

WAGNER MARTINS DOS SANTOS

UTILIZAÇÃO DE ÍNDICES DE VEGETAÇÃO PARA ESTIMATIVA DE PARÂMETROS  
PRODUTIVOS EM SISTEMAS AGROFLORESTAIS NO BIOMA CAATINGA

Serra Talhada-PE

2023

WAGNER MARTINS DOS SANTOS

UTILIZAÇÃO DE ÍNDICES DE VEGETAÇÃO PARA ESTIMATIVA DE PARÂMETROS  
PRODUTIVOS EM SISTEMAS AGROFLORESTAIS NO BIOMA CAATINGA

Dissertação ou Tese apresentada à  
Universidade Federal Rural de Pernambuco,  
Unidade Acadêmica de Serra Talhada, como  
parte das exigências do Programa de Pós-  
Graduação em Produção Vegetal, para  
obtenção do título de Mestre ou Doutor em  
Produção Vegetal.

Orientador: Prof. Dr. Evaristo Jorge Oliveira de  
Souza

Coorientador: Prof. Dr. José Carlos Batista  
Dubeux Júnior

Serra Talhada-PE

2023

Dados Internacionais de Catalogação na Publicação  
Universidade Federal Rural de Pernambuco  
Sistema Integrado de Bibliotecas  
Gerada automaticamente, mediante os dados fornecidos pelo(a) autor(a)

---

S237u

Santos, Wagner Martins dos

Utilização de índices de vegetação para estimativa de parâmetros produtivos em sistemas agroflorestais no bioma Caatinga / Wagner Martins dos Santos. - 2023.  
50 f. : il.

Orientador: Evaristo Jorge Oliveira de Souza.

Coorientador: Jose Carlos Batista Dubeux Junior.

Inclui referências.

Dissertação (Mestrado) - Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Produção Vegetal, Serra Talhada, 2023.

1. sensoriamento remoto. 2. produtividade. 3. aprendizado de máquina. 4. semiárido. 5. capim buffel. I. Souza, Evaristo Jorge Oliveira de, orient. II. Junior, Jose Carlos Batista Dubeux, coorient. III. Título

CDD 581.15

---

WAGNER MARTINS DOS SANTOS

UTILIZAÇÃO DE ÍNDICES DE VEGETAÇÃO PARA ESTIMATIVA DE PARÂMETROS  
PRODUTIVOS EM SISTEMAS AGROFLORESTAIS NO BIOMA CAATINGA

Dissertação ou Tese apresentada à Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada, como parte das exigências do Programa de Pós-Graduação em Produção Vegetal, para obtenção do título de Mestre ou Doutor em Produção Vegetal.

APROVADO em 27/02/2023.

Banca Examinadora



Prof. Dr. Evaristo Jorge O. de Souza  
Nutrição de Ruminantes  
UFRPE/IAST

---

Prof. Dr. Evaristo Jorge Oliveira de Souza – UAST/UFRPE  
Orientador



---

Dr. David Mirabedini Jaramillo - *U.S. Dairy Forage Research Center*  
Examinador Externo



---

Prof. Dr. Alexandre Campelo de Oliveira - UAST/UFRPE  
Examinador Interno

À Deus por sempre guiar meus passos. Aos meus pais, minha irmã e a minha esposa.

Dedico

## AGRADECIMENTOS

Agradeço primeiramente a Deus, por me guiar e me sustentar em todos os momentos da minha vida. Agradeço por tua presença constante em minha vida, por me guiar em cada passo do caminho e por me sustentar em momentos difíceis.

À minha esposa, Lady Daiane Costa de Sousa Martins, a pessoa mais importante da minha vida, agradeço por seu amor incondicional, sua paciência e seu apoio em todas as situações. Você é a razão pela qual eu acordo todas as manhãs com um sorriso no rosto e a minha inspiração para ser uma pessoa melhor a cada dia.

Aos meus pais, Francisco Martins de Sousa e Jacira dos Santos, agradeço por me ensinarem os valores que me tornaram a pessoa que sou hoje. Seus sacrifícios e amor incondicional moldaram a minha vida e me ensinaram a importância da família e da honestidade. Vocês são a minha referência e eu amo vocês incondicionalmente.

À minha irmã, Gislaine Martins dos Santos, que é minha amiga e companheira de todas as horas, agradeço por sempre estar ao meu lado, compartilhando alegrias e tristezas. Você é uma bênção na minha vida e eu sou grato por poder contar com a sua amizade.

Aos meus sogros, Cicero Teodósio de Sousa e Eunice Teodósio da Costa Sousa, e meus cunhados, Camily, Milena e Jhonata. Obrigado por me acolherem em sua família e me tratarem como parte da sua família. Agradeço por todo o amor e carinho que me deram.

Ao meu orientador, Evaristo Jorge Oliveira de Souza, agradeço por sua orientação, sabedoria e paciência. Suas orientações e conselhos foram fundamentais para minha formação acadêmica e profissional.

Aos meus amigos, Agda, Claudenilde, Jasiel, Jheizon, Jonas, Juninho, Kaique, Luana, Matheus, Marcelo Lopes, Mayara, Thaynnary, Thalison, Thomaz, Thamila, Relyson, Pêu, Vinícius, Yasmin. Obrigado por serem parte de minha vida e por me trazerem tanta alegria e felicidade. Espero que possamos continuar a cultivar nossas amizades ao longo dos anos.

Ao grupo de trabalho do qual fiz parte e pude contar com apoio de todos. Sou grato por fazer parte deste grupo e por trabalharmos juntos em busca de nossos objetivos.

Por fim, aos meus professores, agradeço por compartilharem seu conhecimento e experiência comigo. Suas lições e ensinamentos foram inestimáveis e me ajudaram a alcançar minhas metas acadêmicas. Em especial ao professor Alan César Bezerra por sua contribuição de longa data na minha formação.

Ao Programa de Pós-graduação em Produção Vegetal e à Universidade Federal Rural de Pernambuco, pela oportunidade de realização do mestrado em produção vegetal, e por toda a estrutura de aprendizado que possibilitou minha boa formação como profissional.

À FACEPE pela concessão de bolsa e recursos para realização do trabalho.

À banca examinadora pela disponibilidade em avaliar este trabalho de dissertação.

Não existe fracasso. Existem somente resultados.

(Anthony Robbins)

## RESUMO

As alterações ambientais no bioma Caatinga já atingem níveis de aproximadamente 50% da sua vegetação original, ocupando a posição de terceiro bioma mais degradado do Brasil, atrás apenas da floresta atlântica e do cerrado, por práticas inadequadas de pastejo que são impulsionados pela dificuldade de monitoramento e estimativa de parâmetros produtivos de plantas forrageiras, principalmente em sistemas agroflorestais neste bioma. Assim, ergueu-se a hipóteses que os índices de vegetação são alternativas viáveis para estimativa de parâmetros produtivos de culturas forrageiras em sistemas agroflorestais no bioma Caatinga e que a remoção de componentes do sistema durante o processamento contribuirá para aprimoração do modelo preditivo. Por consequência, objetivou-se comparar a capacidade preditiva de diferentes índices sobre a biomassa e índice de área foliar de culturas forrageiras (capim corrente e capim buffel) em sistemas agroflorestais no bioma Caatinga e, avaliar a influência da remoção de componentes do sistema sobre o desempenho dos modelos. Os tratamentos utilizados consistiram em quatro sistemas agroflorestais: 1) capim corrente/buffel + feijão + Caatinga; 2) capim corrente/buffel + algodão + Caatinga; 3) capim corrente/buffel + milho + Caatinga; 4) capim corrente/buffel + Caatinga. O delineamento experimental foi em blocos casualizados, com três repetições e quatro tratamentos, consistindo em quatro parcelas por bloco, totalizando 12 parcelas. Onze índices de vegetação foram calculados a partir de imagens RGB (*Red, Green, Blue*), relacionando-os à biomassa seca (MS) e fresca (MF) e, ao índice de área foliar (IAF). Os índices *Normalized Green Red Difference Index* (NGRDI) e *Visible Atmospherically Resistant Index* (VARI) apresentaram maiores correlações ( $P < 0,05$ ) com as variáveis MF, MS e IAF. Além disso, a remoção das árvores dos ortomosaicos foi a abordagem que mais favoreceu os valores de correlação. Os modelos com base em árvores de classificação e regressão (CART) apresentaram menores valores de RMSE, apresentando valores de 3020,86, 1201,75 e 0,20, para MF, MS e IAF, respectivamente, além de maiores valores de CCC (0,94 para todos os parâmetros produtivos). A utilização do NGRDI e VARI, bem como a remoção das árvores das imagens e a utilização do CART, são recomendadas na estimativa de biomassa e índice de área foliar em sistemas agroflorestais no bioma Caatinga.

**Palavras-chave:** sensoriamento remoto, produtividade, aprendizado de máquina, semiárido, capim buffel, capim corrente.

## ABSTRACT

Land-use changes in the Caatinga biome have already reached levels of approximately 50% of its original vegetation, occupying the position of the third most degraded biome in Brazil, behind only the Atlantic forest and the Cerrado. This degradation has been observed due to inadequate grazing practices that are driven by the difficulty of monitoring and estimation of productive parameters of forage plants, mainly in agroforestry systems in this biome. The hypotheses were that vegetation indices are viable alternatives for estimating the productive parameters of forage crops in agroforestry systems in the Caatinga biome and that the removal of system components during processing will contribute to the improvement of the predictive model. Consequently, the objective was to compare the predictive capacity of different indices on the biomass and leaf area index of forage crops (corrente grass and buffel grass) in agroforestry systems in the Caatinga biome, and to evaluate the influence of the removal of system components on the model performance. The treatments consisted of four agroforestry systems: 1) corrente-buffel grass + beans + Caatinga; 2) corrente-buffel grass + cotton + Caatinga; 3) corrente-buffel grass + corn + Caatinga; 4) corrente-buffel grass + Caatinga. The experimental design was a randomized complete blocks, with three replications and four treatments, consisting of four plots per block, totaling 12 plots. Eleven vegetation indices were calculated from RGB (Red, Green, Blue) images, relating them to dry (MS) and fresh (MF) biomass, and to the leaf area index (LAI). The Normalized Green Red Difference Index (NGRDI) and Visible Atmospherically Resistant Index (VARI) showed the highest correlations ( $P < 0.05$ ) with the variables MF, MS and LAI. Furthermore, removing the trees from the orthomosaics was the approach that most favored the correlation values. The models based on classification and regression trees (CART) showed lower RMSE values, with values of 3020.86, 1201.75 and 0.20 for MF, MS and IAF, respectively, in addition to higher CCC values (0.94 for all production parameters). The use of NGRDI and VARI, as well as the removal of trees from the images and the use of CART, are recommended for estimating biomass and leaf area index in agroforestry systems in the Caatinga biome.

**Keywords:** remote sensing, productivity, machine learning, semiarid, buffel grass, corrente grass.

## LISTA DE FIGURAS

Figura 1. Localização do experimento. a) Foto área georreferenciada da área experimental, b) Mapa de altitude da área experimental .....	24
Figura 2. Condições meteorológicas no período experimental, 26 de fevereiro de 2021 a 17 de junho de 2021 e 25 de fevereiro de 2022 a 29 de junho de 2022. a) Valores de Precipitação e evapotranspiração de referência (ETo). b) Temperatura e umidade relativa do ar (ALLEN et al., 1998).....	25
Figura 3. Design experimental. B: bloco; P: parcela; CA: Caatinga; CB: capim corrente-buffel; AG: Algodão; FE: feijão; MI: milho. ....	27
Figura 4. Fotos áreas da área experimental. a) Antes da implantação. b) Após implantação ..	28
Figura 5. Padrão de voo do VANT.....	28
Figura 6. Moldura com 0,25 m <sup>2</sup> para coleta da massa de forragem .....	31
Figura 7. Uso de sensor portátil ceptômetro <i>AccuPAR</i> para determinação do IAF.....	32
Figura 8. Coeficientes de correlação de <i>Spearman</i> da relação entre as características consideradas e os índices e vegetação para cada abordagem sobre os ortomosaicos. ** representa significância de 0,05.....	35
Figura 9. Influência relativa dos índices os modelos finais de árvores de classificação e regressão (CART).....	37

## LISTA DE TABELAS

Tabela 1. Espécies encontradas na área experimental.....	26
Tabela 2. Descrição dos arquivos gerados a partir de cada ortomosaico. ....	29
Tabela 3. Índices de vegetação. ....	30
Tabela 4. Análise descritiva dos dados.....	34
Tabela 5. Resultados do processo de validação cruzada para os modelos de regressão linear simples.....	35
Tabela 6. Resultados do processo de validação cruzada para os métodos de aprendizado de máquina. ....	36

