumulados para cada nível de sombreamento nas plantas. O autor concluiu que para a condição do experimento, a produção de massa seca da forrageira estudada não revelou influência significativa do sombreamento e que as plantas cultivadas sob sombreamento exibiram uma altura de corte superior em comparação com as cultivadas a pleno sol.

5.2. Avaliação da resposta dos índices de vegetação utilizando componentes principais

A partir da análise exploratória (Tabela 4) dentre os índices avaliados, os índices NGRDI, VARI e VDVI foram os que apresentaram a menor diferença entre média e mediana (diferença menor que 0,01), demonstrando que esses índices possuem distribuição próxima de um valor central e que, no geral, todos obtiveram valores bem próximos, sugerindo uma distribuição dos dados em torno do centro sem grandes desvios.

Tabela 4. Análise descritiva dos dados dos índices de vegetação calculados

	GNDVI	NDVI	NGRDI	RVI	SAVI	VARI	VDVI
Nº de amostras	195	195	195	195	195	195	195
Média	0,4843	0,5822	0,1458	4,1178	0,8732	0,1110	0,2177
Mediana	0,4970	0,6012	0,1539	4,1381	0,9016	0,1175	0,2243
Mínimo	0,3122	0,3060	-0,0065	1,9142	0,4589	-0,0056	0,1107
Máximo	0,5886	0,7679	0,3279	7,6858	1,1516	0,2519	0,3513
Amplitude	0,2764	0,4619	0,3344	5,7716	0,6927	0,2574	0,2406
Desvio padrão	0,0568	0,0912	0,0627	1,0540	0,1367	0,0479	0,0442
Normalidade	0,000018	0,0000036	0,00396	0,2375	0,0000037	0,0342	0,0173
Curtose	0,1539	0,2415	-0,2345	-0,0399	0,2414	-0,2058	-0,2734
Assimetria	-0,7211	-0,7912	-0,2431	0,1957	-0,7911	-0,2416	-0,1696
Soma	94,4341	113,5298	28,4327	802,9715	170,2661	21,6496	42,4420
CV (%)	0,1173	0,1566	0,4300	0,2560	0,1566	0,4315	0,2030

Em relação ao coeficiente de curtose, três índices apresentaram distribuição leptocúrtica com picos e caudas alongados e p-valor baixíssimo: O GNDVI, NDVI e SAVI. Essa combinação indica que os dados não são normalmente distribuídos. Os índices NGRDI, VARI e VDVI apresentaram distribuição platicúrtica, indicando uma curva achatada e valores de p-valor próximos a 0, o que sugere a não distribuição normal dos dados. Com valor de curtose de 0,0399, o índice RVI apresenta uma distribuição mesocúrtica e maior p-valor dos dados observados (0,2375), o que indica que este índice possui a distribuição dos dados mais próxima ao da distribuição normal.

Sobre a assimetria dos dados, somente o índice RVI possui distribuição assimétrica à direita ($\text{Ass.} > 0$), enquanto os índices GNDVI, NDVI, NGRDI, SAVI, VARI e VDVI apresentaram distribuição assimétrica à esquerda ($\text{Ass.} < 0$). A análise do coeficiente de variação mostrou que, com base na classificação proposta por WARRICK & NIELSEN (1980), os índices NDVI, NGRDI, RVI, SAVI, VARI e VDVI apresentaram variação média ($12\% < \text{CV} < 60\%$), enquanto o GNDVI apresentou variação baixa ($\text{CV} < 12\%$).

Os índices de vegetação são fundamentais na agricultura e fornecem uma avaliação direta e confiável das condições dos cultivos. Dependendo do IV, informações sobre vários aspectos do crescimento e desenvolvimento das plantas podem ser monitorados, como teor de clorofila, índice

de área foliar, altura, entre outros. Estudos com IVs tem sido amplamente utilizado para diversas finalidades (OLIVEIRA, 2024; DE MELLO et al., 2020).

No trabalho de KOBAYASHI et al. (2020) foram analisados 91 índices espectrais para classificação de culturas a partir de imagens do satélite Sentinel-2. O uso de índices espectrais melhorou a precisão da classificação dessas culturas atingindo precisão global de 93,0%.

Em LISBOA (2020) o objetivo foi determinar e testar possíveis correlações entre Índices de Vegetação (IVs) e massa de forragem, altura e proteína bruta do capim-braquiária. Os resultados indicaram o potencial dos IVs para serem utilizados em modelos preditivos desses parâmetros.

Em alguns casos a utilização de uma grande quantidade de dados pode ser desafiadora, exigindo recursos computacionais robustos e podendo até inviabilizar a análise univariada devido à sua complexidade (STELLACCI, et al., 2021).

A utilização de uma grande quantidade de dados pode ser desafiadora. Dados coletados em campo estão sujeitos a influências externas, podendo afetar a variabilidade desses e tornar a análise univariada mais complexa ou até mesmo inviável.

A coleta de dados em campo está suscetível a influências externas que afetam a variabilidade dos dados. Essas influências incluem condições climáticas variáveis e fatores ambientais imprevisíveis como por exemplo, tempestades, secas, deslizamentos, alta variação de temperatura, ventos fortes, entre outros. Essa complexidade na variabilidade dos dados pode tornar a análise univariada desafiadora, já que cada variável é considerada isoladamente, sem levar em conta interações e correlações entre múltiplas variáveis.

Nesse contexto, a análise multivariada emerge como uma ferramenta poderosa na compreensão das complexas interações dentro de sistemas agrícolas, como os relacionados aos índices de vegetação. Ao estudar simultaneamente várias variáveis, essa abordagem revela padrões e relações que não seriam perceptíveis em análises univariadas, proporcionando ganhos significativos de informação, permitindo uma compreensão mais abrangente dos processos que influenciam o crescimento das plantas e a produtividade das colheitas.

Utilizou-se a análise de componentes principais para entender o comportamento dos IVs e posteriormente obter um modelo de estimativa dos atributos em relação aos índices de vegetação com menor número de variáveis. Ao analisar os percentuais explicativos (Tabela 5), destaca-se a primeira componente principal (CP1) onde constitui 99,94% da variação dos índices espectrais. Este resultado sugere que todas as informações geradas nos IVs podem ser representadas de forma

abrangente apenas por essa variável. Além disso, essa possui autovalor acima de 1 o que reforça a capacidade da CP1 em representar todos os dados.

Tabela 5. Autovalores (Autow), Percentual explicativo (PE) e percentual explicativo acumulado (PEAc) associada aos componentes principais gerados

CP	CP1	CP2	CP3	CP4	CP5	CP6	CP7
Autow	6,795	0,155	0,041	0,007	0,0001	~ 0,00	~ 0,00
PE (%)	99,944	0,052	~ 0,00	~ 0,00	~ 0,00	~ 0,00	~ 0,00
PEAc (%)	99,944	99,996	~ 100	~ 100	~ 100	~ 100	~ 100

Na Tabela 6, são apresentados os dados de correlação entre os IVs e CP1 e os coeficientes de cada índice (*loadings*) com a CP1. Os resultados reforçam que todos os atributos apresentaram alta correlação com o CP1, e indicam que são correlacionáveis entre si e, portanto, podem ser substituídos pela CP1.

Tabela 6. Correlação e coeficientes entre os índices espectrais (IVs) e Componente Principal 1

	GNDVI	NDVI	NGRDI	RVI	SAVI	VARI	VDVI
Correlação	0,969	0,993	0,992	0,983	0,993	0,991	0,974
Coeficientes	0,372	0,381	0,380	0,377	0,381	0,380	0,374

Todos os IVs analisados apresentaram pesos semelhantes, refletido nos valores dos coeficientes em patamares aproximados. Os coeficientes indicaram a contribuição de cada variável original em cada componente principal e os valores positivos indicaram uma relação positiva com o CP1. Essa similaridade nos pesos indica que cada índice contribuiu de maneira similar para a avaliação do desenvolvimento do Tifton85.

Como o CP1 apresentou um poder explicativo de 99,94%, este componente principal pode ser usado para gerar um modelo global que possibilite monitorar a cultura. Sendo assim, neste estudo é proposto um novo índice denominado Índice de Crescimento da Cultura (ICC) construído a partir da componente principal 1. Os coeficientes associados a cada índice espectral compõem o ICC (Equação 3) que expressa o crescimento da cultura, sendo que quanto maior o índice, mais a cultura está desenvolvida.

$$\text{ICC} = C_1 \cdot \text{GNDVI} + C_2 \cdot \text{NDVI} + C_3 \cdot \text{NGRDI} + C_4 \cdot \text{RVI} + C_5 \cdot \text{SAVI} + C_6 \cdot \text{VARI} + C_7 \cdot \text{VDVI} \quad (3)$$

onde C_x são os coeficientes associados a cada variável original que compõe a componente principal 1.

Na Figura 14 têm-se a dispersão dos pontos amostrados em um plano bidimensional formado pelos componentes principais CP1 e CP2 (componentes mais relevantes). Observa-se um aumento nos valores de CP1 e CP2 da 1EA para a 3EA o que revela um padrão de crescimento ao longo das épocas de avaliação. A partir da 3EA, ocorre uma mudança no comportamento no qual as amostras (3EA, 4EA e 5EA) se agrupam mais próximas, o que sugere menor distinção entre os valores a partir da 3EA. Isso indica que após a 3EA esses valores se estabilizaram, sugerindo que a partir dessa época (após 33 dias de experimento) os índices espectrais apresentem mais dificuldades em se relacionar com os atributos da planta.

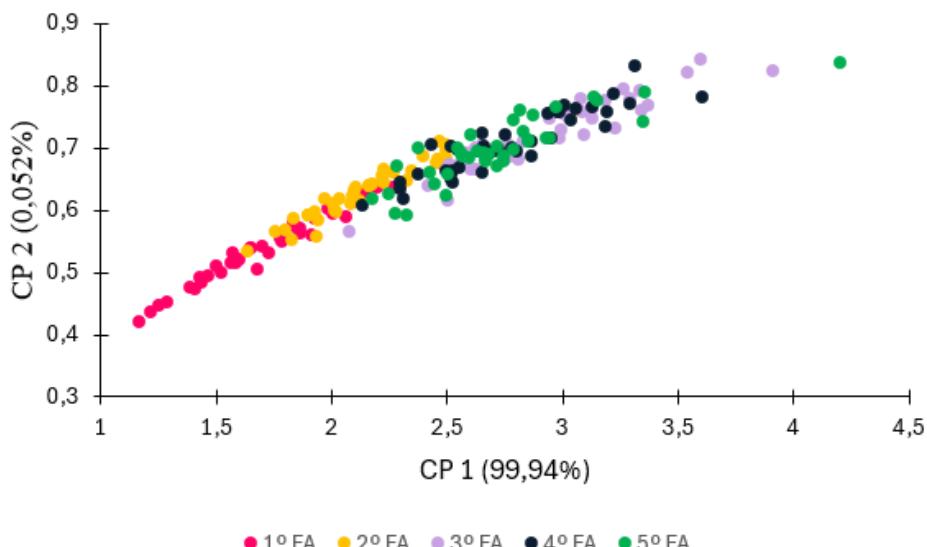


Figura 14. Dispersão no plano bidimensional dos scores do primeiro e segundo componente principal (CP1 e CP2) do grupo de dados.

Analizando o índice proposto, pode-se definir quanto maior o ICC, maior é o estágio de crescimento da cultura. Em alguns instantes há períodos de transição onde o ICC pode representar mais de um estágio de crescimento. Em geral, valores abaixo de 2,00 remetem predominantemente o crescimento da cultura até a 10 dias (1EA). ICC entre 2,00 e 2,50 remete predominantemente a

cultura com crescimento até a 2 EA (17 dias). Valores de ICC acima de 2,50 remetem predominantemente a cultura com crescimento superior a 3EA (33 dias).