## LISTA DE SIGLAS E ABREVIATURAS

ANNs	Redes Neurais
BGI	<i>Blue Green Pigment Index</i>
BI	<i>Brightness Index</i>
BRTs	Árvores de regressão impulsionadas
CART	Árvores de regressão particionadas
CCC	Coefficiente de correlação de Lin
Cub	Cubista
GLI	<i>Green Leaf Index</i>
HI	<i>Primary Colors Hue Index</i>
HUE	<i>Overall Hue Index</i>
IAF	Índice de área foliar
MAE	Erro absoluto médio
MF	Massa fresca
MGRVI	<i>Modified Green Red Vegetation Index</i>
MS	Massa seca
NGRDI	<i>Normalized Green Red Difference Index</i>
R <sup>2</sup>	Coefficiente de determinação.
RGB	<i>Red, Green e Blue</i>
RGBVI	<i>Red Green Blue Vegetation Index</i>
RMSE	Erro quadrático médio
SAFs	Sistemas agroflorestais
SCI	<i>Soil Color Index</i>
SI	<i>Spectral Slope Saturation Index</i>
SVM	Máquinas de vetores de suporte
VANTs	Veículos aéreos não tripulados
VARI	<i>Visible Atmospherically Resistant Index</i>

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>15</b>
<b>2 REVISÃO DE LITERATURA.....</b>	<b>17</b>
2.1 Bioma Caatinga.....	17
2.2 Sistemas agroflorestais (SAFs).....	18
2.3 Adoção de sistemas agroflorestais na região semiárida do Brasil.....	18
2.4 Monitoramento e índices de vegetação.....	19
2.5 Aprendizado de máquina .....	20
2.6 Milho ( <i>Zea Mays</i> L.).....	21
2.7 Feijão-caupi ( <i>Vigna unguiculata</i> ).....	21
2.8 Algodoeiro herbáceo ( <i>Gossypium hirsutum</i> L.).....	22
2.9 Capim Buffel ( <i>Cenchrus ciliaris</i> ).....	22
2.10 Capim corrente ( <i>Urochloa mosambicensis</i> ).....	23
<b>3 MATERIAL E MÉTODOS .....</b>	<b>23</b>
3.1 Localização e caracterização da área experimental.....	23
3.2 Tratamentos experimentais.....	25
3.3 Padrão de voo do veículo aéreo não tripulado.....	28
3.4 Geração de ortomosaicos e índices de vegetação.....	29
3.5 Massa de forragem e Índice de área foliar (IAF).....	31
3.6 Análise de correlação.....	32
3.7 Modelos de aprendizado de máquina.....	32
3.8 Avaliação dos modelos.....	33
<b>4 RESULTADOS.....</b>	<b>34</b>
4.1 Correlação e determinação da abordagem de tratamento dos ortomosaicos.....	34
4.2 Análise dos Modelos de Previsão.....	35
<b>5 DISCUSSÃO .....</b>	<b>37</b>
<b>REFERÊNCIAS .....</b>	<b>40</b>

## 1 INTRODUÇÃO

As alterações no bioma Caatinga já atingem níveis de aproximadamente 50% da sua vegetação original, ocupando a posição de terceiro bioma mais degradado do Brasil, atrás apenas da floresta atlântica e do cerrado (OLIVEIRA et al., 2016; QUEIROZ et al., 2021). Embora atividade pecuária seja uma das principais atividades da região, está se encontra entre as principais fontes de interferência na Caatinga, devido a prática extensiva de pastejo, não adequação da pressão de pastejo e pastejo em momentos inadequados, que são impulsionados pela dificuldade de monitoramento e estimativa de parâmetros produtivos das plantas forrageiras (CARVALHO et al., 2021; PINHEIRO; NAIR, 2018; QUEIROZ et al., 2020).

Os sistemas agroflorestais (SAFs) são bastantes pertinentes na conciliação de viés econômicos e ambientais, contribuindo em diversos pontos, como: o uso integrado da terra, recuperação de áreas, conservação e promoção da biodiversidade, redução de erosão e da emissão de gases causadores do efeito estufa (SHARMA et al., 2022; SUÁREZ et al., 2021).

Denotando a importância de estudos voltados para utilização dos SAFs no bioma Caatinga e, o desenvolvimento de modelos que auxiliem no processo de monitoramento e na tomada de decisão por parte do produtor, principalmente, considerando toda complexidade e necessidade de gestão que os SAFs envolvem, é indispensável o aprimoramento de técnicas do sensoriamento remoto, que consiste em uma ferramenta relevante no processo de monitoramento e tomada de decisão no ambiente agrícola (CARNEIRO et al., 2020; XIAO; XIONG, 2022). Uma vez que, permite a obtenção de informações de forma remota e reduz a necessidade de análises lentas e destrutivas realizadas em campo, tendo, entre suas diversas aplicações, a estimativa dos rendimentos das culturas.

O emprego de veículos aéreos não tripulados (VANTs) no monitoramento de áreas produtivas vem apresentando alto crescimento ao longo dos anos, principalmente devido ao avanço na altitude, qualidade das câmeras, facilidade dos voos e processamento das imagens (DIMAGGIO et al., 2020). De acordo com a literatura consultada, diversos estudos utilizam essa tecnologia, contando principalmente com a utilização dos índices de vegetação (ANDRADE et al., 2022; ARENAS-CORRALIZA et al., 2022; BENIAICH et al., 2022; FREITAS et al., 2022) e desta forma, possibilitando a identificação de características produtivas da vegetação. Estes índices relacionam diferentes bandas do espectro eletromagnético, partindo das interações que as bandas apresentam com características da superfície de contato das

plantas, sendo esta influenciada principalmente pelo conteúdo de água, conteúdo de clorofila, carotenoides espécie (XUE; SU, 2017).

Diversos estudos aplicaram os índices de vegetação em sistemas agrícola convencionais e agrofloretais (ARENAS-CORRALIZA et al., 2022; CASTRO, 2019; GIUFFRIDA et al., 2022; WENGERT et al., 2021), no entanto, ainda é escasso o número de pesquisas que considerem, no processo de modelagem, formas de contornar a complexidade inerente as composições dos sistemas, principalmente os inseridos no bioma Caatinga Uma vez que, os SAFs possuem combinações de espécies com diferentes estruturas morfológicas e fisiológicas que, conseqüentemente, influência as relações dos índices com as características vegetativas, principalmente em sistemas agrofloretais no bioma Caatinga.

Diferentes técnicas de modelagem são utilizadas constantemente na literatura (AZADBAKHT et al., 2022; COSENZA et al., 2022; KAUSHAL et al., 2022; KEARNEY et al., 2022; LI et al., 2022; SWAYZE et al., 2022), entre estas, os métodos de aprendizado de máquina se destacam como uma importante ferramenta no processo de geração de modelos de previsão, contando com algoritmos capazes de aprender durante a definição de modelos e conseqüentemente aproveitando o máximo de informações na medida que caracterizam rapidamente padrões complexos dos dados de entrada. Assim, sendo possível melhorar os modelos obtidos no processo de automatização de ferramentas para o apoio à tomada de decisão (BAWA et al., 2023; DURMUŞ; ATASOY, 2023; GRAEVE et al., 2023; SHI et al., 2022). Portanto, é fundamental sua comparação com outro modelos, especialmente modelos clássicos e difundidos, como os modelos de regressão linear clássica (SERVIA et al., 2022).

Diante do exposto acima, manifestou-se a hipótese que os índices de vegetação são alternativas viáveis para estimativa de parâmetros produtivos de culturas forrageiras em sistemas agrofloretais no bioma Caatinga. Por consequência, objetivou-se comparar a capacidade preditiva de diferentes índices de vegetação sobre a biomassa e índice de área foliar de culturas forrageiras (capim corrente e capim buffel) em sistemas agrofloretais no bioma Caatinga e, avaliar a influência da remoção de componentes do sistema sobre o desempenho dos modelos.

## 2 REVISÃO DE LITERATURA

### 2.1 Bioma Caatinga

A Caatinga ocupa cerca de 13% do território brasileiro, estando incluso na região semiárida do Nordeste do Brasil caracterizada por longos períodos de secas, elevada variabilidade temporal e espacial da precipitação, elevada temperatura e alta demanda evapotranspirativa (SILVA et al., 2020). O termo ‘Caatinga’ refere-se principalmente a uma floresta tropical sazonalmente seca que apresenta uma variedade diversificada de fisionomias, formada por uma diversidade de espécies em diferentes estratos herbáceo, arbustivo e arbóreo (COSTA et al., 2018; GANEM et al., 2020).

O bioma Caatinga vem sofrendo um extenso processo de degradação ambiental, já ocupando a posição de terceiro bioma mais degradado do Brasil, logo após a floresta atlântica e o cerrado, as modificações sofridas por esse bioma já alcançam patamares em torno de 50% (OLIVEIRA et al., 2016; QUEIROZ et al., 2021). A atividade pecuária está entre as principais fontes de modificações da Caatinga, principalmente pela vegetação nativa do bioma servir como principal suporte forrageiro para a produção de pequenos ruminantes. Impulsionados pela dificuldade de monitoramento e estimativa de parâmetros produtivos das plantas forrageiras, a produção de pequenos ruminantes é uma das principais atividades da região que mais contribuem para degradação da Caatinga, pois é caracterizada pela prática extensiva de pastejo, não adequação da pressão de pastejo e pastejo em momentos inadequados. O monitoramento através do sensoriamento remoto, como a utilização de VANTs, é fundamental para auxiliar no acompanhamento da produção de forragem pelo produtor (CARVALHO et al., 2021; PINHEIRO; NAIR, 2018; QUEIROZ et al., 2020).

Com a necessidade de utilizar de forma adequada os recursos naturais, os SAFs surgem como uma poderosa estratégia de produção pois, reduz o impacto ambiental, promove a biodiversidade dos ecossistemas e melhora a conservação do solo, além de gerar diversidade de renda para os produtores rurais. (JHA; KAECHLE; SIEBER, 2021; NDLOVU; BORRASS, 2021).

## 2.2 Sistemas agroflorestais (SAFs)

Os SAFs constituem-se basicamente na produção agrícola e ou pecuária em simultâneo com a produção florestal, plantas perenes, herbáceas ou arbóreas, visando-se um aproveitamento da terra com foco não somente na produtividade, mas também na sustentabilidade, por meio da diversificação e manejo que possibilite a interação positiva entre as espécies presentes nesse sistema (VIERA; SCHUMACHER, 2011), contribuindo para maior segurança para o produtor e melhor aproveitamento de áreas ocupadas por espécies lenhosas sem a necessidade de desmatamento (ELBAKIDZE et al., 2021).

Promovem diversos benefícios ambientais, como: o aporte de nutrientes, através da promoção de matéria orgânica e ciclagem de nutrientes que ocorre pela captação em profundidade através do sistema radicular mais profundo dos componentes florestais, e posterior liberação por serrapilheira, podas, frutos e raízes mortas (CARSAN et al., 2014; SCHROTH et al., 2001; VILLARREYNA; AVELINO; CERDA, 2020); no ciclo do carbono, por sua capacidade de absorção e aumento do estoque no solo, com maior capacidade de sequestro que plantas de cultivo e pastagem, por contribuir tanto acima do solo quanto em profundidade devido ao extenso sistema radicular das árvores (LORENZ; LAL, 2014; RIBEIRO et al., 2019; SHI; HAN, 2014) e; na erosão do solo, devido maior cobertura da área e estruturação do solo e conseqüentemente menor impacto causado pelas gotas das chuvas, redução da velocidade do vento e do escoamento superficial (NGUYEN et al., 2021; OSUNA-CEJA, 2019; QUANDT, 2020; RAZA et al., 2021).

## 2.3 Adoção de sistemas agroflorestais na região semiárida do Brasil

Segundo o Censo Agropecuário Brasileiro 2017 (IBGE, 2019), os SAFs vêm apresentando crescimento considerável no Brasil, registrando um aumento de 67% entre os anos de 2006 e 2017, passando de 8,3 para pouco mais de 13,8 milhões de hectares destinados ao SAFs e, embora não tenha ocorrido nesse período um levantamento específico do número de SAFs no bioma Caatinga. Considerando os municípios que estão inclusos na delimitação do bioma Caatinga, observa-se um aumento entre as áreas destinadas ao sistema, passando cerca de 3.38 milhões de hectares, em 2006, para 6.87 milhões, em 2017.

O avanço se torna menos expressivo devido as limitações impostas principalmente pela ampla diversidade e complexidade dos sistemas de produção no Brasil (GORI MAIA et al.,

2021), mas que se torna necessário devido a segurança alimentar ser cada vez mais evidente devido ao aumento populacional, as mudanças climáticas e da redução dos recursos naturais (TADESSE et al., 2021).

Embora a implantação de SAFs no semiárido brasileiro ainda seja considerado um assunto complexo, principalmente devido a variabilidade climática da região, alguns estudos (MAGALHÃES et al., 2020; MARTINS et al., 2015; PACIULLO et al., 2011; PEREZ-MARIN; MENEZES, 2009; SACRAMENTO et al., 2013) vêm sendo desenvolvidos abordando esse assunto.

Esses estudos destacam que os SAFs no semiárido reduzem de uso de fertilizantes nitrogenados (MARTINS et al., 2015), aumentam o aporte de N, P e K através da água da chuva por escorrer pela copa e tronco das árvores em relação a que entrava em contato direto com o solo (PEREZ-MARIN; MENEZES, 2009), elevam o sequestro de C e N do solo (SACRAMENTO et al., 2013), reduzem a variação de proteína bruta da pastagem (PACIULLO et al., 2011) e melhoram o conforto térmico animal (MAGALHÃES et al., 2020).

#### 2.4 Monitoramento e índices de vegetação

O monitoramento eficiente das características inerentes as áreas de produção é um processo importante para garantir maior qualidade e produtividade dos cultivos, possibilitando identificar problemas de forma mais precisa, como: falhas no plantio, áreas com baixa biomassa, fertilidade do solo, ocorrência de pragas e doenças. No entanto, as medições de campo geralmente apresentam custo elevado, são onerosas e destrutivas, reduzindo a frequência de repetições ao longo do tempo e a qualidade do monitoramento (ALI et al., 2022; MARTINEZ et al., 2021; XU et al., 2021). Desta forma, as técnicas de sensoriamento remoto (como exemplo: drones, satélites e sensores) são importantes ferramentas para tornar mais rápida e menos onerosa quando comparadas as práticas de monitoramento em campo.

O monitoramento através do sensoriamento remoto se torna possível devido a radiação refletida pelas plantas, sejam em comprimentos de ondas visíveis ou por infravermelho, possibilitando avaliação de fatores como o estresse, cobertura do solo, atividade fotossintética, desenvolvimento, danos e doenças (ALI et al., 2022). A utilização do sensoriamento remoto para determinação de parâmetros produtivos de plantas forrageiras é possível em virtude dos índices de vegetação, tais como: NDVI (*Normalized Difference Vegetation index*), VARI (*Visible Atmospherically Resistant Index*) e GLI (*Green Leaf Index*) (JEÍNEK et al., 2020;

VALDERRAMA-LANDEROS et al., 2021). Os dados espectrais podem ser obtidos por imagens disponibilizadas por satélites e por VANTs. Com os VANTs possibilita melhor resolução espacial, melhor planejamento dos intervalos de tempo de coleta de informações, quando comparado com as imagens obtidas por satélites (MARTINEZ et al., 2021) e, mesmo necessitando de investimento em equipamentos e mão de obra especializada, trata-se de uma solução flexível devido a variedade de VANTs e sensores disponíveis no mercado (COSTA; NUNES; AMPATZIDIS, 2020).

## 2.5 Aprendizado de máquina

O desenvolvimento e emprego de tecnologias nas áreas de produção são cada vez mais importantes, contribuindo para melhor produtividade, qualidade, sustentabilidade e na redução de custo. Assim, a utilização de inteligência artificial (IA) se destaca como uma importante ferramenta, possuindo diferentes subcampos como o processamento de imagens, mineração e análise de dados e o aprendizado de máquina (CIOFFI et al., 2020). O aprendizado de máquina (ML) é comumente classificado como um tópico da IA utilizado para análise e compreensão dos dados e desta forma, através da sua capacidade de aprendizado, identificar padrões e regras complexas existentes nos dados, tendo como consequência aplicação em processos de tomada de decisão que envolvem modelos de classificação e previsão com o mínimo de intervenção humana (SARKER et al., 2020).

O ML vem sendo aplicado em diversos seguimentos ciências agrárias, conforme relatado por Jamali et al. (2023), que aplicaram os ML na estimativa do índice de área foliar (IAF) e parâmetros foliares do trigo, utilizando máquinas de vetores de suporte (SVM), redes neurais (ANN) e redes neurais profundas (DNN), encontrando resultados positivos para DNN; Moradi et al. (2023) identificaram melhor desempenho para os algoritmos de aprendizado de máquina (modelo *ensemble* e *Random Forest*) em relação ao uso do sensoriamento remoto, na capacidade preditiva espacial da vulnerabilidade da vegetação aos estresses hidrometeorológicos na bacia do sul do Baluchistão; Bawa et al. (2023) aplicaram as máquinas de vetores de suporte (SVM) na identificação de capulhos de algodão abertos em diferentes configurações ambientais encontrando altas precisões de classificação, Poudyal et al. (2022) estimaram de forma eficiente, através de um modelo de árvore de regressão de aumento de gradiente, a concentração de sacarose, toneladas de açúcar e porcentagem de sacarose da cana-de-açúcar. Com o exposto acima, denota-se a importância do estudo e aplicação do aprendizado

de máquina na predição e no auxílio da tomada de decisão nos meios de produção agrícola. No entanto, ainda são escassos a utilização desta tecnologia para tomada de decisões em SAFs, principalmente aqueles inseridos no bioma Caatinga.

## 2.6 Milho (*Zea Mays* L.)

O milho (*Zea mays* L.) é um dos cereais mais importantes do mundo, sendo consumido em diversas formas e com altas qualidades nutricionais. Ele fornece cerca de metade do consumo de calorias mundial e é utilizado tanto para a alimentação humana quanto para garantir a segurança alimentar de muitos agricultores familiares, quanto para alimentação animal, além de estar presente na composição de produtos da indústria cosmética e farmacêutica (ABBAS; ABDEL-LATTIF; SHAHBA, 2021; ALMEIDA et al., 2020; ROSA et al., 2021; ZUFFO et al., 2021). Geralmente é cultivado em áreas secas e na região Nordeste, seja em sistema solteiro ou consorciado. A produtividade da cultura depende da ocorrência de eventos de precipitação, variando entre 387 a 683 mm (SOUZA et al., 2015).

Nardini et al. (2019) relatam a importância da utilização do milho, em consorcio com espécies florestais, como uma cultura importante principalmente para produtores rurais, garantindo a expansão da área de cultivo de forma sustentável. Atentando-se a importância de estudos sobre tal cultura, principalmente pelo seu metabolismo C4, conferindo problemas quanto a sua capacidade fotossintética devido a incidência de radiação reduzida, afetando a produção de biomassa e conteúdo de proteína do milho.

## 2.7 Feijão-caupi (*Vigna unguiculata*)

O feijão-caupi (*Vigna unguiculata*) é uma importante leguminosa para os trópicos semiáridos que inclui partes da África, Ásia, América Central, América do Sul, Sul da Europa e Sul Estados Unidos (ALAM et al., 2018). Introduzida no Brasil em torno do século XVI, teve início de sua produção em maior escala em 2006 após se expandir para regiões mais fortes do meio agrícola (RAISSE et al., 2020). Chegando a produzir cerca de 738 mil toneladas em 2018 sendo a segunda leguminosa mais produzida no Brasil (HASHIMOTO; SCHMIELE; NABESHIMA, 2021).

O Nordeste destaca-se com 63,4% da produção total do Brasil, e com 87% das leguminosas produzidas na região representadas pelo cultivo de feijão-caupi (HASHIMOTO; SCHMIELE; NABESHIMA, 2020, 2021), devido a boa adaptabilidade a região semiárida,

rusticidade, precocidade, tolerância a ampla faixa de temperatura (18 °C e 37 °C) e ao déficit hídrico no solo (ANGELOTTI et al., 2020; BARBOSA et al., 2021; HASHIMOTO; SCHMIELE; NABESHIMA, 2021).

Segundo Osman et al. (2011), O feijão-caupi é uma das culturas mais importantes a serem associadas a árvores como a *Parkia biglobosa* (Jacq.) Benth, uma importante prática utilizada nas zonas do Sahel e Sudão da África, principalmente por sua tolerância a seca e ao sombreamento. Bado et al. (2021) denotam que em certas configurações o consorcio entre milho e feijão-caupi sob *Ziziphus mauritiana* apresenta melhor produtividade que o monocultivo, sendo um importante meio socioeconômico, principalmente para pequenos agricultores, garantindo um manejo sustentável dos recursos ambientais.

## 2.8 Algodoeiro herbáceo (*Gossypium hirsutum* L.)

O algodão (*Gossypium hirsutum* L.) é uma cultura perene, tropical e indeterminada, cultivada anualmente para obtenção de fibras, óleo e farinha. A semente de algodão é uma importante matéria prima usada para obtenção de óleo comestível, produção de biodiesel, ração animal e vários produtos industriais (XU et al., 2021).

Cultivado predominantemente em condições de sequeiro, um dos principais limitantes da produtividade do algodão, afetando a produção de matéria seca do caule, sementes e fibra (LACAPE; WERY; ANNEROSE, 1998; WITT et al., 2020) (LACAPE; WERY; ANNEROSE, 1998; WITT et al., 2020), além de bastante sensível a variação de temperatura, com faixa ótima entre 29,9 e 32,6 °C (XU et al., 2021).

## 2.9 Capim Buffel (*Cenchrus ciliaris*)

O capim buffel (*Cenchrus ciliaris*) é uma gramínea forrageira perene, nativa da África, Oriente Médio, Ásia e Europa, amplamente cultivada em regiões tropicais e subtropicais ao redor do mundo, sendo uma das gramíneas forrageiras mais indicadas para o semiárido brasileiro. Além de ser tolerante a seca, apresenta um sistema radicular profundo, rápido crescimento, povoamentos densos, suporta pastagens pesadas, responde de forma rápida a umidade, elevada capacidade competitiva e, alto valor nutricional para bovinos e ovinos (BRUNO et al., 2017; BURSON et al., 2015; MARTIN et al., 2015).

Burson et al. (2015) avaliando a produtividade de biomassa em SAFs no semiárido paraibano, com gliricídia (*Gliricidia sepium* (Jacq.) Steud) e maniçoba (*Manihot glaziovii* Muel Arg.), verificaram que o buffel apresentou maior produtividade nos sistemas agroflorestais quanto comparado com a palma e o consórcio milho-feijão, igualando a produtividade do consórcio milho-feijão no cultivo tradicional (sem as árvores). Demonstrando a capacidade dessa cultura em sistemas mais complexos mesmo em condições mais restritas como as semiáridas.

## 2.10 Capim corrente (*Urochloa mosambicensis*)

O capim corrente (*Urochloa mosambicensis*) é uma gramínea forrageira perene, originada do sul da África, adaptada as condições semiáridas com bom desenvolvimento entre precipitações anuais de 500 mm e 1000 mm. Considerada uma importante espécie forrageira exótica no aumento de produção de forragem nas regiões semiáridas, contribuindo para melhora dos aspectos socioeconômicos dessas regiões. Apresenta hábito rastejante e estolonífero, tolerância a salinidade, capacidade de crescer em diferentes tipos de solo e fertilidade, tolerância ao pastejo pesado e boa produção de sementes (COÊLHO et al., 2021; KUMAR et al., 2017; LEITE et al., 2017).

*U. mosambicensis* demonstrou-se como uma importante espécie para a restauração de pastagens degradadas devido sua capacidade de cobertura do solo pelas maiores taxas de fotossíntese garantidas pela largura e número de folhas, além da agressividade dos seus estolões, sua capacidade de dispersão dupla (estolões e sementes) (COÊLHO et al., 2021; RAVHUHALI et al., 2019).

## 3 MATERIAL E MÉTODOS

### 3.1 Localização e caracterização da área experimental

O estudo foi realizado na Universidade Federal Rural de Pernambuco/Unidade Acadêmica de Serra Talhada (UFRPE/UAST) em Serra Talhada-PE, Brasil (Figura 1), durante os períodos de 26/02/2021 a 17/06/2021 e 25/03/2022 a 29/06/2022, desenvolvido em área de Caatinga (7° 57' 2" S, 38° 17' 53" W) raleada, rebaixada e enriquecida com *Urochloa mosambicensis* Hack Dandy (capim corrente) e *Cenchrus ciliares* L. (capim buffel), e com altitude média de 512 m.