É importante destacar que o ICC é calculado a partir da resposta de diversos índices espectrais o que lhe atribui uma característica robusta e ampla do ponto de vista das informações que compõe esses índices. Como se nota na Figura 14, o ICC apresenta grande potencial para o acompanhamento do crescimento da cultura, sendo um índice alternativo e inovador para monitoramento de lavouras a partir das características espectrais. Além do mais, o ICC tem potencial de aplicação em lavouras com grande nível de variabilidade onde muitas vezes a análise a partir de um único IV tenha dificuldade em monitorar algum atributo da cultura.

5.3. Estimativa dos atributos em função dos índices de vegetação

A dependência entre as variáveis foi avaliada pelo cálculo do coeficiente de correlação linear de Pearson (r). Conforme FERREIRA FILHO et al. (2020), as correlações são classificadas em cinco intervalos: correlação muito fraca ($0 < r < 0,19$); fraca ($0,20 < r < 0,39$); moderada ($0,40 < r < 0,69$); forte ($0,70 < r < 0,89$); muito forte ($0,90 < r < 1$).

A Tabela 7 mostra a correlação entre os atributos e os índices de vegetação. O índice VARI foi o que apresentou a maior correlação com a clorofila, com $r = 0,848$. Para a altura, o IV com maior correlação foi o GNDVI, $r = 0,719$. Por fim, na análise em questão, o NDVI foi o índice de vegetação que apresentou maior correlação com o IAF ($r = 0,869$). Em todos os casos, foram obtidas correlações fortes positivas onde o crescimento de uma variável é diretamente proporcional a outra.

Tabela 7. Correlação entre atributos da cultura e índices de vegetação

	Clorofila	Altura	IAF	GNDVI	NDVI	NGRDI	RVI	SAVI	VARI	VDVI
Clorofila	1									
Altura	0,427	1								
IAF	0,885	0,509	1							
GNDVI	0,796	0,758	0,848	1						
NDVI	0,815	0,757	0,868	0,996	1					
NGRDI	0,846	0,739	0,845	0,977	0,987	1				
RVI	0,836	0,717	0,788	0,965	0,966	0,987	1			
SAVI	0,815	0,757	0,868	0,996	0,999	0,987	0,966	1		
VARI	0,848	0,742	0,842	0,974	0,985	0,999	0,987	0,985	1	
VDVI	0,830	0,738	0,835	0,970	0,983	0,998	0,983	0,983	0,997	1

Em seu trabalho, MONTANARO & ROSA (2022) objetivou correlacionar o índice de vegetação NDVI com índice de clorofila e produtividade da soja em diferentes dias após a semeadura (DAS). Na correlação da produtividade e NDVI, os melhores resultados foram com 117 DAS (0,60), e 107 DAS (0,53), ambas classificadas como moderadas. Para as correlações entre clorofila e NDVI, os resultados apresentaram baixa correlação com maior valor para 0,46, com NDVI a 117 DAS.

Ao contrário de MONTARO & ROSA (2022), o presente estudo obteve correlações fortes em todos os atributos. Esses resultados sugerem que dentre os 7 IVs estudados, o VARI é o índice mais indicado para estimar o conteúdo de clorofila, o GNDVI é o índice mais indicado para estimar a altura e o NDVI é o índice mais indicado para estimar o índice de área foliar. Portanto, estes foram os índices escolhidos para a realização da regressão linear e geração do modelo de estimativa.

Ao realizar a regressão linear entre os atributos e os IVs escolhidos, o índice com maior coeficiente de determinação (R^2) em relação ao respectivo atributo foi o NDVI com o IAF (Figura 15c) com $R^2=0,7539$. Esse valor indica que 75% da variação do IAF é explicada pelo índice. Para a clorofila e o VARI (Figura 15a), obteve-se o coeficiente de determinação de 0,7202, o que significa que 72% da variação da clorofila é explicada pelo índice VARI. No caso da altura e GNDVI (Figura 15b), obteve-se o menor R^2 , de 0,5744, o que significa que apenas 57% da variação

da altura é explicada pelo índice GNDVI. Apesar de ser o menor R², ainda sim possui um bom poder explicativo.

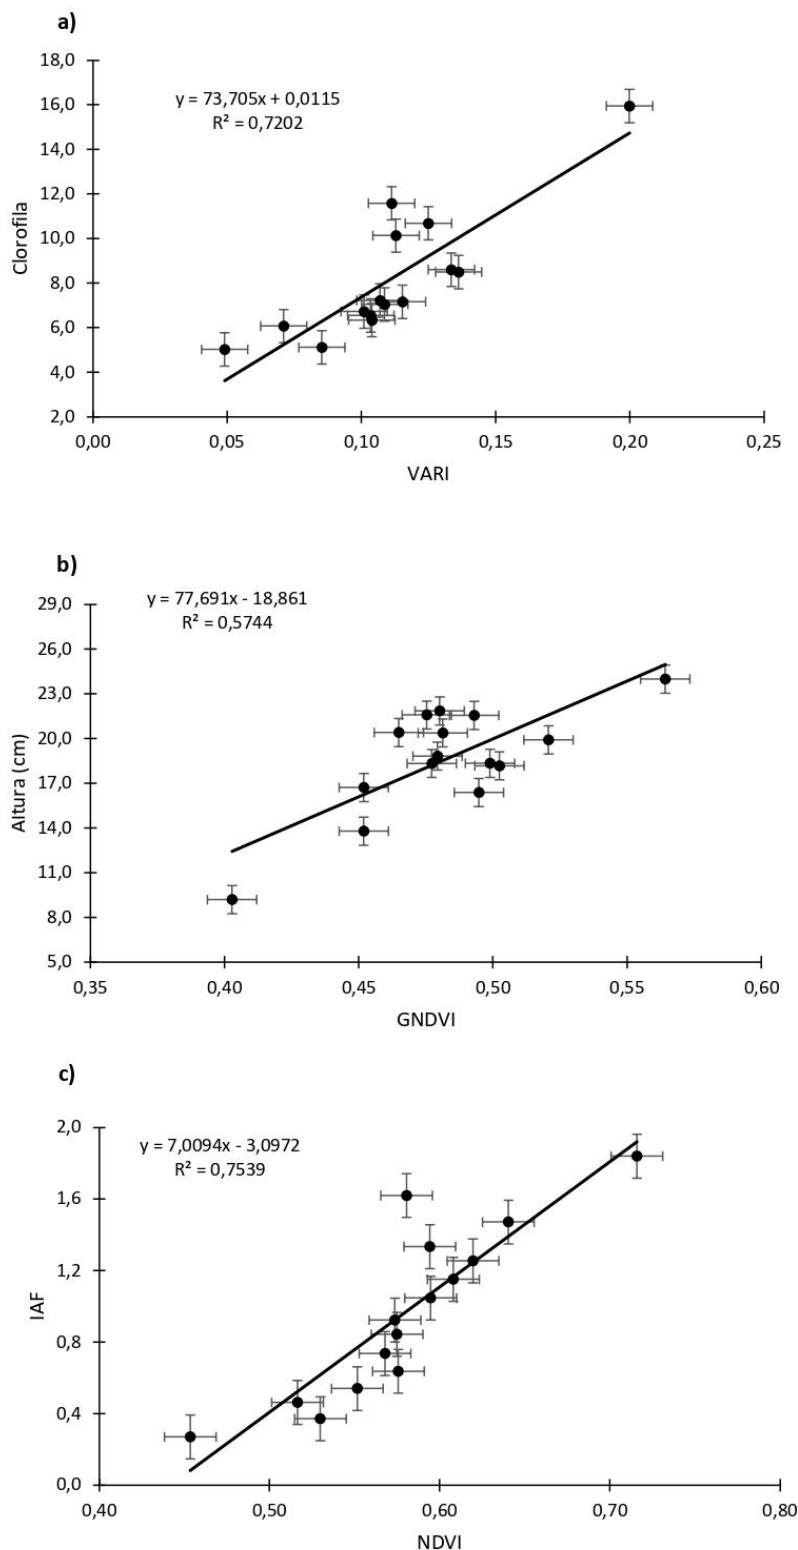


Figura 15. Regressão entre Clorofila e VARI (a); Regressão entre Altura e GNDVI (b); Regressão entre IAF e NDVI (c).

A utilização de modelos multivariados, como a Regressão por Componentes Principais, oferece diversas vantagens na análise da relação entre atributos da cultura e índices de vegetação (SOUZA et al., 2024). Em abordagens univariada, apenas um índice de vegetação é considerado de cada vez. Já os modelos multivariados permitem a integralização de informações de múltiplos IVs em uma única estrutura analítica, tornando a análise mais abrangente e podem capturar de forma mais precisa a variação nos dados e fornecer estimativas mais robustas dos atributos da cultura.

Neste estudo, em todos os atributos foram obtidas correlações fortes ($0,70 < r < 0,89$) e positivas com o ICC, assim como na análise realizada individualmente com todos os índices. Para o atributo Clorofila, obteve-se a maior correlação (0,83) seguido de 0,81 para IAF e 0,73 para altura.

Na elaboração da regressão para a clorofila (Figura 16a) e para altura (Figura 16b), foi observado que as equações empregando o ICC resultaram em valores de coeficiente de determinação similares as utilizando somente um índice de vegetação. No caso da clorofila, obteve-se R^2 de 0,7009 e altura $R^2 = 0,5336$. Esses valores indicam que 70% da variação da clorofila é explicada pelo ICC e que 53% da variação da altura é explicada pelo ICC. No entanto, o modelo de regressão do IAF e ICC (Figura 16c), apresentou um coeficiente de determinação de 0,6582 (65% da variação do IAF é explicada pelo ICC).

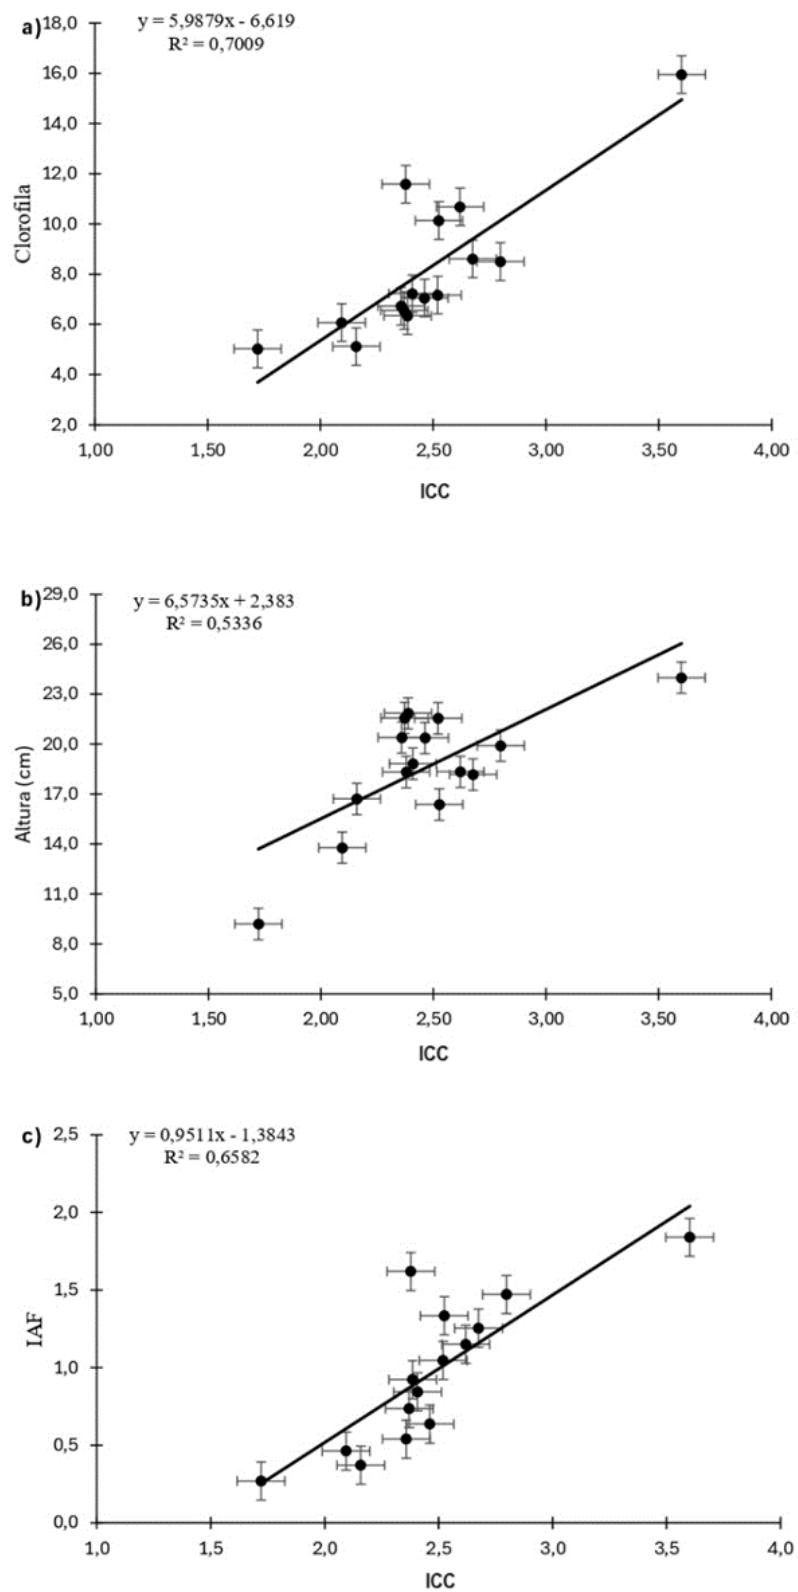


Figura 16. Regressão entre Clorofila e ICC (a); Regressão entre Altura e ICC (b); Regressão entre IAF e ICC (c).

Embora os modelos da análise univariada tenha apresentado ajustes próximos ao obtidos pela ACP, para a análise univariada foi necessário realizar um pré-processamento alocando dados em intervalos próximos em classes visando minimizar o impacto da variabilidade da área na qualidade dos modelos gerados, em contrapartida, os modelos obtidos a partir da ACP foram gerados pelo conjunto total de dados coletados ao longo do experimento (195 dados) sem necessidade de um tratamento prévio. Este fato reforça a potencialidade do ICC em se relacionar com os atributos da cultura mesmo com nível de variabilidade que comprometam a análise a partir de um único índice de vegetação.

Com os modelos gerados foi possível elaborar mapas que proporcionam uma estimativa da distribuição espacial dos atributos na área de estudo ao longo do experimento. Neste estudo, foram elaborados os mapas de estimativa para a 1EA, 3 EA e 5 EA tanto da análise univariada como também os modelos utilizando ACP (ICC). Foi comparado as 3 épocas de avaliação para identificar padrões temporais e espaciais das respostas espectrais da vegetação em relação a cada atributo.

Ao analisar a evolução temporal da clorofila, utilizando o modelo gerado com o índice VARI, ao longo das épocas de avaliação, observou-se o crescimento dos atributos estimados na 5 EA (Figura 17e e Figura 17f), se comparado com a primeira EA (Figura 17a e Figura 17b). No entanto, esse aumento não foi observado entre a 3EA (Figura 17c e Figura 17d) para a 5EA, sugerindo até um possível decréscimo. Essa mudança de padrão possibilita questões importantes sobre os fatores que podem ter influenciado na geração do modelo. Dentre estas, pode-se salientar a não realização de adubações de cobertura e a alta incidência de plantas invasoras em competição com a forrageira, o que pode impactar direto no crescimento da cultura.

Já a evolução temporal da altura (modelo com o índice GNDVI) ao longo das épocas de avaliação, pode-se notar o aumento dos valores estimados da primeira EA (Figura 18a e Figura 18b) para a última EA (Figura 18e e Figura 18f) analisada, embora o aumento mais significativo tenha sido entre a 1EA e a 3EA (Figura 18c e Figura 18d). Entre a 3EA e a 5EA apresentou um comportamento de estabilidade dos valores estimados.

Por fim, na análise da evolução temporal do IAF ao longo das épocas (NDVI), é notório o crescimento dos atributos da 1EA (Figura 19a e Figura 19b) para a 5EA (Figura 19e e Figura 19f). Porém, esse aumento foi mais discreto do que o observado entre 1EA e 3EA ((Figura 19c e Figura 19d). Assim como na clorofila, esse padrão sugere possíveis influências no crescimento da

planta como também na geração do modelo.

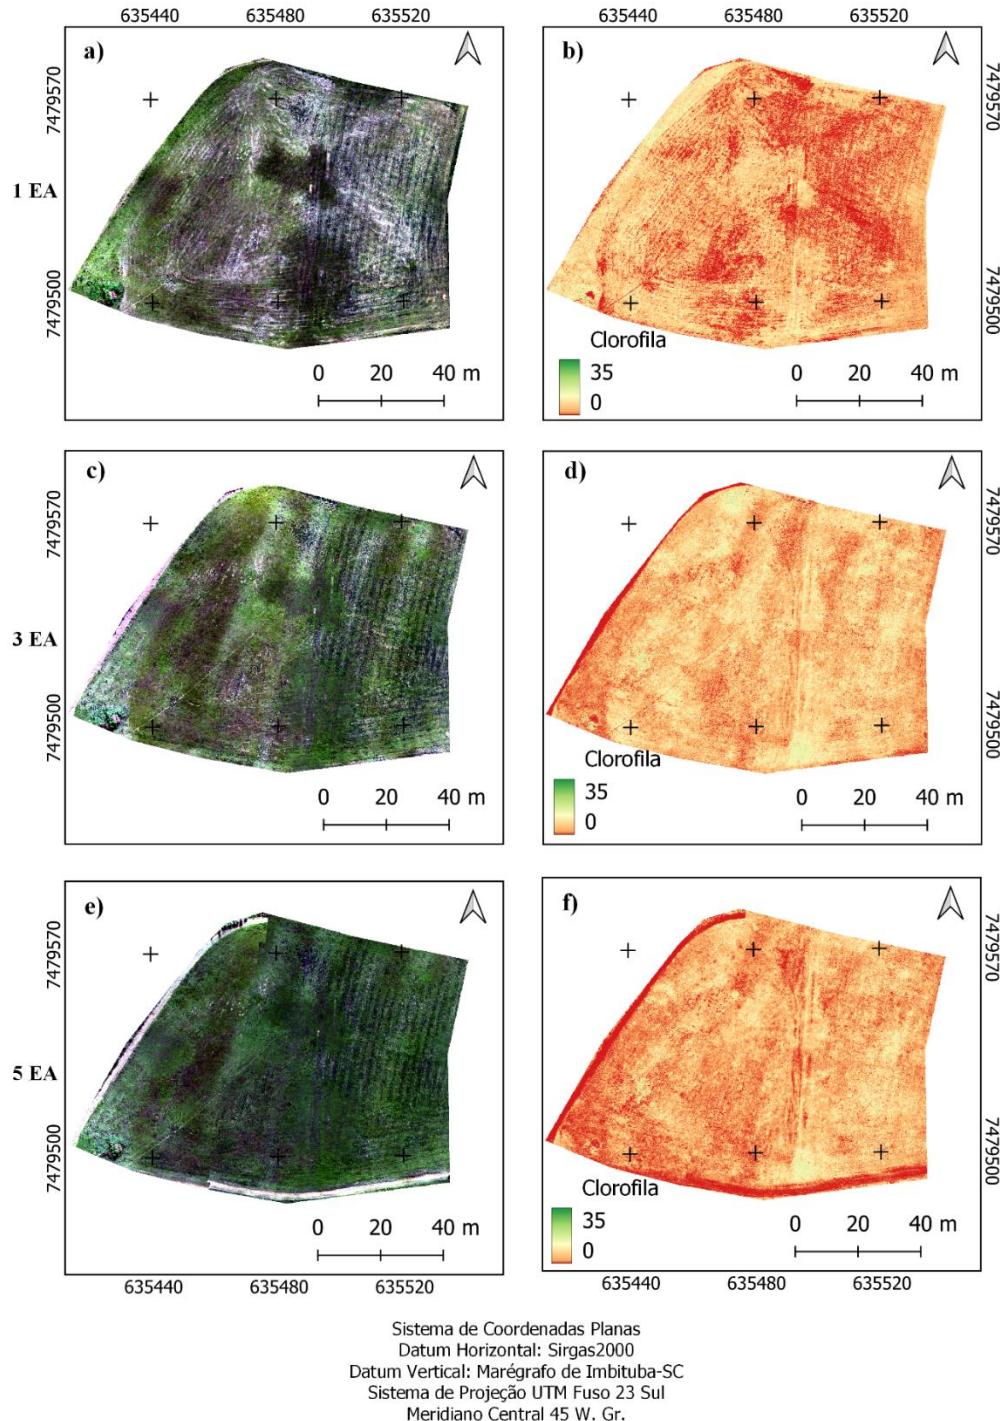


Figura 17. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de Clorofila em função dos índices de vegetação VARI para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de Clorofila em função dos índices de vegetação VARI para 3EA (d); Imagem obtida pelo ARP na

5EA (e); Mapa de estimativa de Clorofila em função dos índices de vegetação VARI para 5EA (f).