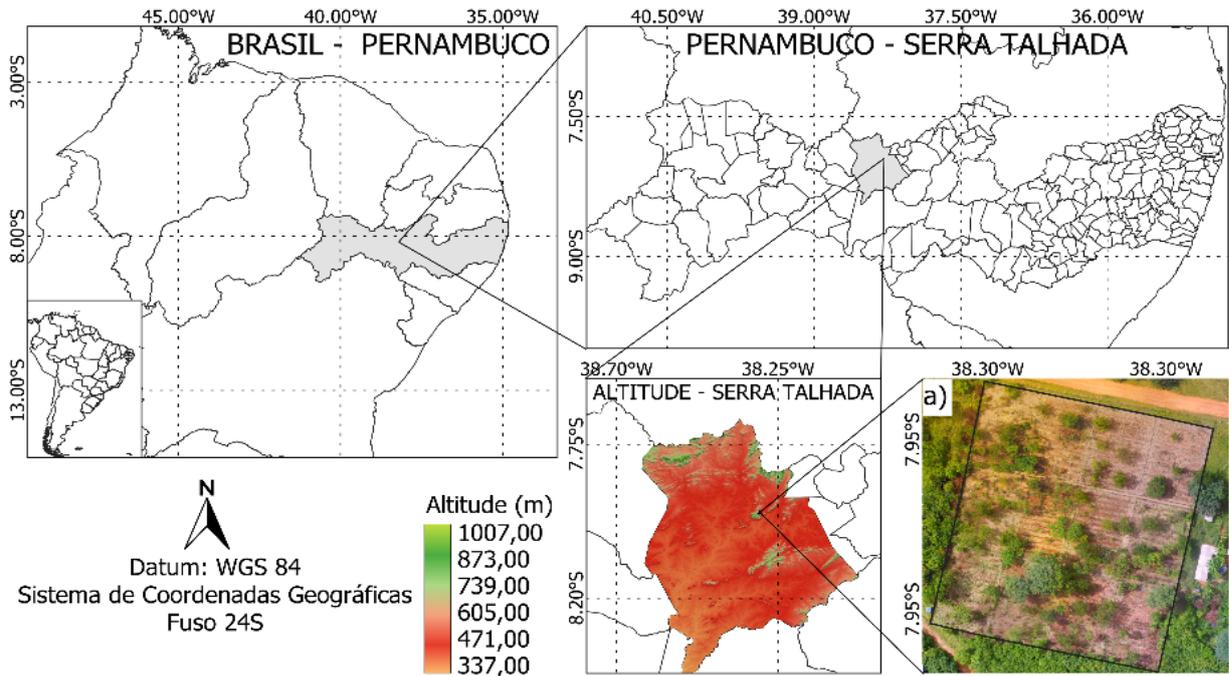


Figura 1. Localização do experimento. a) Foto aérea georreferenciada da área experimental, b) Mapa de altitude da área experimental

A região é caracterizada com clima do tipo BSw<sub>h</sub> (clima semiárido com invernos secos e verões chuvosos) segundo a classificação climática de Köppen (ALVARES et al., 2013). Durante o período de condução do experimento foram registrados temperatura do ar de 24,75 e 25,41 °C, umidade relativa do ar de 66,64 e 77,27%, precipitação acumulada do período de 419,80 mm e 180,3 mm e radiação de 19,02 e 17,01 MJ/m<sup>2</sup>, 2021 e 2022 respectivamente, obtidos por meio da estação meteorológica do Instituto Nacional de Meteorologia (INMET), localizada a 548 metros da área experimental (Figura 2).

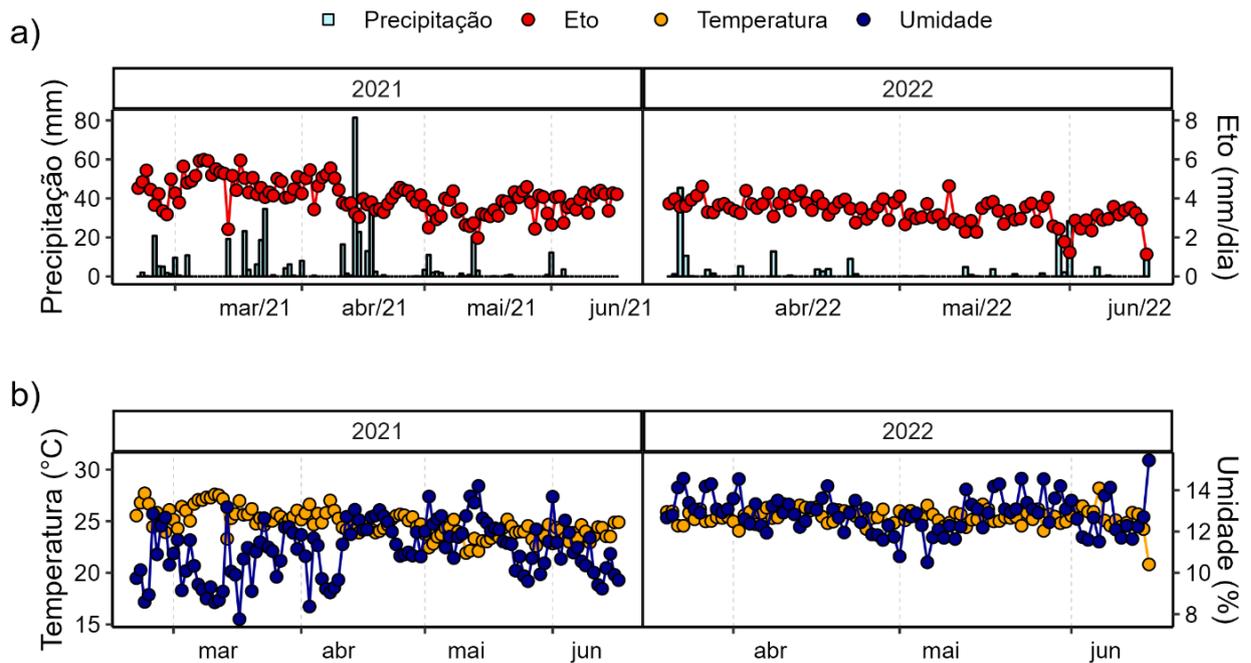


Figura 2. Condições meteorológicas no período experimental, 26 de fevereiro de 2021 a 17 de junho de 2021 e 25 de fevereiro de 2022 a 29 de junho de 2022. a) Valores de Precipitação e evapotranspiração de referência (ETo). b) Temperatura e umidade relativa do ar (ALLEN et al., 1998)

### 3.2 Tratamentos experimentais

A área experimental possuía 7200 m<sup>2</sup> (80 x 90 m), dividida em três blocos contendo quatro parcelas de 584 m<sup>2</sup> (29,20 x 20 m), abrangendo quatro sistemas agroflorestais em cada bloco da área (Figura 3). Os sistemas agroflorestais contaram com uma integração entre a vegetação do bioma Caatinga (Tabela 1), plantas forrageiras e culturas agrícolas. Foram utilizados o capim corrente (*Urochloa mosambicensis* (Hack.) Dandy) e capim buffel (*Cenchrus ciliaris* L.) e, as culturas agrícolas: milho (*Zea mays* L. cv. Batité), feijão-caupi (*Vigna unguiculata* L. cv. CCE-115) e algodão (*Gossypium hirsutum* L. cv. BRS Aroeira).

Tabela 1. Espécies encontradas na área experimental

Nome Vulgar	Espécie
Mororó	<i>Bauhinia cheilantha</i> Steud.
Marmeleiro	<i>Croton sonderianus</i> Müll. Arg.
Feijão bravo	<i>Capparis flexuosa</i> L.
Jurema branca	<i>Mimosa</i> sp.
Cipó unha-de-gato	<i>Uncaria</i> sp.
Catingueira	<i>Caesalpinia pyramidalis</i> Tul.
Maniçoba	<i>Manihot glaziovii</i> Müll. Arg.
Juazeiro	<i>Ziziphus joazeiro</i> Mart
Angico	<i>Anadenanthera macrocarpa</i> (Benth) Brenan
Tingui	<i>Magonia</i> sp.
Capim meloso	<i>Melinis</i> sp.
Picão preto	<i>Bidens pilosa</i>
Pau-piranha	<i>Guapira</i> sp.
Capa bode	<i>Melochia tomentosa</i> L.
Aroeira mansa	<i>Myracrodruon urundeuva</i> Allemão
Mandacaru	<i>Cereus jamacaru</i> . DC
Incó	<i>Neocalyptrocalyx</i> sp.
Jurema preta	<i>Mimosa tenuiflora</i> Benth.
Jitirana	<i>Merremia aegyptia</i> (L.) Urb.

Os tratamentos foram constituídos por quatro sistemas agroflorestais no bioma Caatinga, caracterizados da seguinte forma: 1) capim corrente-buffel + feijão + Caatinga; 2) capim corrente-buffel + algodão + Caatinga; 3) capim corrente-buffel + milho + Caatinga; 4) capim corrente-buffel + Caatinga (Figura 3).



Figura 3. Design experimental. B: bloco; P: parcela; CA: Caatinga; CB: capim corrente-buffel; AG: Algodão; FE: feijão; MI: milho.

No preparo da área foram realizados o raleamento e rebaixamento da vegetação da Caatinga para tornar o ambiente mais propício para o desenvolvimento das demais culturas. O capim corrente e o capim buffel já estavam estabelecidos na área antes do início do experimento, sendo realizado um corte de uniformização a 10 cm de altura do solo com auxílio de uma roçadeira costal (Stihl FS160) (Figura 4). Para plantio das culturas agrícolas foram abertas faixas de plantio entre os capins com 1 metro de largura e 26 metros de comprimento, resultando em uma distância de 0,5 m entre as culturas e o capim. Os espaçamentos foram de 0,5 m entre plantas e 2 m entre fileiras.

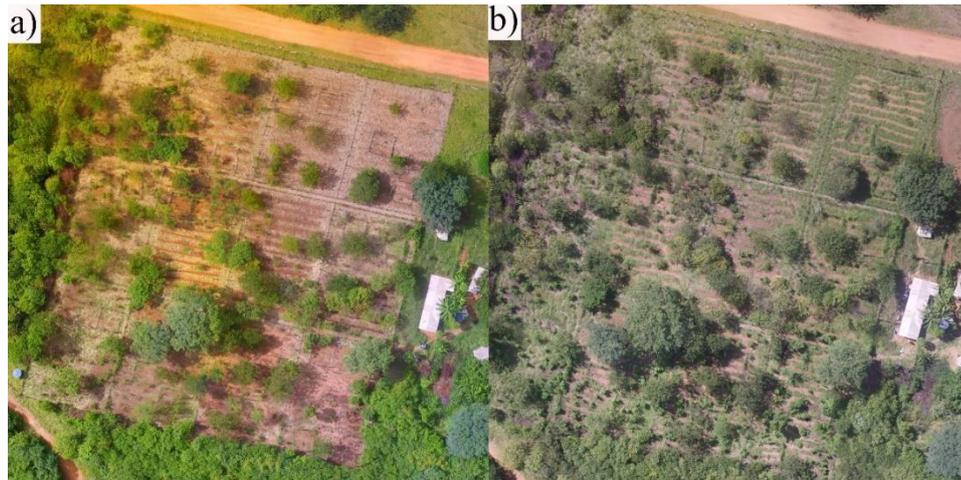


Figura 4. Fotos áreas da área experimental. a) Antes da implantação. b) Após implantação

### 3.3 Padrão de voo do veículo aéreo não tripulado

Para captura das imagens foi utilizado um VANT modelo *Phantom 3 advanced*, da marca DJI, portando uma câmera com sensor de 1/2.3" CMOS e 12.76 M pixels (12.4 M efetivos). Com intuito de compreender toda área de estudo, o padrão de voo foi realizado conforme o padrão de *boustrophedon* (ROSSELLO et al., 2021) (Figura 5) à uma altura de 100 m do solo.



Figura 5. Padrão de voo do VANT

A obtenção das imagens ocorreu a cada sete dias entre às 10 h e 14 h durante período de iluminação consistente, evitando-se a presença de nuvens devido sua interferência pelo sombreamento na área de captura e, conseqüentemente, na qualidade das imagens. O padrão de sobreposição utilizado para as imagens foi de 80% frontal e 70% lateral com a finalidade de reduzir a perda de informações, sendo as coordenadas das imagens definidas pelo sistema de posicionamento global GPS/Glonass acoplado ao VANT (ARANTES et al., 2019).

### 3.4 Geração de ortomosaicos e índices de vegetação

As imagens coletadas no voo foram processadas em formas de ortomosaico, que consiste na construção de uma única imagem a partir da composição das fotos sobrepostas (ROSSELLO et al., 2021). O processamento dos ortomosaicos foi realizado com auxílio do *WebODM* (versão 1.9.15) (OPENDRONEMAP, 2022), um software de mapeamento de drones de código aberto, com as correções de georreferenciamento realizadas com auxílio do *QGIS* (versão 3.20.10) (QGIS DEVELOPMENT TEAM, 2022) através do plugin *LF Tools*.

Após o processamento, as imagens foram manipuladas no software R versão 4.1.3 (R CORE TEAM, 2022) com auxílio dos pacotes *raster* (HIJMANS, 2022) e *FIELDimageR* (MATIAS; CARAZA-HARTER; ENDELMAN, 2020). Os ortomosaicos sofreram quatro abordagens diferentes, *Agrofor - Complete*; *Soil - Removed*; *Tree - Removed* e *Tree+Soil - Removed*, conforme descrito na Tabela 2.