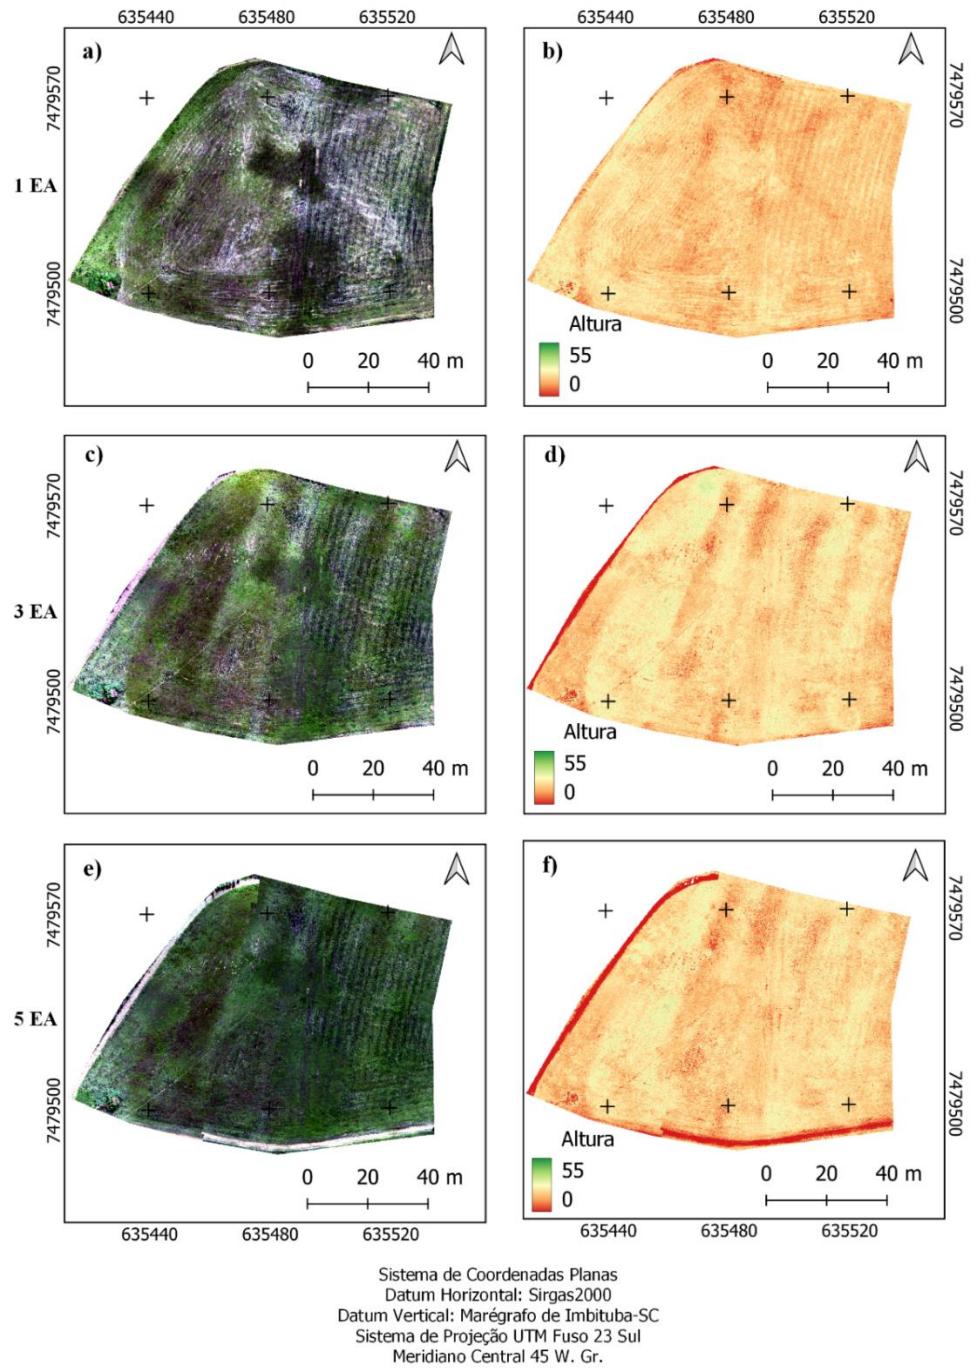


Figura 18. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de Altura em função dos índices de vegetação GNDVI para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de Altura em função dos índices de vegetação GNDVI para 3EA (d); Imagem obtida pelo ARP na 5EA (e); Mapa de estimativa de Altura em função dos índices de vegetação GNDVI

para 5EA (f).

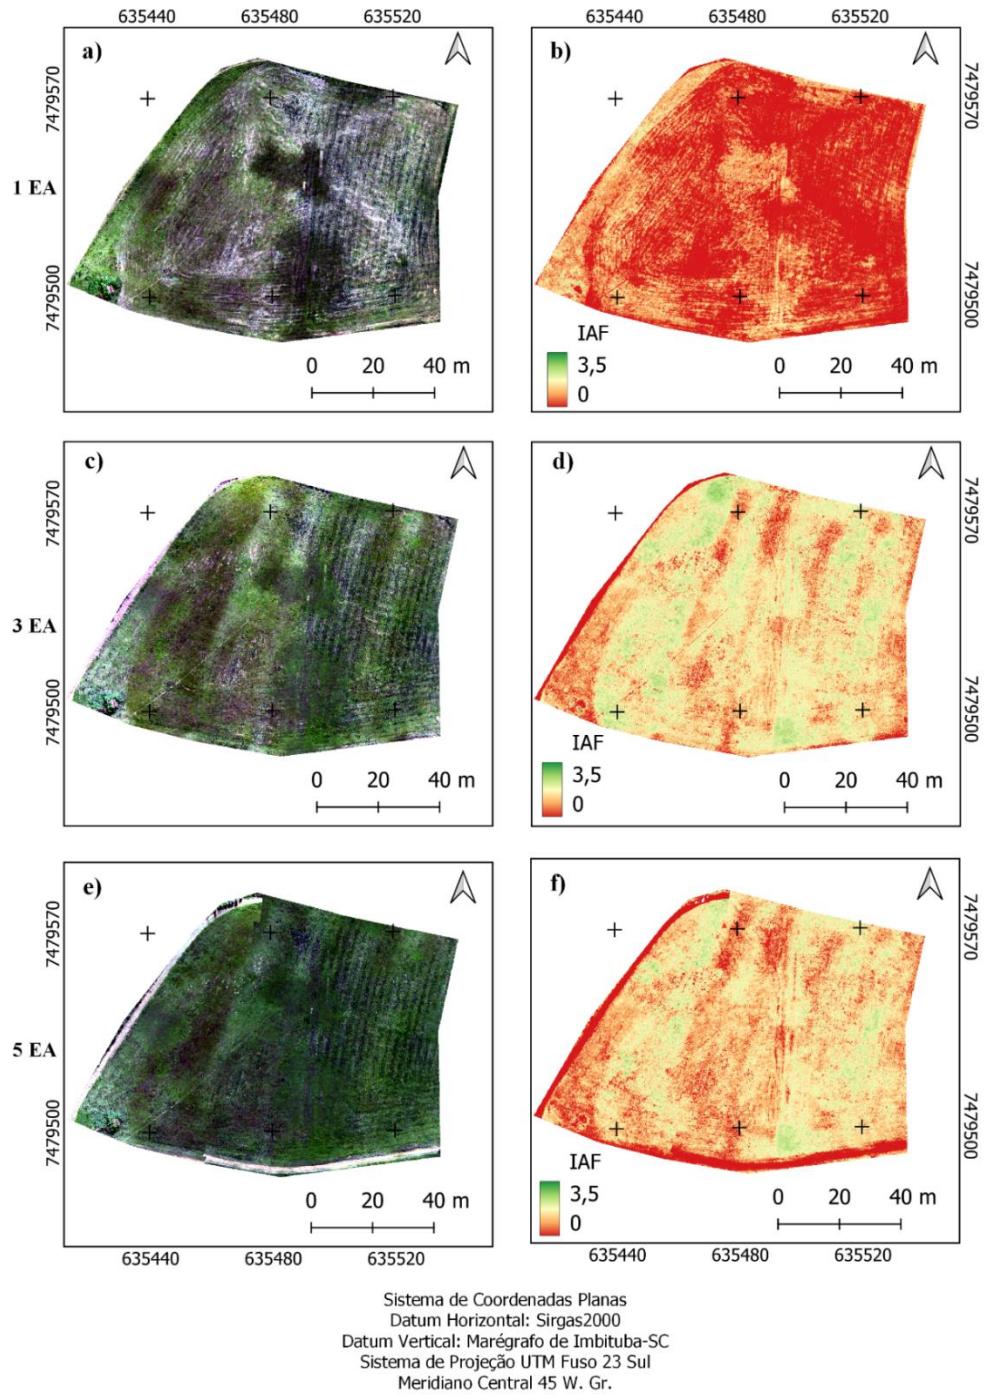


Figura 19. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de IAF em função dos índices de vegetação NDVI para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de IAF em função dos índices de vegetação NDVI para 3EA (d); Imagem obtida pelo ARP na 5EA (e); Mapa de estimativa de IAF em função dos índices de vegetação NDVI para 5EA (f).

Ao analisar a evolução temporal da clorofila, utilizando o índice multivariado ICC, ao longo das épocas de avaliação, observou-se um aumento dos atributos estimados entre as épocas 1EA (Figura 20a e Figura 20b), 3EA (Figura 20c e Figura 20d) e 5EA (Figura 20e e Figura 20f). Ainda apresentando um decréscimo entre a 3EA e 5EA, comportamento similar ao dos mapas de estimativa de clorofila gerados com o modelo utilizando somente o IV VARI.

Para a evolução temporal da estimativa de altura gerada com ICC ao longo das épocas de avaliação, pode-se notar o crescimento dos valores estimados da 1EA (Figura 21a e Figura 21b) para a 5EA (Figura 21e e Figura 21f) analisada, embora tendo aumento mais significativo entre a 1EA e a 3EA (Figura 21c e Figura 21d). Entre a 3EA e a 5EA os mapas apresentaram estabilidade nos valores estimados.

Destaca-se que o ICC realçou a crescente das alturas ao longo do tempo. Em certas situações índices multivariados podem melhorar os mapas de estimativa de atributos da cultura por serem influenciados por características de múltiplos índices de vegetação simultaneamente.

Por fim, na evolução temporal do IAF gerado em relação ao ICC ao longo das épocas, foi observado o crescimento dos atributos da 1EA (Figura 22a e Figura 22b) para a 5EA (Figura 22e e Figura 22f). Notou-se que entre a 1EA e 3EA (Figura 22c e Figura 22d) aparenta possível decréscimo dos valores estimados. Vale ressaltar que houve uma superestimativa do modelo em algumas regiões do mapa, cuja legenda indica IAF próximo a 3,5 em tons verde escuro, onde nos dados de campo não se obteve valores de IAF maiores que 1,8. Alguns fatores podem ter influenciado na geração do modelo e consequentemente na superestimativa dos valores. Dentre estas, pode-se salientar a falta de adubação adequada na área de estudo, o manejo não adequado e até mesmo a presença de plantas invasoras disputando espaço, o que pode impactar direto no crescimento da cultura.

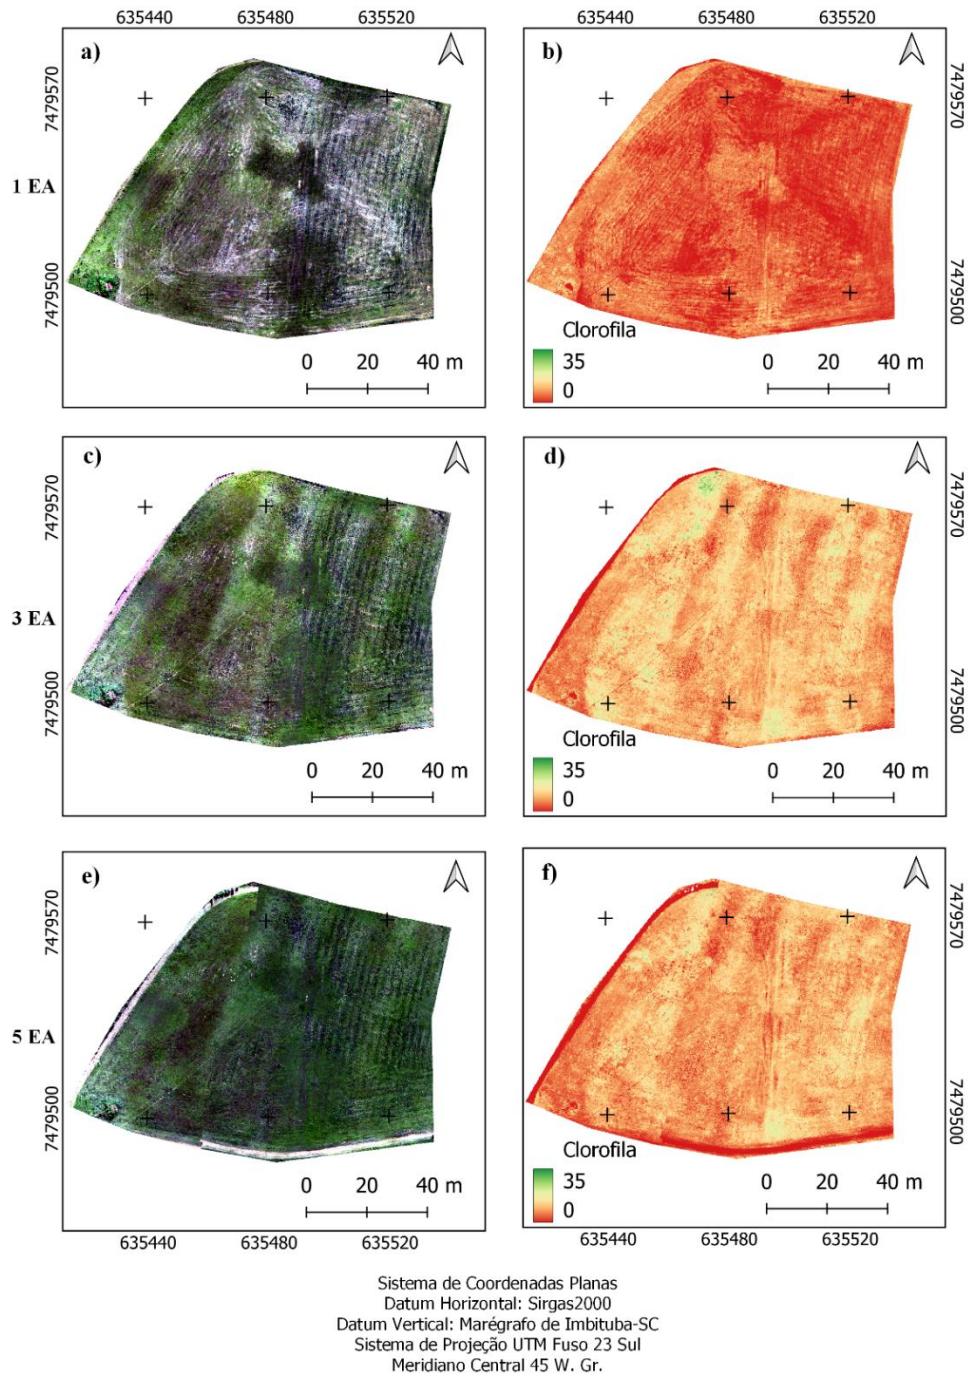


Figura 20. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de Clorofila em função do ICC para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de Clorofila em função do ICC para 3EA (d); Imagem obtida pelo ARP na 5EA (e); Mapa de estimativa de Clorofila em função do ICC para 5EA (f).

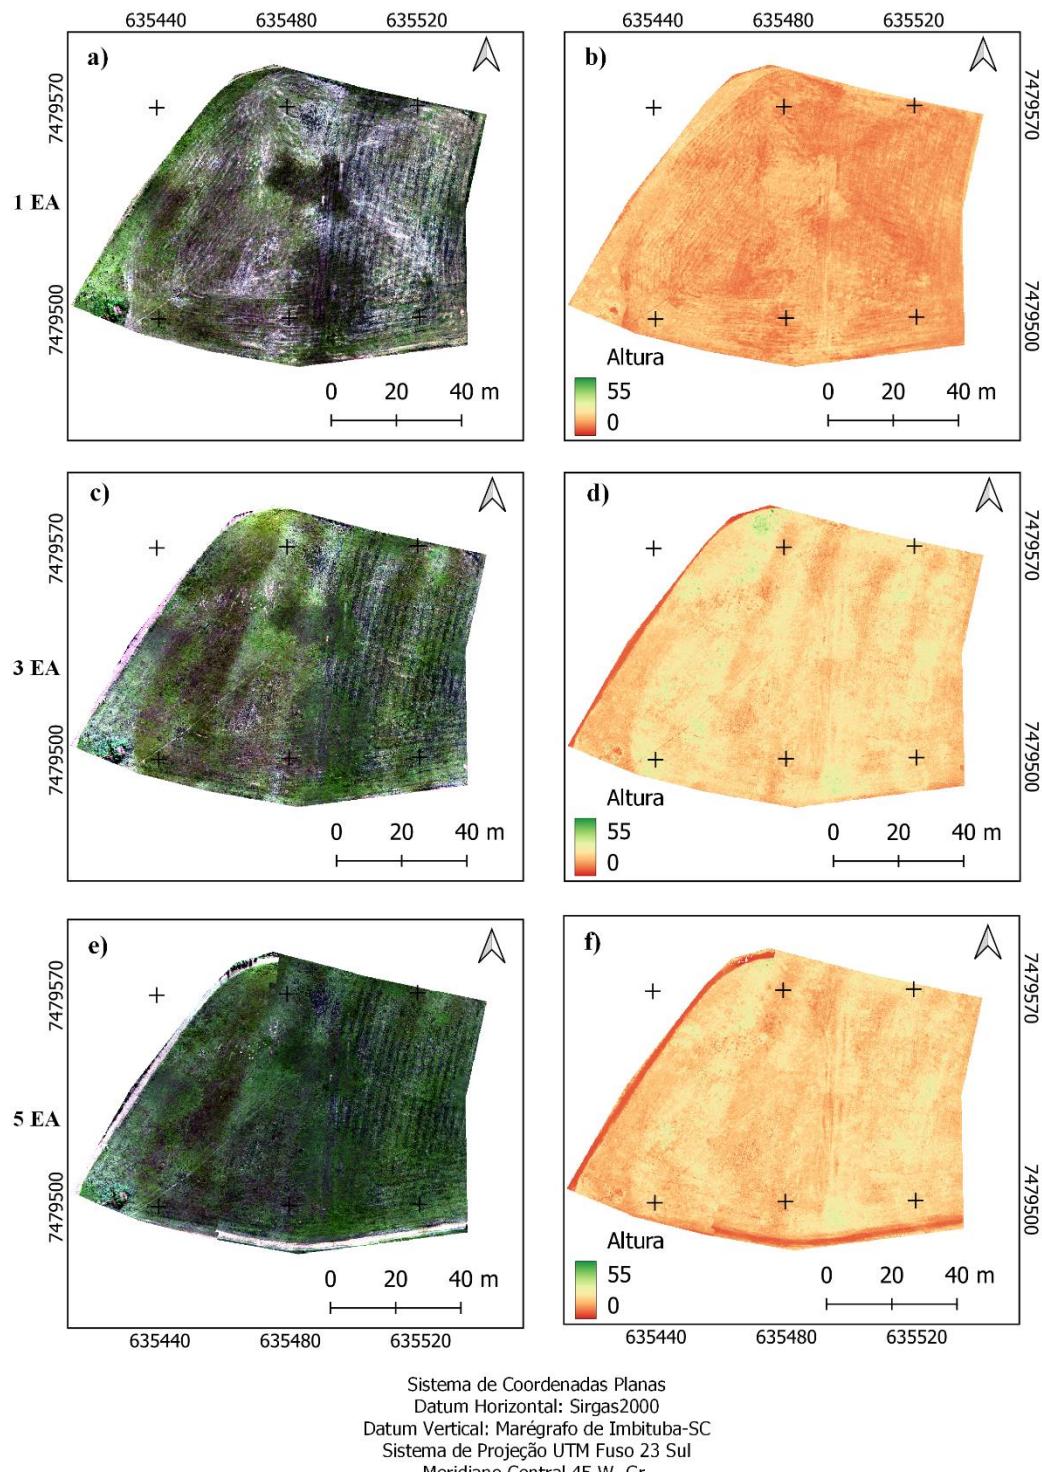


Figura 21. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de Altura em função do ICC para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de Altura em função do ICC para 3EA (d); Imagem obtida pelo ARP na 5EA (e); Mapa de estimativa de Altura em função

do ICC para 5EA (f).

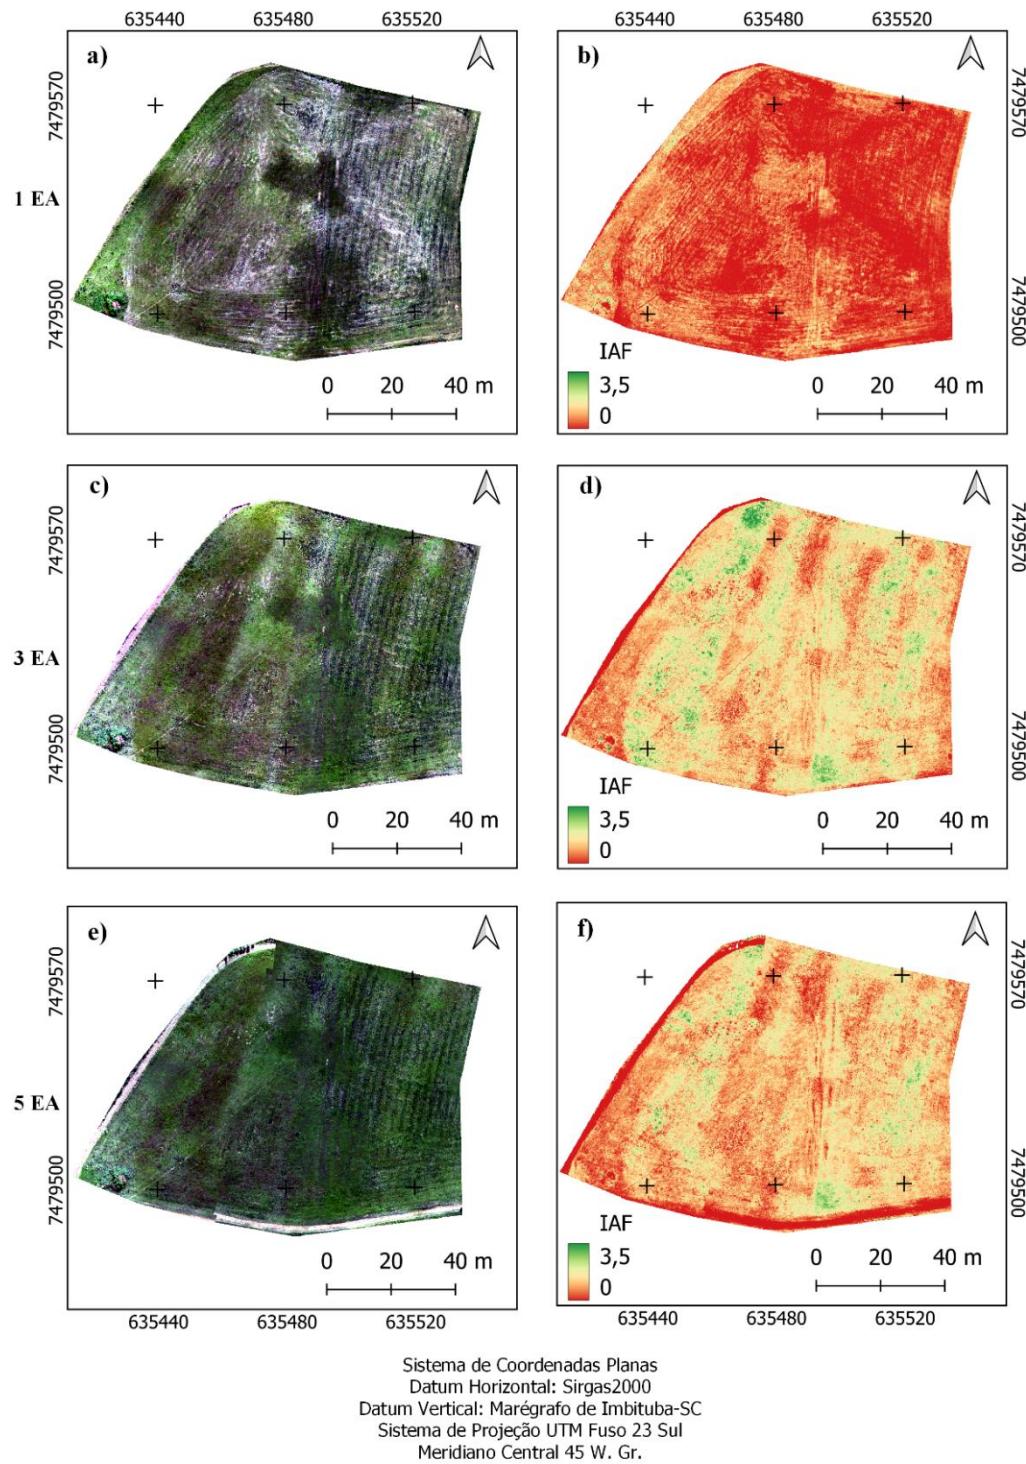


Figura 22. Imagem obtida pelo ARP na 1EA (a); Mapa de estimativa de IAF em função do ICC para 1EA (b); Imagem obtida pelo ARP na 3EA (c); Mapa de estimativa de IAF em função do ICC para 3EA (d); Imagem obtida pelo ARP na 5EA (e); Mapa de estimativa de IAF em função do ICC para 5EA (f).

para 5EA (f).