Tabela 2. Descrição dos arquivos gerados a partir de cada ortomosaico

Tipo de Arquivo	Descrição
<i>Agrofor - Complete</i>	Arquivo original contendo todos os componentes da área de estudo (solo, culturas, árvores)
<i>Soil - Removed</i>	Arquivo com o componente solo removido
<i>Tree - Removed</i>	Arquivo com o componente árvore removido
<i>Tree+Soil - Removed</i>	Arquivo com os componentes solo e árvore removidos

A remoção dos componentes, solo e árvore, tiveram como finalidade melhorar a influência de cada componente sobre a correlação entre os índices de vegetação gerados e os parâmetros a serem estimados (massa seca, massa fresca e índice de área foliar). Não ocorreu remoção das culturas devido maior dificuldade de diferenciação dos capins. Para remoção do

solo foram utilizados valores limiares do índice de vegetação HUE. Para remoção das árvores foi gerado uma máscara de corte através do índice de vegetação NGRDI a partir do ortomosaico do início do experimento (Figura 3a), devido maior facilidade de identificação. Posteriormente foram calculados 11 índices de vegetação baseados em RGB (*Red, Green, Blue*) (Tabela 3) para cada um dos arquivos gerados (Tabela 2) em todas as datas de coleta.

Tabela 3. Índices de vegetação

Nome	Abreviatura	Equação	Autoria
Brightness Index	BI	$((R^2+G^2+B^2)/3)^{0.5}$	(RICHARDSON; WEIGAND, 1977)
Blue Green Pigment Index	BGI	B/G	(ZARCO-TEJADA et al., 2005)
Green Leaf Index	GLI	$(2*G-R-B)/(2*G+R+B)$	(LOUHAICHI; BORMAN; JOHNSON, 2001)
Primary Colors Hue Index	HI	$(2*G-R-B)/(G-B)$	(ESCADAFAL; BELGHIT; BEN-MOUSSA, 1994)
Overall Hue Index	*HUE	$\text{cotg}(2*(B-G-R)/30.5*(G-R))$	(ESCADAFAL; BELGHIT; BEN-MOUSSA, 1994)
Normalized Green Red Difference Index	NGRDI	$(G-R)/(G+R)$	(TUCKER, 1979)
Modified Green Red Vegetation Index	MGRVI	$(G^2-R^2)/(G^2 + R^2)$	(BENDIG et al., 2015)
Red Green Blue Vegetation Index	RGBVI	$(G^2-B*R^2)/(G^2 + B*R^2)$	(POSSOCH et al., 2016)
Soil Color Index	SCI	$(R-G)/(R+G)$	(MATHIEU et al., 1998)
Spectral Slope Saturation Index	SI	$(R-B)/(R+B)$	(ESCADAFAL; BELGHIT; BEN-MOUSSA, 1994)
Visible Atmospherically Resistant Index	VARI	$(G-R)/(G+R-B)$	(GITELSON et al., 2002)

R: Red, G: Green, B: Blue, cotg: cotangente. \*HUE modificado por Matias et al. (2020).

### 3.5 Massa de forragem e Índice de área foliar (IAF)

A determinação da massa de forragem e do índice de área foliar dos capins foi realizada em dias e coincidentes com a coleta de imagens. Para massa de forragem foi realizado o corte ao nível do solo com auxílio de uma moldura com  $0,25 \text{ m}^2$  em três pontos representativos por parcela para cada capim (Figura 6). Posteriormente, as amostras foram pesadas para definir a massa fresca (MF), acondicionadas em sacos de papel devidamente identificados e secas em estufa de ventilação forçada a  $55 \text{ }^\circ\text{C}$  por 72 h para determinação da massa seca (MS).



Figura 6. Moldura com  $0,25 \text{ m}^2$  para coleta da massa de forragem

O índice de área foliar (IAF) foi obtido através do uso de sensor portátil ceptômetro *AccuPAR (LP-80, Decagon Devices, Pullman, USA)* (FANG et al., 2014), realizando-se cinco medidas em locais representativos por parcela, considerando o mesmo intervalo de horário e condições de luminosidade das coletas de imagens (Figura 7).



Figura 7. Uso de sensor portátil ceptômetro *AccuPAR* para determinação do IAF

### 3.6 Análise de correlação

Foi utilizado o índice de correlação de *Spearman* para avaliar as correlações entre os índices de vegetação e os parâmetros considerados da cultura (massa fresca, massa seca e IAF). A escolha deste método consiste na melhor capacidade de avaliar o grau de associação em um cenário de dados mais dispersos e com presença de *outliers* (SCHOBER; SCHWARTE, 2018; WINTER; GOSLING; POTTER, 2016). A correlação foi determinada com o software R versão 4.1.3 (R CORE TEAM, 2022).

### 3.7 Modelos de aprendizado de máquina

Para os modelos de máquinas de aprendizado, foram utilizados os métodos: regressão linear é um método estatístico utilizado para determinar relações entre uma variável dependente (valor a ser previsto) e uma ou mais variáveis independentes (preditoras), assumindo uma relação linear entre as variáveis (WANG; SHI; WEN, 2023); redes neurais (ANNs), que consistem em um processo simplificado inspirado nas redes neurais biológicas, possibilitando o reconhecimento de padrões em conjuntos de dados complexos através do aprendizado (GUE

et al., 2020; HASSON; NASTASE; GOLDSTEIN, 2020); máquinas de vetores de suporte (SVM), com aprendizado que envolve o reconhecimento de padrões por meio da definição de um hiperplano que particiona os dados em áreas homogêneas, para auxílio nos processos de previsão (BAWA et al., 2023; MOUSAVIZADEGAN et al., 2023); cubista (Cub), um método de árvore modelo caracterizado pela utilização de árvores para posterior análise de regressão, onde a regressão é aplicada no subconjunto de dados que são formados após a partição dos dados realizada pelas árvores (ALABI et al., 2022); árvores de regressão impulsionadas (BRTs), destacando-se pelo seu alto poder preditivo ao considerar o conceito de divisão binária recursiva em conjunto com uma técnica de aprendizado (impulsioneamento) (DÖPKE; FRITSCH; PIERDZIOCH, 2017) e; árvores de classificação e regressão (CART), baseada em regras que permitem a criação de árvores a partir de um particionamento recursivo, dividindo os dados em subconjuntos com base em fatores independentes (POURGHASEMI; RAHMATI, 2018).

### 3.8 Avaliação dos modelos

O desempenho preditivo dos modelos foi avaliado por meio de validação *cruzada k-fold*, repetido dez vezes, que consiste em dividir os dados em subconjuntos, usando um dos subconjuntos como teste e os outros para estimar o modelo, aumentando a confiabilidade e imparcialidade durante a estimativa (TAJIK; AYOUBI; ZERAATPISHEH, 2020). Foram utilizados para avaliação dos resultados da validação cruzada: o erro quadrático médio (RMSE), o erro absoluto médio (MAE), o coeficiente de correlação de Lin (CCC) e o coeficiente de determinação ( $R^2$ ).

O processo de modelagem foi realizado com o software R versão 4.1.3 (R CORE TEAM, 2022), com auxílio dos pacotes *neuralnet* (FRITSCH; GUENTHER; WRIGHT, 2019), *kernelab* (KARATZOGLOU; SMOLA; HORNIK, 2022), *Cubist* (KUHN; QUINLAN, 2022), *gbm* (GREENWELL et al., 2022) e *rpart* (THERNEAU; ATKINSON, 2022) para os modelos ANNs, SVM, Cub, BRTs e CART, respectivamente. Para avaliação foram utilizados os pacotes *caret* (KUHN, 2022) e *DescTools* (ANDRI ET MULT. AL., 2022).

## 4 RESULTADOS

### 4.1 Correlação e determinação da abordagem de tratamento dos ortomosaicos

Como nos resultados não houve diferença entre os tratamentos realizados, todas as imagens e as variáveis produtivas (massa fresca, massa seca e IAF) foram avaliadas em conjunto, ou seja, independente dos sistemas agroflorestais. Sendo descrito os dados médios, máximos, mínimos, mediana e desvio padrão.

Tabela 4. Análise descritiva da biomassa e índice de área foliar do capim buffel e do capim corrente para cada tratamento.

	Tratamento	Média	Máximo	Mínimo	Mediana	Desvio padrão	P<0.05
Massa Fresca (kg/ha)	Algodão	16185.38	32650.67	1068.67	18324.13	2327.29	0.95
	Caatinga	14537.66	33775.73	988.53	15451.33	2214.05	0.95
	Feijão	14569.63	31284.93	1527.87	15461.83	1671.66	0.95
	Milho	16260.14	38802.67	1556.27	13969.97	3393.82	0.95
Massa Seca (kg/ha)	Algodão	5050.21	12007.62	193.60	4968.13	1057.59	0.99
	Caatinga	4675.15	12568.19	130.21	5024.50	1065.31	0.99
	Feijão	5116.42	19795.12	239.20	4065.86	2077.48	0.99
	Milho	5241.47	14414.41	275.34	4318.56	982.65	0.99
Índice de área foliar	Algodão	1.23	2.55	0.29	1.25	0.28	0.98
	Caatinga	1.24	2.25	0.33	1.26	0.15	0.98
	Feijão	1.32	2.88	0.31	1.31	0.26	0.98
	Milho	1.27	3.56	0.35	1.33	0.38	0.98

Os índices NGRDI, MGRVI e VARI apresentaram as maiores correlações positivas e significativas ( $P < 0,05$ ) para massa fresca (0,8 para NGRDI, 0,8 para MGRVI e 0,8 para VARI), massa seca (0,7 para NGRDI, 0,7 para MGRVI e 0,7 para VARI) e IAF (0,7 para NGRDI, 0,7 para MGRDI e 0,7 para VARI), respectivamente. Os índices SCI, SI e HUE apresentaram as maiores correlações negativas e significativas ( $P < 0,05$ ) para massa fresca (0,8 para SCI, 0,7 para SI e 0,7 para HUE), massa seca (0,7 para SCI, 0,7 para SI e 0,7 para HUE) e IAF (0,7 para SCI, 0,6 para SI e 0,5 para HUE), respectivamente. Enquanto BGI, GLI, RGB e BI apresentam ocorrências não significativas ( $P > 0,05$ ) (Figura 8).

Os índices SCI e MGRVI apresentaram comportamento significativo ( $P < 0,05$ ) idêntico ao do NGRDI com correlações de 0,8, 0,7 e 0,7 para MF, MS e IAF, respectivamente, com o SCI com valores em módulo iguais aos valores de NGRDI. Optando-se pela retirada de ambos nos processos de estimativa, mantendo-se somente o NGRDI (Figura 8).

A abordagem de tratamento dos ortomosaicos pela remoção de componentes (árvore e solo) que mais contribuiu para melhoria dos valores de correlação foi a remoção das árvores (Figura 8) e, portanto, foi utilizada na geração dos modelos preditivos.

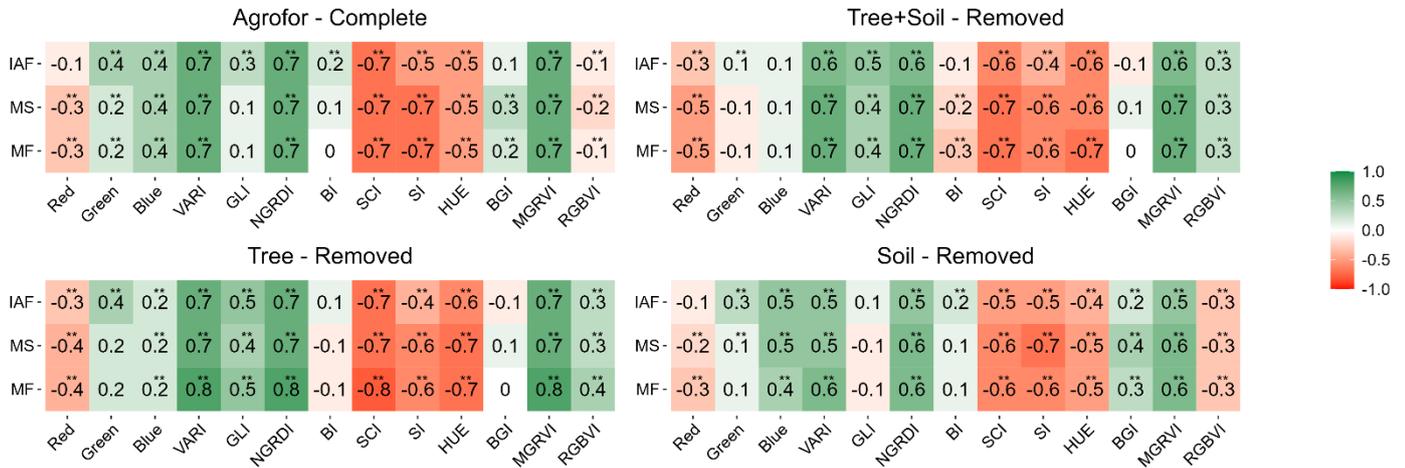


Figura 8. Coeficientes de correlação de *Spearman* da relação entre as características consideradas e os índices e vegetação para cada abordagem sobre os ortomosaicos. \*\* representa significância de 0,05

#### 4.2 Análise dos Modelos de Previsão

Com relação aos modelos de regressão linear, o NGRDI apresentou melhor ajuste para MF (RMSE = 4002,04, MAE = 3551,13, CCC = 0,83,  $R^2 = 0,75$ ) e MS (RMSE = 1743,56, MAE = 1514,18, CCC = 0,71,  $R^2 = 0,69$ ), e o VARI para IAF (RMSE = 0,31, MAE = 0,26, CCC = 0,77,  $R^2 = 0,71$ ), no qual apresentou diferença menos evidente entre os índices do que para MF e MS (Tabela 5).