A utilização de ARPs para estimativa de atributos de cultura demonstra ser uma ferramenta valiosa para os produtores. Essa tecnologia permite uma coleta de dados mais precisa, não destrutiva e fornece informações importantes sobre as culturas, sendo um facilitador e otimizador das práticas agrícolas, auxiliando em estratégias de manejo mais eficientes e assertivas. Além disso, a utilização de ARPs podem reduzir custos operacionais e o tempo necessário para monitorar extensas áreas de cultivo.

A variabilidade na produção agrícola pode ser influenciada por práticas de manejo inefficientes, adubação inadequada, prejudicando o acompanhamento temporal das culturas. No entanto, o Índice de Crescimento da Cultura desenvolvido surge como alternativa para minimizar esses efeitos sendo eficaz na estimativa de atributos culturais, mesmo diante das variabilidades encontradas nos dados. Neste estudo, percebe-se que antes dos 33 dias de desenvolvimento da cultura o ICC apresenta estimativas mais precisas, com tendência de maior acurácia quanto mais precoce for a aplicação. Dessa forma, esse índice é uma ferramenta valiosa para a análise dos atributos e manejo agrícola da cultura.

5.4. Predição da biomassa em função dos índices espectrais

Os resultados da análise de correlação entre os índices de vegetação (IVs) e a biomassa final são apresentados na Tabela 8. A análise dessas correlações permitiu identificar quais IVs estão mais fortemente associados à biomassa final. Dentre os índices de vegetação avaliados, o GNDVI foi o que apresentou maior correlação ($r = -0,822$) na 3EA, portanto esse valor indica que o GNDVI da 3EA é o que melhor explica a biomassa final dentre todas as épocas de avaliação analisadas. Essa correlação é forte e negativa, ou seja, o crescimento de uma variável é inversamente proporcional a outra.

Tabela 8. Correlação entre a biomassa final e os índices de vegetação

	Correlação	Correlação	Correlação	Correlação	Correlação
	1 ^a EA	2 ^a EA	3 ^a EA	4 ^a EA	5 ^a EA
GNDVI	-0,49504	-0,79269	-0,82298	-0,53915	-0,40365
NDVI	-0,49128	-0,77918	-0,82157	-0,58714	-0,40784

NGRDI	-0,5256	-0,74056	-0,80351	-0,62587	-0,43157
RVI	-0,56502	-0,74976	-0,79525	-0,58762	-0,44581
SAVI	-0,49128	-0,77915	-0,82157	-0,58714	-0,40787
VARI	-0,52077	-0,73978	-0,80076	-0,62448	-0,42866
VDVI	-0,4759	-0,71891	-0,76279	-0,57211	-0,31645

Em RAMOS (2020) foi realizada a estimativa de biomassa florestal utilizando dados de 20 anos de monitoramento da vegetação a partir de índices de vegetação. A autora analisou modelos exponencial, polinomial e linear com os índices SR, NDVI, EVI, NDWI e NDDI entre os anos de 1996 e 2016. O modelo escolhido para a estimativa temporal foi o com maior coeficiente de determinação ($R^2=0,85$) e utilizou as variáveis ano e os índices de vegetação: NDWI, NDDI e EVI.

Neste trabalho, utilizou-se um modelo polinomial de grau 2 para estimar a biomassa com um coeficiente de determinação de 0,8078, indicando uma forte correlação entre as variáveis conforme observado na Figura 23. Os dados obtidos em campo e utilizados para a construção do modelo situam-se na faixa de valores de GNDVI entre 0,5 e 0,6. Em seguida, apresenta-se uma comparação visual entre o ortomosaico na região espectral do visível da 5EA (Figura 24a) e o mapa de estimativa de biomassa (Figura 24b).

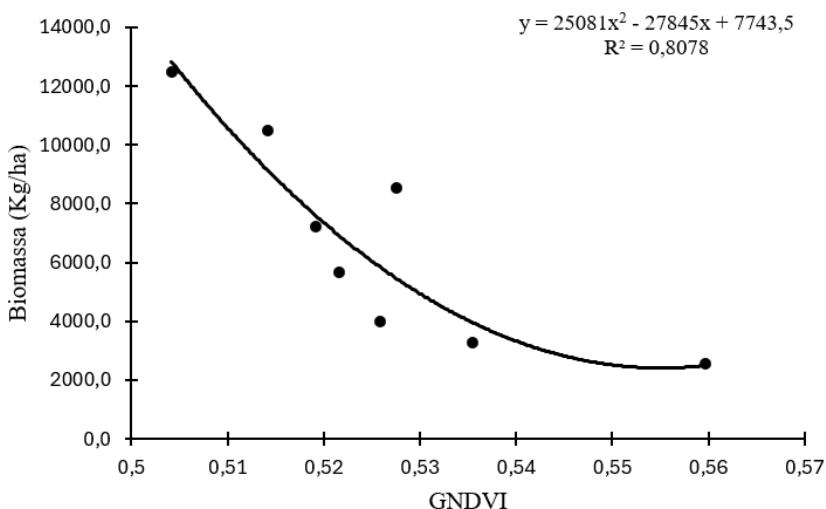


Figura 23. Regressão polinomial entre GNDVI e Biomassa do Tifton obtida após 48 dias de experimento.

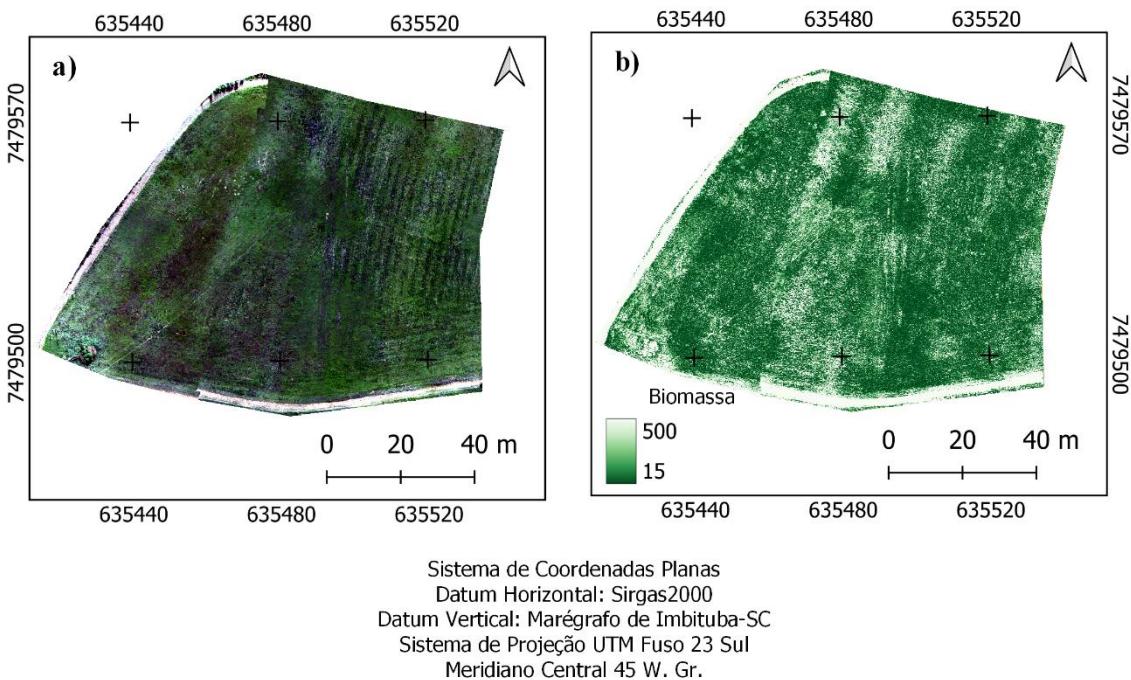


Figura 24. Comparativo entre (a) a imagem do ortomosaico aos 48 dias (5EA) e; (b) os valores de biomassa do Tifton85 estimados pelo modelo com base no GNDVI.

Em geral, espera-se que valores maiores de GNDVI sejam associados a maiores valores de biomassa visto que esse índice mede a atividade fotossintética da cultura que normalmente é maior com a densidade da vegetação. Porém, conforme gráfico apresentado (Figura 23), valores menores de GNDVI estão associados a maiores valores de biomassa e à medida que o GNDVI aumenta, a relação com a biomassa diminui tendendo a se estabilizar.

No ortomosaico obtido em 22/06/2023, é possível identificar a estrada e a área experimental com a cultura (Figura 24a). Na Figura 24b têm-se o mapa de estimativa de biomassa da cultura para a 5EA que visualmente está condizente com a realidade observada no ortomosaico. No entanto, percebe-se que o modelo tende a extrapolar em regiões onde o GNDVI se aproxima de zero, como em áreas com pouca vegetação ou solo exposto, indicando alto crescimento da cultura. Nessas situações, o modelo pode erroneamente indicar a presença de alta biomassa.

Este comportamento do modelo pode ser atribuído ao intervalo de dados limitado utilizado para gerar o modelo, bem como pelas condições de manejo inadequado, deficiência de nutrientes no solo e controle de pragas na área do experimento. Vale ressaltar que para valores de GNDVI dentro do intervalo utilizado para a geração do modelo, a estimativa foi condizente e assertiva.

No trabalho de SCHWALBERT et al. (2020) foi avaliado quão cedo poderia predizer a produtividade de soja usando NDVI, EVI, temperatura da superfície terrestre e precipitação como variáveis independentes com diferentes algoritmos, dentre eles o da regressão linear múltipla. Os autores concluíram que a precisão do modelo diminuiu à medida que antecipava as datas anteriores das previsões. O melhor modelo indicou que a produtividade da soja pôde ser prevista com 70 dias antes da colheita.

Neste estudo foi possível estimar a produtividade final em um momento precoce (3EA), antes da cultura atingir o momento da colheita de forma assertiva quando se tinha valores de GNDVI entre 0,48 e 0,62. É válido destacar a necessidade de futuros ajustes no modelo e elaboração de modelos com maior quantidade de dados ou em maiores intervalos. Entretanto, apesar da limitação, o modelo surge como uma ferramenta valiosa e se torna diferencial para o planejamento estratégico e tomada de decisões assertivas dos produtores.

6. CONCLUSÃO

Este estudo demonstrou que técnicas de sensoriamento remoto são eficazes na avaliação das respostas espectrais da forrageira Tifton85 e que foi possível analisar isso em diferentes estágios de crescimento da cultura.

A utilização de ARPs para obtenção de dados espectrais são comumente utilizados no cálculo de índices de vegetação (IVs). Essa tecnologia permitiu a caracterização da área, fornecendo informações da cultura por um método não destrutivo e de rápida aquisição.

A mensuração dos atributos do Tifton85 foi obtida em diferentes épocas de avaliação e mostrou padrões significativos do crescimento da cultura, onde se observou um crescimento da cultura, principalmente entre a primeira época de avaliação e a terceira.

Neste estudo, foram obtidas correlações fortes e moderadas ao analisar os IVs e atributos do Tifton85. De forma univariada, os modelos de estimativas apresentaram melhor desempenho quando associado ao índice VARI para estimativa da clorofila ($R^2 = 0,7202$), índice GNDVI para estimativa da altura ($R^2 = 0,5744$) e índice NDVI para estimativa do IAF ($R^2 = 0,7539$).

A análise multivariada, possibilitou reduzir a dimensionalidade das informações obtidas pelos IVs para um único componente principal (poder explicativo = 99,94%) e verificar de forma gráfica a relação entre a variância gerada pelos IVS e o crescimento da cultura, especialmente entre até a 3EA (33 dias de crescimento após o corte de uniformização).