Tabela 5. Resultados do processo de validação cruzada para os modelos de regressão linear simples

Índice	Resposta	RMSE	MAE	CCC	$R^2$	Equação
NGRDI	Massa fresca	4002.04	3551.13	0.83	0.75	$y = 22022 + 152776x$
VARI	Massa fresca	4164.82	3656.81	0.82	0.73	$y = 22610 + 98632x$
NGRDI	Massa seca	1743.56	1514.18	0.71	0.69	$y = 7258 + 52400x$
VARI	Massa seca	1805.94	1623.18	0.70	0.66	$y = 7446 + 33669x$
NGRDI	Índice de área foliar	0.31	0.26	0.76	0.68	$y = 1,678 + 9,232x$
VARI	Índice de área foliar	0.31	0.26	0.77	0.71	$y = 1.727 + 6,133x$

RMSE: erro quadrático médio, MAE: erro absoluto médio, CCC: coeficiente de correlação de Lin e  $R^2$ : coeficiente de determinação.

Para os métodos de aprendizado de máquina, os melhores modelos foram encontrados para o método de árvores de regressão particionada (Tabela 6), inclusive comparando com a regressão linear (Tabela 5), apresentando um RMSE menor, ou seja, com valores de 3020.86, 1201.75 e 0.20 para MF, MS e IAF, respectivamente. Assim como, maior precisão e acurácia para os valores previstos (CCC), apresentando valores 0.94 para MF, MS e IAF.

Tabela 6. Resultados do processo de validação cruzada para os métodos de aprendizado de máquina

Parâmetro	Modelo	RMSE	MAE	CCC	R <sup>2</sup>
Massa fresca	RN	4898.54	3911.63	0.81	0.73
	SVM	5488.14	4309.95	0.78	0.68
	CART	3020.86	2339.19	0.94	0.89
	Cub	5275.10	4046.60	0.80	0.68
	BRT	3414.95	2599.76	0.91	0.88
Massa seca	RN	2185.85	1661.84	0.76	0.66
	SVM	2358.47	1853.77	0.72	0.59
	CART	1201.75	935.84	0.94	0.89
	Cub	2353.00	1567.60	0.72	0.59
	BRT	1787.54	1295.92	0.83	0.78
Índice de área foliar	RN	0.34	0.25	0.81	0.72
	SVM	0.42	0.33	0.70	0.56
	CART	0.20	0.15	0.94	0.89
	Cub	0.36	0.24	0.78	0.67
	BRT	0.27	0.19	0.87	0.81

RN: redes neurais, SVM: máquinas de vetores de suporte, CART: árvores de classificação e regressão, Cub: Cubista, BRTs: árvores de regressão impulsionadas, RMSE: erro quadrático médio, MAE: erro absoluto médio, CCC: coeficiente de correlação de Lin e R<sup>2</sup>: coeficiente de determinação.

Analisando as influências das variáveis no modelo de destaque CART, nota-se o NGRDI e o VARI como destaque assim como nos índices de correlação linear (Figura 9), seguidos pelo índice HUE.

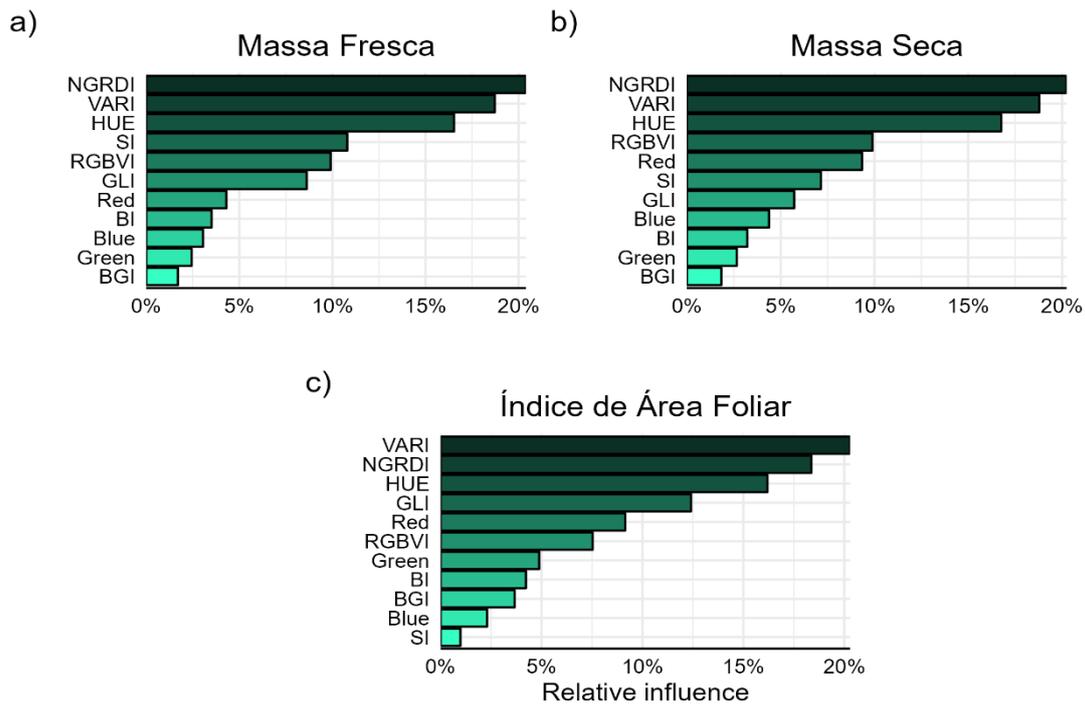


Figura 9. Influência relativa dos índices os modelos finais de árvores de classificação e regressão (CART)

## 5 DISCUSSÃO

A remoção das árvores do ortomosaicos para o processo de estimativa mostrou-se um processamento importante na predição das variáveis produtivas do capim corrente e do capim buffel em sistemas agroflorestais no bioma Caatinga. Semelhantemente ao encontrado por Lourenço et al. (2021) na análise da biomassa das árvores acima do solo em um sistema agroflorestal, onde foram extraídas somente as árvores para geração dos modelos.

A remoção das árvores neste estudo foi superior mesmo quando comparado à remoção conjunta das árvores com a superfície do solo. Possivelmente, pela superfície do solo atuar como um balanço aos altos valores que ocorrem devido a problemas de saturação dos índices, ocasionado em condições de copas mais densas (CAO et al., 2017), já que os valores do solo são representados por valores próximos ou abaixo de zero pela maioria dos índices. Portanto, retirar o solo dos ortomosaicos potencializaria o problema de saturação dos produtos com sensor RGB, comprometendo a estimativa dos parâmetros produtivos, reforçado pela grande influência do índice de solo HUE no modelo de melhor desempenho CART (Figura 9).

O MGRVI, desenvolvido por Bendig et al. (2015) a partir do NGRDI, com a premissa que a elevação ao quadrado das refletâncias usadas no processo de geração dos índices contribui

para amplificação da diferença entre estas, apresentou comportamento idêntico ao visualizado para o NGRDI. Com isso, demonstrando que, nesse experimento, não foi observada influência da elevação ao quadrado na associação com os elementos analisados, caracterizando esse processo como irrelevante nos modelos de previsão, diferente de Xu et al. (2019) onde o NGRDI foi melhor no processo de extração da vegetação de *Haloxylon ammodendron* em relação ao MGRVI. Quanto ao SCI, desenvolvido com base na variação da tonalidade do solo (MATHIEU et al., 1998), é exatamente o inverso do NGRDI e contribui unicamente para aspectos visuais que poderiam ser obtidos pela inversão dos valores finais de NGRDI ou até mesmo da escala de cores utilizada.

O desempenho preditivo em geral superior por parte do NGRDI (MF e MS) seguido pelo VARI (IAF), (Tabela 5 e Figura 9) corresponde aos diversos trabalhos da literatura que o relacionam a biomassa, como, Elazab et al. (2016) que descreveram o NGRDI como eficiente na identificação da biomassa, rendimento e de captação de pequenas diferenças no teor de clorofila da cultura do milho. Tang et al. (2021) verificaram ótima correlação do NGRDI com a biomassa de alfafa. Sapkota et al. (2020) também encontraram ótimas contribuições do VARI em seus modelos, destacando a capacidade de previsão mesmo em condições mais sombreadas. Denotando assim, a capacidade desses índices mesmo em situações mais adversas inerentes a coleta de dados do sensoriamento remoto.

Diferentemente das relações apresentadas por Alves et al. (2022) avaliando a severidade de doenças em folhas, sob condições controladas na obtenção de imagens, poucos índices demonstraram alta relação com os parâmetros ajustados, demonstrando que a influência das condições ambientais e físicas, impostas durante as tomadas de imagens, seja por questões meteorológicas, inclinação do sol, ou mesmo pela complexidade do campo de produção. De toda forma, a relação satisfatória apresentada pelo NGRDI e VARI pode estar relacionada com maior foco, das suas devidas fórmulas, nas bandas do vermelho e verde, pois apresentam maior taxa de rendimento quântico e maior taxa de reflexão, respectivamente (HOGEWONING et al., 2012; KUME, 2017; ZHEN; VAN IERSEL, 2017).

Para os modelos de regressão linear, com modelo com maior facilidade de reprodução, e os demais modelos gerados, embora tenham apresentado desempenho inferior ao CART ainda podem ser utilizados. Segundo Rotz et al. (2019), mesmo em condições que a precisão e exatidão não sejam obtidas de forma elevada, a recomendação dos métodos ainda pode ser mantida, devidos os gastos, as medições demoradas e destrutivas e a experiência do produtor na sua área.

Os modelos desenvolvidos apresentaram desempenho preditivo satisfatório com valores consideravelmente altos de exatidão e precisão, visto os diversos fatores que exercem influência sobre o processo de estimativa, como: as condições ambientais, complexidade da vegetação, equipamentos e qualidade do levantamento dos dados (COLAÇO et al., 2020). O melhor desempenho do método CART, conforme os valores calculados de CCC (0,94) e de  $R^2$  (0,89), deve-se a fatores como a capacidade de aproveitamento de informações por meio do aprendizado, ser robusto a *outliers*, não paramétrico e, principalmente, ser menos sensível aos dados de aprendizagem (CHOUBIN et al., 2018).

## 6 CONCLUSÃO

Recomenda-se a utilização dos modelos baseados em árvores de regressão impulsionadas (CART) como uma alternativa para construção de modelos preditores para parâmetros produtivos de capim corrente e capim buffel em sistemas agroflorestais no bioma Caatinga.

Em virtude da facilidade de reprodução, principalmente os índices NGRDI e VARI, a utilização de modelos baseados em regressão linear também é uma alternativa viável para estimar índices produtivos de capim corrente e capim buffel na Caatinga.

A remoção de árvores dos ortomosaicos é um importante processo na predição de parâmetros produtivos do capim corrente e do capim buffel em sistemas agroflorestais no bioma Caatinga.