O índice multivariado proposto (índice de crescimento da cultura – ICC) demonstrou grande aplicabilidade, especialmente em lavouras onde devido à grande variabilidade os modelos univariados gerados pelos IVs apresentam baixa relação com os atributos da cultura. Os modelos gerados a partir do ICC apresentaram $R^2 = 0,7009$ para clorofila, $R^2 = 0,5336$ para altura e $R^2 = 0,6582$ para o IAF possibilitando gerar mapas representativos da variabilidade destes atributos da cultura.

Para a estimativa de biomassa, o índice de maior correlação foi o GNDVI da 3EA ($r = -0,82298$), sendo este utilizado para predizer a biomassa final da cultura, obtendo $R^2 = 0,8078$.

A geração de modelos capazes de estimar atributos da cultura a partir das características espectrais apresenta um potencial para otimizar a produção agrícola e promover melhorias nas tomadas de decisões sem necessitar de métodos destrutivos.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ABIEC – Associação Brasileira das Indústrias Exportadoras de Carne. **Beef Report: perfil da pecuária no Brasil.** São Paulo, 2023. Disponível: <https://www.abiec.com.br/publicacoes/beef-report-2023/>

AHMAD, A. et al. Remotely piloted aircraft (RPA) in agriculture: A pursuit of sustainability. **Agronomy**, v. 11, n. 1, p. 7, 2020.

ALBUQUERQUE, C. J. B. et al. Uso do clorofilômetro e sua relação com o manejo da adubação nitrogenada em cultivares de sorgo granífero e silageiro na região semiárida. **Brazilian Journal of Development**, v. 6, n. 4, p. 16976-16993, 2020.

ALI, A. M., et al. Site-Specific Nitrogen Fertilizer Management Using Canopy Reflectance Sensors, Chlorophyll Meters and Leaf Color Charts: A Review. **Nitrogen**. 2024.

ALMEIDA, S. L. H. Sensoriamento remoto aplicado ao modelo SAFER na estimativa de parâmetros biofísicos de cultivos. 2022. **Tese de Doutorado**. Universidade Estadual Paulista Júlio de Mesquita Filho (Unesp).

ALVIM, M. J. et al. Estratégia de fornecimento de concentrado para vacas da raça holandesa em pastagens de coast-cross. **Pesquisa Agropecuária Brasileira**, v. 34, p. 1711-1720, 1999.

AMIRRUDDIN, A. D. et al. Synthetic Minority Over-sampling TEchnique (SMOTE) and Logistic Model Tree (LMT)-Adaptive Boosting algorithms for classifying imbalanced datasets of nutrient and chlorophyll sufficiency levels of oil palm (*Elaeis guineensis*) using spectroradiometers and unmanned aerial vehicles. **Computers and Electronics in Agriculture**, v. 193, p. 106646, 2022.

ANDRADE, W. R. Produção de capim e feno de Tifton85 sob doses de nitrogênio em diferentes dias de rebrotação. 2017. **Tese de Doutorado**. Universidade Estadual De Montes Claros.

ARNOLD, C. Y. The determination and significance of the base temperature in linear heat unit system. **Proceedings of the American Society for Horticultural Science**, Geneva, v. 74, p. 430-445, 1959.

BARROS, P. P. da S. et al. Monitoramento fitossanitário utilizando sensoriamento remoto: Avanços e desafios. **Revista Brasileira de Cartografia**, v. 73, n. 2, p. 489–515, 2021.

BASSOI, L. H. et al. **Agricultura de precisão e agricultura digital**. In: TECCOGS – Revista Digital de Tecnologias Cognitivas, n. 20, 2019.

BERNARDI, A. C. C.; PEREZ, N. B. Agricultura de Precisão em Pastagens. **Agricultura de precisão: resultados de um novo olhar - Embrapa**, p. 492-499. 2014.

BEZERRA, W. S. M. Modelo agrometeorológico para predição da produtividade do capim-zuri sob manejos nutricionais contrastantes. 2022. **Dissertação de Mestrado**. Universidade Federal de Rondônia.

BORGES, C. E. Avaliação de plantas forrageiras tropicais sob sombreamentos no outono e inverno. 2020. **Dissertação de Mestrado**. Universidade Federal Dos Vales Do Jequitinhonha E Mucuri

BOURSIANIS, A. D. et al. Internet of things (IoT) and agricultural unmanned aerial vehicles (UAVs) in smart farming: A comprehensive review. **Internet of Things**, v. 18, p. 100187, 2022.

CARLI, V. Estruturação de um modelo para simulação do efeito do nitrogênio, intensidade e frequência de remoção de pastagem de Tifton85. 2009. **Dissertação de Mestrado**. Universidade Regional do Noroeste do Estado do Rio Grande do Sul.

CASAGRANDE, L. G. Produção e valor nutritivo de pastagens de tifton 85 sobressemeadas com azevém e inoculadas com Azospirillum brasiliense. 2021. **Dissertação de Mestrado**. Universidade Federal de Santa Maria.

CLERCQ, M. et al. **Agriculture 4.0: the future of farming technology**, 2018.

CRUZ, N. T. et al. Fatores que afetam as características morfogênicas e estruturais de plantas forrageiras. **Research, Society and Development**, v. 10, n. 7, 2021.

DA PONTE, M. N. et al. EFICIÊNCIA DE INTERCEPTAÇÃO DA RADIAÇÃO FOTOSSINTETICAMENTE ATIVA DE FORRAGEIRAS PERENES TROPICAIS EM UMA FLORESTA DE PINUS ELLIOTTII. **Salão do Conhecimento**, 2017.

DAI, P. V. S. et al. Estimativa de volume de madeira baseada em índices de vegetação. **Scientia Forestalis**, v. 49, n. 129, p. 1-12, 2021.

DA SILVA, C. J. A. et. al. How lamb production systems can affect the characteristics and sward structure of Tifton85 pasture?. **Small Ruminant Research**, v. 188, p. 106124, 2020.

DE CASTRO, I. T. P. et al. FRACIONAMENTO DOS CARBOIDRATOS TOTAIS DO FENO

DE HÍBRIDOS DE SORGO COM CAPIM-SUDÃO. **Semana de Agronomia da UESB (SEAGRUS)**, v. 2, n. 1, 2020.

DE FIGUEIREDO, R. P. CUSTO DE IMPLANTAÇÃO E PRODUÇÃO DA CULTURA TIFTON85 COM IRRIGAÇÃO POR ASPERSÃO PARA SUPLEMENTAÇÃO ALIMENTAR DE GADO LEITEIRO. **Anais Sintagro**, v. 11, n. 1, 2019.

DE MELLO, D. C. et al. Uso e ocupação do solo: comparação de índices NDVI e GNDVI e inferências sobre biomassa de dossel vegetal. **Cadernos de Agroecologia**, v. 15, n. 1, 2020.

DE SOUZA, F. N. T. et al. NDVI radiometric index in permanent preservation area obtained through remotely piloted aircraft. 2021.

DE SOUZA, R. et al. Effect of Time of Day and Sky Conditions on Different Vegetation Indices Calculated from Active and Passive Sensors and Images Taken from UAV. **Remote Sensing**, v. 13, n. 9, p. 1691, 2021.

DELL'ORTO, E. et al. Estimativas do teor de clorofila do mangue da Baía de Vitória (ES) por meio de dados hiperespectrais. **Revista Brasileira de Geografia Física**, v. 13, n. 01, p. 131-142, 2019.

DOS SANTOS, E. P. et al. Imagens Sentinel-2A e Espectrorradiometria Aplicada a Estudo de Pastagens Degradadas. **Anuario do Instituto de Geociencias**, v. 41, n. 2, 2018.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. **Monitoramento tecnológico de cultivares de forragens no Brasil**. São Carlos, SP: Embrapa Pecuária Sudeste, 2021.

FAO - Food and Agriculture Organization of the United Nations. **Alimentos e Agricultura no mundo: Anuário Estatístico**. Roma, 2023.

FERREIRA FILHO, D. F. et al. Análise pluviométrica no estado do Pará: comparação entre dados obtidos de estações pluviométricas e do satélite GPCC. **Revista Brasileira de Climatologia**, v. 26, 2020.

FERREIRA, R. et al. Identificação de pragas na agricultura com auxílio de ARPs. **Anuário Acadêmico-científico da UniAraguaia**, v. 6, n. 1, p. 47-52, 2017.

FERREIRA, R. A. et al. Análise da variabilidade espacial e zonas de produtividade em vinhedos, no Vale Central Gaúcho. **Nativa**, v. 11, n. 3, p. 297-308, 2023.

FIGUEIREDO, M. R. P. de. et al. Digestibility of diets with passion fruit by-product estimated through external and internal markers in dairy heifers. **Acta Scientiarum. Animal Sciences**, v.43, 2020.

FLORENZANO, T. G. Iniciação em sensoriamento remoto. 3^a ed. ampl. e atual. **Oficina de Textos**, 2011. 128 p.

FORMAGGIO, A. R.; SANCHES, I. D. Sensoriamento remoto em agricultura. **Oficina de Textos**, 2017.

FONSECA, A. F. C.; GONZÁLEZ, A. M. R. Comparativa multi e hiperespectral del pasto Cynodon nlemfuensis bajo condiciones tropicales y de pastoreo con ganado lechero. **Ingeniería**, v. 32, n. 1, p. 1-18, 2022.

FORMAGGIO, A. R.; SANCHES, I D. Sensoriamento remoto em agricultura. **São Paulo: Oficina de Textos**, 2017.

GIOVOS, R. et al. Remote sensing vegetation indices in viticulture: A critical review. **Agriculture**, v. 11, n. 5, p. 457, 2021.

GITELSON, A. A. et al. Use of a green channel in remote sensing of global vegetation from EOS-

MODIS. **Remote sensing of Environment**, v. 58, n. 3, p. 289-298, 1996.

GITELSON, A.A. et al. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v.80, n. 1, p. 76–87, 2002.

GUO, Y. et al. Integrating spectral and textural information for identifying the tasseling date of summer maize using UAV based RGB images. **International Journal of Applied Earth Observation and Geoinformation**, v. 102, p. 102435, 2021.

HERNÁNDEZ, Merly Rocio Vásquez. Resposta espectral da vegetação desidratada e valores de NBR (Normalized Burn Ratio) obtidos via dados MSI Sentinel-2 em regiões tropicais. 2021. **Dissertação de Mestrado**. Universidade Federal de Viçosa.

HONGYU, K. et al. Análise de componentes principais: resumo teórico, aplicação e interpretação. **ES Engineering and Science**, v. 5, n. 1, p. 83-90, 2016.

HOTT, M. C. et al. Uso de veículo aéreo não tripulado (VANT) para estimativa de vigor e de correlações agronômicas em genótipos de capim Cynodon. **Engenharia Sanitária e Ambiental**. Ponta Grossa: ATENA Editora, p. 235-244, 2019.

HUETE, A.R. A soil adjusted vegetation index (SAVI), **Remote Sensing of Environment**, v.2, n.25: p.295-309, 1988.

HUNT, E. R. et al. Evaluation of digital photography from model aircraft for remote sensing of crop biomass and nitrogen status. **Precision Agriculture**, v. 6, p. 359-378, 2005.

İLERİ, O; KOÇ, A. Monitoring the available forage using Sentinel 2-derived NDVI data for sustainable rangeland management. **Journal of Arid Environments**, v. 200, p. 104727, 2022.

JORDAN, C.F. Derivation of leaf-area index from quality of light on the forest floor. **Ecology**, v.50, p.663-666, 1969.

KOBAYASHI, N. et al. Crop classification using spectral indices derived from Sentinel-2A imagery. **Journal of Information and Telecommunication**, v. 4, n. 1, p. 67-90, 2020.

LIANG, Y. et al. Improved estimation of aboveground biomass in rubber plantations by fusing spectral and textural information from UAV-based RGB imagery. **Ecological Indicators**, v. 142, p. 109286, 2022.

LIMA, M. D. Desenvolvimento produtivo do Tifton 85 irrigado e não irrigado. 2023. **Dissertação de Mestrado**. Universidade Federal da Grande Dourados

LISBOA, A. M. Sensoriamento remoto na avaliação de pasto de Brachiaria decumbens. 2020. **Dissertação de Mestrado**. Universidade Federal de Viçosa.

MAIMAITIJIANG, M. et al. Vegetation index weighted canopy volume model (CVMVI) for soybean biomass estimation from unmanned aerial system-based RGB imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 151, p. 27-41, 2019.

MAGALHÃES, L. P. Imageamento aéreo por aeronave remotamente pilotada e satélite na cultura do milho: saturação de índices vegetativos e alternativas. 2022. **Tese de Doutorado**. Universidade de São Paulo.

MALLMANN, C. E. S. Estudo de um modelo matemático para simulação do efeito do pastejo sobre o crescimento de pastagens de Tifton85. 2007. **Dissertação de Mestrado**. Universidade Regional do Noroeste do Estado do Rio Grande do Sul.

MESHESHA, D. T. et al. Prediction of grass biomass from satellite imagery in Somali regional state, eastern Ethiopia. **Heliyon**, v. 6, n. 10, p. e05272, 2020.

MONTANARO, V.; ROSA, H. A. ANÁLISES FÍSICAS DO SOLO CORRELACIONADAS COM ÍNDICES VEGETAÇÃO E PRODUTIVIDADE NA CULTURA DA SOJA. **Anais do City Farm**, v. 1, n. 1, 2022.

MOMESSO, L. et al. Forage grasses steer soil nitrogen processes, microbial populations, and microbiome composition in a long-term tropical agriculture system. **Agriculture, Ecosystems & Environment**, v. 323, p. 107688, 2022.

MORGAN, G. R. et al. RGB indices and canopy height modelling for mapping tidal marsh biomass from a small unmanned aerial system. **Remote Sensing**, v. 13, n. 17, p. 3406, 2021.

MURPHY, D. J. et al. A review of precision technologies for optimising pasture measurement on Irish grassland. **Agriculture**, v. 11, n. 7, p. 600, 2021.

NAJI, T. A. H. Study of vegetation cover distribution using DVI, PVI, WDVI índices with 2D-space plot. **Journal of Physics: Conference Series**, v. 1003, n. 1, p.012083, 2018. doi: 10.1088/1742-6596/1003/1/012083

NUNES, L. R. de L.; NUNES, A. M. C. Capim Tifton85 submetido a diferentes dosagens de nitrogênio e idades de rebrota. **Revista Científica Rural**, Bagé-RS, v. 20, n. 2, 2018.

OLIVEIRA, B. C. S. Estimation of spatio-temporal variability of pasture aboveground biomass and height in integrated systems using Sentinel-2 images. 2024. **Dissertação de Mestrado**. Universidade Estadual de Campinas (UNICAMP).

OLIVO, C. J. Et al. Productivity and crude protein concentration of Tifton85 pasture-based mixed with pinto peanut. **Ciência e Agrotecnologia**. V.43, p.8, 2019.

PEREIRA, F. R da S. et al. Nitrogen variability assessment of pasture fields under an integrated crop-livestock system using UAV, PlanetScope, and Sentinel-2 data. **Computers and Electronics in Agriculture**, v. 193, p. 106645, 2022.

PEZZOPANE, J. R. M. et al. Assessment of Piatã palisadegrass forage mass in integrated livestock production systems using a proximal canopy reflectance sensor. **European Journal of Agronomy**, v. 103, p. 130-139, 2019.

PINHEIRO, A. G. et al. Lacunas de produtividades e estratégias de cultivo na melhoria da produção de forragem para a região semiárida brasileira-Revisão. **Revista Brasileira de Geografia Física**, v. 14, n. 04, p. 2403-2426, 2021.

PRESTES, C. D. P. et al. Avaliação de metodologia de estimativa de produtividade de soja por meio de aeronave não tripulada e técnica de aprendizado de máquina baseada em regressão. **Revista Mundi Engenharia, Tecnologia e Gestão**, v. 5, n. 3, 2020.

RADOČAJ, D. et al. State of major vegetation indices in precision agriculture studies indexed in web of science: A review. **Agriculture**, v. 13, n. 3, p. 707, 2023.

RAMOS, N. O. Estimativa e modelagem da biomassa florestal acima do solo a partir do uso do sensoriamento remoto: 20 anos de monitoramento da vegetação. 2021. **Dissertação de Mestrado**. Universidade de Brasília.

RAMOS, P. N. F. et al. Determinação da análise de regressão linear simples para explicar a influência dos atributos físicos do solo na produção do algodão. **Research, Society and Development**, v. 11, n. 8, 2022.

ROCHA, I. J. F. et al., Seleção de modelo de regressão para estimar o índice de área foliar utilizando imagens de sensoriamento remoto. **CIÊNCIAS AGRÁRIAS: O AVANÇO DA CIÊNCIA NO BRASIL**, v.4, p. 377-392, 2022.

ROSA, P. P. Estudo meta-analítico dos efeitos dos ciclos e intervalos de pastejo sobre as características de rendimento e qualidade forrageira do Capim elefante (*Pennisetum purpureum*

Schumach cv. Napier), Tifton 85 (Cynodon spp.), Coast-cross (Cynodon dactylon (L.) Pers) e Tanzânia (Panicum maximum Jacq) para produção de leite a pasto. 2023. **Tese de Doutorado.** Universidade Federal de Pelotas.

ROUSE, J.W. et al. Monitoring vegetation systems in the Great Plains with ERTS (Earth Resources Technology Satellite). **PROCEEDINGS OF THE THIRD ERTS SYMPOSIUM**, SP-351 Goddard Space Flight Center, p. 309–317, 1973.

SANTOS, H. R. O. Características agronômicas e nutricionais de híbridos de sorgo com capim-sudão (*Sorghum bicolor* x *Sorghum sudanense*) para a produção de feno. 2018. **Dissertação de Mestrado.** Universidade Estadual do Sudoeste da Bahia.

SAMPAIO, H. S. et al. Comparação entre índices de vegetação obtidos por imagens aéreas com veículo aéreo não tripulado (VANT) e satélite. **Brazilian Journal of Biosystems Engineering**, v. 14, n. 2, p. 111-124, 2020.

SAMPAIO, M. I. R. Índices de vegetação por diferentes plataformas e suas relações com produtividade do milho (*zea mays* l.) Sob variabilidade de doses de nitrogênio a partir de análises multivariadas. 2019. **Dissertação de Mestrado.** Universidade Federal de Santa Maria.

SANCHES, A. C. Coeficiente de cultura (Kc) e correlações de consumo de água, fatores produtivos e biométricos de gramíneas tropicais em cultivo exclusivo e em sobressemeadura com forrageiras de inverno. 2018. **Tese de Doutorado.** Universidade de São Paulo.

SANTOS, H. G. et al. **Sistema Brasileiro de Classificação de Solos**. 5. ed. Brasília, DF: Embrapa, 2018.

SANTOS, L. M. et al. Use of RPA Images in the Mapping of the Chlorophyll Index of Coffee Plants. **Sustainability**, v. 14, n. 20, p. 13118, 2022.

SCHWALBERT, R. A. et al. Satellite-based soybean yield forecast: Integrating machine learning and weather data for improving crop yield prediction in southern Brazil. **Agricultural and Forest Meteorology**, v. 284, p. 107886, 2020.

SILVA, L. R. Efeito do manejo de secagem e armazenamento sobre o valor nutritivo do feno de Crotalaria ochroleuca L. 2022. **Tese de Doutorado**. Universidade Estadual do Oeste do Paraná.

SILVA, T. M. M. et al. Estimativa de teores foliares de clorofila em vinhedo por meio de clorofilômetro portátil. **Simpósio Nacional de Instrumentação Agropecuária**. 2019.

SHAFIAN, S. et al. Unmanned aerial systems-based remote sensing for monitoring sorghum growth and development. **PloS one**, v. 13, n. 5, 2018.

SISHODIA, R. P. et al. Applications of remote sensing in precision agriculture: A review. **Remote Sensing**, v. 12, n. 19, p. 3136, 2020.

SOBRINHO, M. et al. Uso de veículos aéreos não tripulados (VANT) para mensuração de processos florestais. **ENCICLOPÉDIA BIOSFERA**, v. 15, n. 27, 2018.

SOUZA, A. L. P. et al. Avaliação de três métodos de obtenção do índice de área foliar para cultura da soja. **Nativa**, v. 7, n. 3, p. 284-287, 2019.

SOUZA, C. et al. Natural genetic diversity of nutritive value traits in the genus Cynodon. **Agronomy**, v. 10, n. 11, p. 1729, 2020.

SOUZA, J. F. et al. Relationship between spectral indices and quality parameters of tifton 85 forage. **Revista Caatinga**, v. 37, p. e12139, 2024.

SOUZA, M. R. Q. Estimativa de biomassa de trigo usando imagens de alta resolução espacial a partir de veículo aéreo não tripulado. 2018. **Dissertação de Mestrado**. UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL.

SPERANZA, E. A.; ANTUNES, J. F. G.; INAMASU, R. Y. Uso de imagens de sensoriamento remoto para identificação de variabilidade espacial em Agricultura de Precisão. In: **Embrapa Informática Agropecuária-Artigo em anais de congresso (ALICE)**. In: **SIMPÓSIO DE GEOTECNOLOGIAS NO PANTANAL**, 2018.

STELLACCI, A. M. et al. Assessment of soil quality under different soil management strategies: Combined use of statistical approaches to select the most informative soil physico-chemical indicators. **Applied Sciences**, v. 11, n. 11, p. 5099, 2021.

TAGLIAPIETRA, E. L. et al. Optimum leaf area index to reach soybean yield potential in subtropical environment. **Agronomy Journal**, v. 110, n. 3, p. 932-938, 2018.

TAIZ, L. et al. Fisiologia e desenvolvimento vegetal. **Artmed Editora**, 2017.

THÉAU, J. et al. Estimation of forage biomass and vegetation cover in grasslands using UAV imagery. **PloS one**, v. 16, n. 1, p. e0245784, 2021.

TONG, X.; DUAN, L.; LIU, T.; SINGH, V. P. Combined use of in situ hyperspectral vegetation indices for estimating pasture biomass at peak productive period for harvest decision. **Precision Agriculture**, v.20, p.477–495, 2019.

VENDRUSCULO, L. G et al. Análise do índice de vegetação mpri e sua correlação com clorofila em cultura da limeira ácida 'TAHITI' sobre híbridos e cultivares de citros na região norte de Mato Grosso. In: **ENCONTRO DE CIÊNCIA E TECNOLOGIAS AGROSSUSTENTÁVEIS, 5; JORNADA CIENTÍFICA DA EMBRAPA AGROSSILVIPASTORIL**, EMBRAPA, p.24, 2021.

VIÇOSI, K. A. et al. Características bromatológicas e produtividade do capim Tifton 85 submetido a fontes de adubos nitrogenados. **Revista Cultura Agronômica**, v. 29, n. 1, p. 106, 2020.

XIAOQIN, W. et al. Extraction of vegetation information from visible unmanned aerial vehicle images. **Transactions of the Chinese Society of Agricultural Engineering**, v. 31, n. 5, 2015.

WARRICK A. W.; NIELSEN D. R. Spatial variability of soil physical properties in the field. In: **Hillel D, ed. Applications of soil physics.** New York, Academic Press, p. 319-344, 1980.