## REFERÊNCIAS

- ABBAS, M.; ABDEL-LATTIF, H.; SHAHBA, M. Ameliorative effects of calcium sprays on yield and grain nutritional composition of maize (*Zea mays* L.) cultivars under drought stress. **Agriculture**, v. 11, n. 4, p. 1–13, 2021.
- ALABI, T. R. et al. Estimation of soybean grain yield from multispectral high-resolution UAV data with machine learning models in West Africa. **Remote Sensing Applications: Society and Environment**, v. 27, p. 100782, 1 ago. 2022.
- ALAM, B. et al. Different genotypes of Dalbergia sissoo trees modified microclimate dynamics differently on understory crop cowpea (*Vigna unguiculata*) as assessed through ecophysiological and spectral traits in agroforestry system. **Agricultural and Forest Meteorology**, v. 249, p. 138–148, 15 fev. 2018.
- ALI, A. M. et al. Crop Yield Prediction Using Multi Sensors Remote Sensing (Review Article). **The Egyptian Journal of Remote Sensing and Space Science**, v. 25, n. 3, p. 711–716, 1 dez. 2022.
- ALLEN, R. G. et al. Crop evapotranspiration – guidelines for computing crop water requirements. In: FAO (Ed.). . **FAO Irrigation and Dranaige**. Roma, Itália: [s.n.]. p. 56.
- ALMEIDA, C. D. S. et al. Germination of creole maize and fava bean seeds under salt stress. **Revista Caatinga**, v. 33, n. 3, p. 853–859, 2020.
- ALVARES, C. A. et al. Köppen’s climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- ALVES, K. S. et al. RGB-based phenotyping of foliar disease severity under controlled conditions. **Tropical Plant Pathology**, v. 47, n. 1, p. 105–117, 1 fev. 2022.
- ANDRADE, T. G. et al. Soybean yield prediction using remote sensing in southwestern Piauí state, Brazil. **Revista Caatinga**, v. 35, n. 1, p. 105–116, 14 fev. 2022.
- ANDRI ET MULT. AL., S. **DescTools: Tools for Descriptive Statistics**, 2022. Disponível em: <<https://cran.r-project.org/package=DescTools>>
- ANGELOTTI, F. et al. Cowpea development under different temperatures and carbon dioxide concentrations. **Pesquisa Agropecuaria Tropical**, v. 50, p. 1–7, 2020.
- ARANTES, B. H. et al. DRONE APLICADO NA AGRICULTURA DIGITAL. **Ipê Agronomic Journal**, v. 3, n. 1, p. 14–18, 3 jun. 2019.
- ARENAS-CORRALIZA, M. G. et al. Phenological, morphological and physiological drivers of cereal grain yield in Mediterranean agroforestry systems. **Agriculture, Ecosystems &**

**Environment**, v. 340, p. 108158, 1 dez. 2022.

AZADBAKHT, M. et al. Alfalfa yield estimation based on time series of Landsat 8 and PROBA-V images: An investigation of machine learning techniques and spectral-temporal features. **Remote Sensing Applications: Society and Environment**, v. 25, p. 100657, 1 jan. 2022.

BADO, B. V.; WHITBREAD, A.; MANZO, M. L. S. Improving agricultural productivity using agroforestry systems: Performance of millet, cowpea, and ziziphus-based cropping systems in West Africa Sahel. **Agriculture, Ecosystems & Environment**, v. 305, p. 107175, 1 jan. 2021.

BARBOSA, I. J. et al. Revista Brasileira de Engenharia Agrícola e Ambiental Mulch with sugarcane bagasse and bamboo straw attenuates salt stress in cowpea cultivation 1 Cobertura morta com bagaço de cana e palha de bambu atenua o estresse salino no cultivo do feijão-caupi. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 25, n. 7, p. 485–491, 2021.

BAWA, A. et al. A support vector machine and image processing based approach for counting open cotton bolls and estimating lint yield from UAV imagery. **Smart Agricultural Technology**, v. 3, p. 100140, 1 fev. 2023.

BENDIG, J. et al. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79–87, 1 jul. 2015.

BENIAICH, A. et al. UAV-based vegetation monitoring for assessing the impact of soil loss in olive orchards in Brazil. **Geoderma Regional**, v. 30, p. e00543, 1 set. 2022.

BRUNO, L. R. G. P. et al. Buffel grass morphoagronomic characterization from *cenchrus* germplasm active bank. **Revista Caatinga**, v. 30, n. 2, p. 487–495, 2017.

BURSON, B. L. et al. Genetic Diversity among Pentaploid Buffelgrass Accessions. **Crop Science**, v. 55, n. 4, p. 1637–1645, 1 jul. 2015.

CAO, Z. et al. A new three-band spectral index for mitigating the saturation in the estimation of leaf area index in wheat. <http://dx.doi.org/10.1080/01431161.2017.1306141>, v. 38, n. 13, p. 3865–3885, 3 jul. 2017.

CARNEIRO, F. M. et al. Comparison between vegetation indices for detecting spatial and temporal variabilities in soybean crop using canopy sensors. **Precision Agriculture**, v. 21, n. 5, p. 979–1007, 1 out. 2020.

CARSAN, S. et al. Can agroforestry option values improve the functioning of drivers of

agricultural intensification in Africa? **Current Opinion in Environmental Sustainability**, v. 6, n. 1, p. 35–40, 2014.

CARVALHO, W. F. et al. Effect of concentrate supplement to ewes on nutritive value of ingested Caatinga native forage nutritive value as affected by season. **Tropical Animal Health and Production**, v. 53, n. 6, p. 1–16, 1 dez. 2021.

CASTRO, R. Remote monitoring of coffee cultivation through computational processing of satellite images. **Proceedings - 2019 7th International Engineering, Sciences and Technology Conference, IESTEC 2019**, p. 13–18, 1 out. 2019.

CHOUBIN, B. et al. Precipitation forecasting using classification and regression trees (CART) model: a comparative study of different approaches. **Environmental Earth Sciences**, v. 77, n. 8, p. 1–13, 1 abr. 2018.

CIOFFI, R. et al. Artificial Intelligence and Machine Learning Applications in Smart Production: Progress, Trends, and Directions. **Sustainability 2020, Vol. 12, Page 492**, v. 12, n. 2, p. 492, 8 jan. 2020.

COÊLHO, J. J. et al. Exotic forage grasses in the Brazilian semi-arid region: Forage mass, competitiveness, and botanical similarities of non-native pastures. **Journal of Arid Environments**, v. 193, p. 104551, 1 out. 2021.

COLAÇO, A. F. et al. Yield mapping methods for manually harvested crops. **Computers and Electronics in Agriculture**, v. 177, p. 105693, 1 out. 2020.

COSENZA, D. N. et al. Silvicultural experiment assessment using lidar data collected from an unmanned aerial vehicle. **Forest Ecology and Management**, v. 522, p. 120489, 15 out. 2022.

COSTA, H. H. A. et al. Efeito da suplementação com sulfato de zinco ou propilenoglicol em ovinos em uma pastagem nativa da Caatinga no período chuvoso: desempenho, características da carcaça e da carne. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v. 70, n. 3, p. 993–1003, 1 maio 2018.

COSTA, L.; NUNES, L.; AMPATZIDIS, Y. A new visible band index (vNDVI) for estimating NDVI values on RGB images utilizing genetic algorithms. **Computers and Electronics in Agriculture**, v. 172, p. 105334, 1 maio 2020.

DIMAGGIO, A. M. et al. A Pilot Study to Estimate Forage Mass from Unmanned Aerial Vehicles in a Semi-Arid Rangeland. **Remote Sensing 2020**, v. 12, n. 15, p. 2431, 29 jul. 2020.

DÖPKE, J.; FRITSCH, U.; PIERDZIOCH, C. Predicting recessions with boosted regression

- trees. **International Journal of Forecasting**, v. 33, n. 4, p. 745–759, 1 out. 2017.
- DURMUŞ, Y.; ATASOY, A. F. Application of multivariate machine learning methods to investigate organic compound content of different pepper spices. **Food Bioscience**, v. 51, p. 102216, 1 fev. 2023.
- ELAZAB, A. et al. Detecting interactive effects of N fertilization and heat stress on maize productivity by remote sensing techniques. **European Journal of Agronomy**, v. 73, p. 11–24, 1 fev. 2016.
- ELBAKIDZE, M. et al. Perceived benefits from agroforestry landscapes across North-Eastern Europe: What matters and for whom? **Landscape and Urban Planning**, v. 209, p. 104044, 2021.
- ESCADAFAL, R.; BELGHIT, R.; BEN-MOUSSA, A. Indices spectraux pour la télédétection de la dégradation des milieux naturels en Tunisie aride. **Proceedings of the 6th International Symposium on Physical Measurements and Signatures in Remote Sensing**, p. 17–21, 1994.
- FANG, H. et al. Seasonal variation of leaf area index (LAI) over paddy rice fields in NE China: Intercomparison of destructive sampling, LAI-2200, digital hemispherical photography (DHP), and AccuPAR methods. **Agricultural and Forest Meteorology**, v. 198, p. 126–141, 2014.
- FREITAS, R. G. et al. Estimating pasture aboveground biomass under an integrated crop-livestock system based on spectral and texture measures derived from UAV images. **Computers and Electronics in Agriculture**, v. 198, p. 107122, 1 jul. 2022.
- FRITSCH, S.; GUENTHER, F.; WRIGHT, M. N. **neuralnet: Training of Neural Networks**, 2019. Disponível em: <<https://cran.r-project.org/package=neuralnet>>
- GANEM, K. A. et al. Mapping Caatinga vegetation using optical earth observation data – Opportunities and challenges. **Revista Brasileira de Cartografia**, v. 72, p. 829–854, dez. 2020.
- GITELSON, A. A. et al. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, n. 1, p. 76–87, 1 abr. 2002.
- GIUFFRIDA, M. V. et al. Optimization of UAV-Based Imaging and Image Processing Orthomosaic and Point Cloud Approaches for Estimating Biomass in a Forage Crop. **Remote Sensing 2022, Vol. 14, Page 2396**, v. 14, n. 10, p. 2396, 17 maio 2022.
- GORI MAIA, A. et al. The economic impacts of the diffusion of agroforestry in Brazil. **Land Use Policy**, v. 108, p. 105489, 2021.

- GRAEVE, M. DE et al. Multivariate versus machine learning-based classification of rapid evaporative Ionisation mass spectrometry spectra towards industry based large-scale fish speciation. **Food Chemistry**, v. 404, p. 134632, 15 mar. 2023.
- GREENWELL, B. et al. **gbm: Generalized Boosted Regression Models**, 2022. Disponível em: <<https://cran.r-project.org/package=gbm>>
- GUE, I. H. V. et al. Artificial neural networks for sustainable development: a critical review. **Clean Technologies and Environmental Policy**, v. 22, n. 7, p. 1449–1465, 1 set. 2020.
- HASHIMOTO, J. M.; SCHMIELE, M.; NABESHIMA, E. H. Pasting properties of raw and extruded cowpea cotyledons flours. **Brazilian Journal of Food Technology**, v. 23, p. 1–11, 2020.
- HASHIMOTO, J. M.; SCHMIELE, M.; NABESHIMA, E. H. Modelling to obtain expanded cowpea products in a twin screw extruder. **Brazilian Journal of Food Technology**, v. 24, p. 1–13, 2021.
- HASSON, U.; NASTASE, S. A.; GOLDSTEIN, A. Direct Fit to Nature: An Evolutionary Perspective on Biological and Artificial Neural Networks. **Neuron**, v. 105, n. 3, p. 416–434, 5 fev. 2020.
- HIJMANS, R. J. **raster: Geographic Data Analysis and Modeling**, 2022. Disponível em: <<https://cran.r-project.org/package=raster>>
- HOGEWONING, S. W. et al. Photosynthetic Quantum Yield Dynamics: From Photosystems to Leaves. **The Plant Cell**, v. 24, n. 5, p. 1921–1935, 26 jun. 2012.
- JAMALI, M. et al. Wheat leaf traits monitoring based on machine learning algorithms and high-resolution satellite imagery. **Ecological Informatics**, v. 74, p. 101967, 1 maio 2023.
- JEÍNEK, Z. et al. Winter wheat, winter rape and poppy crop growth evaluation with the help of remote and proximal sensing measurements. **Agronomy Research**, v. 18, n. 3, p. 2049–2059, 2020.
- JHA, S.; KAEICHELE, H.; SIEBER, S. Factors influencing the adoption of agroforestry by smallholder farmer households in Tanzania: Case studies from Morogoro and Dodoma. **Land Use Policy**, v. 103, p. 105308, 2021.
- KARATZOGLU, A.; SMOLA, A.; HORNIK, K. **kernlab: Kernel-Based Machine Learning Lab**, 2022. Disponível em: <<https://cran.r-project.org/package=kernlab>>
- KAUSHAL, R. et al. An allometric model-based approach for estimating biomass in seven Indian bamboo species in western Himalayan foothills, India. **Scientific Reports 2022 12:1**, v. 12, n. 1, p. 1–16, 9 maio 2022.

- KEARNEY, S. P. et al. Monitoring standing herbaceous biomass and thresholds in semiarid rangelands from harmonized Landsat 8 and Sentinel-2 imagery to support within-season adaptive management. **Remote Sensing of Environment**, v. 271, p. 112907, 15 mar. 2022.
- KUHN, M. **caret: Classification and Regression Training**, 2022. Disponível em: <<https://cran.r-project.org/package=caret>>
- KUHN, M.; QUINLAN, R. **Cubist: Rule- And Instance-Based Regression Modeling**, 2022. Disponível em: <<https://cran.r-project.org/package=Cubist>>
- KUMAR, A. et al. First Report of Johnsongrass mosaic virus Infecting *Urochloa mosambicensis* in Ethiopia. **Plant Disease**, v. 102, n. 2, p. 459, 18 dez. 2017.
- KUME, A. Importance of the green color, absorption gradient, and spectral absorption of chloroplasts for the radiative energy balance of leaves. **Journal of Plant Research**, v. 130, n. 3, p. 501–514, 1 maio 2017.
- LACAPE, M. J.; WERY, J.; ANNEROSE, D. J. M. Relationships between plant and soil water status in five field-grown cotton (*Gossypium hirsutum* L.) cultivars. **Field Crops Research**, v. 57, n. 1, p. 29–43, maio 1998.
- LEITE, M. L. DE M. V. et al. Estimativa da área foliar em *Urochloa mosambicensis* por dimensões lineares. **Revista Agropecuária Técnica**, v. 38, n. 1, p. 9–17, 2017.
- LI, D. et al. Evaluation of method to model stomatal conductance and its use to assess biomass increase in poplar trees. **Agricultural Water Management**, v. 259, p. 107228, 1 jan. 2022.
- LORENZ, K.; LAL, R. Soil organic carbon sequestration in agroforestry systems. A review. **Agronomy for Sustainable Development**, v. 34, p. 443–454, 2014.
- LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. <http://dx.doi.org/10.1080/10106040108542184>, v. 16, n. 1, p. 65–70, 2001.
- LOURENÇO, P. et al. Estimating tree aboveground biomass using multispectral satellite-based data in Mediterranean agroforestry system using random forest algorithm. **Remote Sensing Applications: Society and Environment**, v. 23, p. 100560, 1 ago. 2021.
- MAGALHÃES, C. A. S. et al. Improvement of thermal comfort indices in agroforestry systems in the southern Brazilian Amazon. **Journal of Thermal Biology**, v. 91, p. 102636, 1 jul. 2020.
- MARTIN, T. G. et al. Buffel grass and climate change: a framework for projecting invasive species distributions when data are scarce. **Biological Invasions**, v. 17, n. 11, p. 3197–3210,

29 nov. 2015.

MARTINEZ, J. L. et al. Comparison of Satellite and Drone-Based Images at Two Spatial Scales to Evaluate Vegetation Regeneration after Post-Fire Treatments in a Mediterranean Forest. **Applied Sciences** **2021**, Vol. **11**, Page **5423**, v. 11, n. 12, p. 5423, 10 jun. 2021.

MARTINS, J. C. R. et al. Nitrogen symbiotically fixed by cowpea and gliricidia in traditional and agroforestry systems under semiarid conditions. **Pesquisa Agropecuaria Brasileira**, v. 50, n. 2, p. 178–184, 2015.

MATHIEU, R. et al. Relationships between Satellite-Based Radiometric Indices Simulated Using Laboratory Reflectance Data and Typic Soil Color of an Arid Environment. **Remote Sensing of Environment**, v. 66, n. 1, p. 17–28, 1 out. 1998.

MATIAS, F. I.; CARAZA-HARTER, M. V; ENDELMAN, J. B. **{FIELDimageR}: An {R} package to analyze orthomosaic images from agricultural field trials**, 2020. Disponível em: <<https://doi.org/10.1002/ppj2.20005>>

MORADI, E. et al. Vegetation vulnerability to hydrometeorological stresses in water-scarce areas using machine learning and remote sensing techniques. **Ecological Informatics**, v. 73, p. 101838, 1 mar. 2023.

MOUSAVIZADEGAN, M. et al. Smartphone image analysis-based fluorescence detection of tetracycline using machine learning. **Food Chemistry**, v. 403, p. 134364, 1 mar. 2023.

NARDINI, C. et al. Growth and solar radiation use efficiency of corn cultivated in agroforestry systems. **Emirates Journal of Food and Agriculture**, v. 31, n. 7, p. 535–543, 27 ago. 2019.

NDLOVU, N. P.; BORRASS, L. Promises and potentials do not grow trees and crops. A review of institutional and policy research in agroforestry for the Southern African region. **Land Use Policy**, v. 103, p. 105298, 2021.

NGUYEN, M. P. et al. Adoption of Agroforestry in Northwest Viet Nam : What Roles Do Social and Cultural Norms Play ? **Forests**, v. 12, n. 4, p. 493, 2021.

OLIVEIRA, V. R. et al. Growth of arboreal leguminous plants and maize yield in agroforestry systems. **Revista Arvore**, v. 40, n. 4, p. 679–688, jul. 2016.

OPENDRONEMAP. **WebODM**, 2022. Disponível em:

<<https://github.com/OpenDroneMap/WebODM>>

OSMAN, A. N. et al. Performance of cowpea (*Vigna unguiculata*) and pearl millet (*Pennisetum glaucum*) intercropped under *Parkia biglobosa* in an agroforestry system in Burkina Faso. **African Journal of Agricultural Research**, v. 6, n. 4, p. 882–891, 2011.

- OSUNA-CEJA, E. S. A rainfed agroforestry system for the semi-arid Altiplano of Mexico. **Revista Mexicana de Ciencias Agrícolas**, n. 22, p. 89–103, 2019.
- PACIULLO, D. S. C. et al. Performance of dairy heifers in a silvopastoral system. **Livestock Science**, v. 141, n. 2–3, p. 166–172, 1 nov. 2011.
- PEREZ-MARIN, A. M.; MENEZES, R. S. C. Nutrient cycling through rainfall, throughfall and stemflow in an agroforestry system with *Gliricidia sepium* in semi-arid Paraiba, Brazil. **Revista Brasileira de Ciencia do Solo**, v. 32, n. 6, p. 2573–2579, 2009.
- PINHEIRO, F. M.; NAIR, P. K. R. Silvopasture in the caatinga biome of Brazil: A review of its ecology, management, and development opportunities. **Forest Systems**, v. 27, n. 1, p. 1–16, 2018.
- POSSOCH, M. et al. Multi-temporal crop surface models combined with the RGB vegetation index from UAV-based images for forage monitoring in grassland. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 41, p. 991–998, 6 jun. 2016.
- POUDYAL, C. et al. Sugarcane yield prediction and genotype selection using unmanned aerial vehicle-based hyperspectral imaging and machine learning. **Agronomy Journal**, v. 114, n. 4, p. 2320–2333, 2022.
- POURGHASEMI, H. R.; RAHMATI, O. Prediction of the landslide susceptibility: Which algorithm, which precision? **CATENA**, v. 162, p. 177–192, 1 mar. 2018.
- QGIS DEVELOPMENT TEAM. **QGIS Geographic Information System**, 2022. Disponível em: <<https://www.qgis.org>>
- QUANDT, A. Contribution of agroforestry trees for climate change adaptation: narratives from smallholder farmers in Isiolo, Kenya. **Agroforestry Systems**, v. 94, n. 6, p. 2125–2136, 2020.
- QUEIROZ, M. G. DE et al. Spatial and temporal dynamics of soil moisture for surfaces with a change in land use in the semi-arid region of Brazil. **Catena**, v. 188, p. 104457, maio 2020.
- QUEIROZ, M. G. et al. Composition of caatinga species under anthropic disturbance and its correlation with rainfall partitioning. **Floresta e Ambiente**, v. 28, n. 1, jul. 2021.
- R CORE TEAM. **R: A Language and Environment for Statistical Computing** Vienna, Austria, 2022. Disponível em: <<https://www.r-project.org/>>
- RAISSE, E. R. et al. Chemical desiccants for anticipation of harvest and physiological quality of cowpea seeds. **Revista Caatinga**, v. 33, n. 4, p. 878–887, 2020.
- RAVHUHALI, K. E. et al. A comparative analysis of the morphology and nutritive value of

five South African native grass species grown under controlled conditions. **African Journal of Range & Forage Science**, v. 36, n. 1, p. 67–70, 2 jan. 2019.

RAZA, A. et al. Modeling approaches to assess soil erosion by water at the field scale with special emphasis on heterogeneity of soils and crops. **Land**, v. 10, n. 4, p. 422, 2021.

RIBEIRO, J. M. et al. Fertilidade do solo e estoques de carbono e nitrogênio sob sistemas agroflorestais no Cerrado Mineiro. **Ciência Florestal**, v. 29, n. 2, p. 913–923, 2019.

RICHARDSON, A. J.; WEIGAND, C. L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, v. 43, n. 12, p. 1541–1552, dez. 1977.

ROSA, F. L. DA et al. Dosis y épocas de aplicación de nitrógeno vía foliar en la producción de maíz para ensilado en la Amazonia Meridional. **Revista De La Facultad De Agronomía De La Universidad Del Zulia**, v. 38, n. 2, p. 241–260, 2021.

ROSSELLO, N. B. et al. Information-Driven Path Planning for UAV With Limited Autonomy in Large-Scale Field Monitoring. **IEEE Transactions on Automation Science and Engineering**, 1 jul. 2021.

ROTZ, S. et al. The Politics of Digital Agricultural Technologies: A Preliminary Review. **Sociologia Ruralis**, v. 59, n. 2, p. 203–229, 1 abr. 2019.

SACRAMENTO, J. A. A. S. DO et al. Soil carbon and nitrogen stocks in traditional agricultural and agroforestry systems in the semiarid region of Brazil. **Revista Brasileira de Ciência do Solo**, v. 37, n. 3, p. 784–795, jun. 2013.

SAPKOTA, B. et al. Detection of Italian Ryegrass in Wheat and Prediction of Competitive Interactions Using Remote-Sensing and Machine-Learning Techniques. **Remote Sensing 2020, Vol. 12, Page 2977**, v. 12, n. 18, p. 2977, 13 set. 2020.

SARKER, I. H. et al. Cybersecurity data science: an overview from machine learning perspective. **Journal of Big Data**, v. 7, n. 1, p. 1–29, 1 dez. 2020.

SCHÖBER, P.; SCHWARTE, L. A. Correlation coefficients: Appropriate use and interpretation. **Anesthesia and Analgesia**, v. 126, n. 5, p. 1763–1768, 1 maio 2018.

SCHROTH, G. et al. Plant-soil interactions in multistrata agroforestry in the humid tropics. **Agroforestry Systems**, v. 53, n. 2, p. 85–102, 2001.

SERVIA, H. et al. Operational framework to predict field level crop biomass using remote sensing and data driven models. **International Journal of Applied Earth Observation and Geoinformation**, v. 108, p. 102725, 1 abr. 2022.

SHARMA, P. et al. Geospatial technology in agroforestry: status, prospects, and constraints.

- Environmental Science and Pollution Research** 2022, v. 1, p. 1–29, 21 abr. 2022.
- SHI, H. et al. Explainable machine learning model for predicting the occurrence of postoperative malnutrition in children with congenital heart disease. **Clinical Nutrition**, v. 41, n. 1, p. 202–210, 1 jan. 2022.
- SHI, S.; HAN, P. Estimating the soil carbon sequestration potential of China's Grain for Green Project. **Global Biogeochem Cycles**, v. 28, n. 11, p. 1279–1294, 2014.
- SILVA, J. L. B. DA et al. Changes in the water resources, soil use and spatial dynamics of Caatinga vegetation cover over semiarid region of the Brazilian Northeast. **Remote Sensing Applications: Society and Environment**, v. 20, p. 100372, 1 nov. 2020.
- SOUZA, L. S. B. DE et al. Water requirement and crop coefficient of maize and cowpea in sole and intercropping systems. **Revista Caatinga**, v. 28, n. 4, p. 151–160, 2015.
- SUÁREZ, L. R. et al. Cacao agroforestry systems improve soil fertility: Comparison of soil properties between forest, cacao agroforestry systems, and pasture in the Colombian Amazon. **Agriculture, Ecosystems & Environment**, v. 314, p. 107349, 1 jul. 2021.
- SWAYZE, N. C. et al. Influence of UAS Flight Altitude and Speed on Aboveground Biomass Prediction. **Remote Sensing**, v. 14, n. 9, p. 1989, 1 maio 2022.
- TADESSE, S. et al. Crop productivity and tree growth in intercropped agroforestry systems in semi-arid and sub-humid regions of Ethiopia. **Agroforestry Systems**, v. 95, n. 3, p. 487–498, 2021.
- TAJIK, S.; AYOUBI, S.; ZERAATPISHEH, M. Digital mapping of soil organic carbon using ensemble learning model in Mollisols of Hyrcanian forests, northern Iran. **Geoderma Regional**, v. 20, p. e00256, 1 mar. 2020.
- TANG, Z. et al. Validation of UAV-based alfalfa biomass predictability using photogrammetry with fully automatic plot segmentation. **Scientific Reports** 2021 11:1, v. 11, n. 1, p. 1–13, 8 fev. 2021.
- THERNEAU, T.; ATKINSON, B. **rpart: Recursive Partitioning and Regression Trees**, 2022. Disponível em: <<https://cran.r-project.org/package=rpart>>
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**, v. 8, n. 2, p. 127–150, 1 maio 1979.
- VALDERRAMA-LANDEROS, L. et al. Extrapolating canopy phenology information using Sentinel-2 data and the Google Earth Engine platform to identify the optimal dates for remotely sensed image acquisition of semiarid mangroves. **Journal of Environmental Management**, v. 279, p. 111617, 1 fev. 2021.

- VIERA, M.; SCHUMACHER, M. V. Biomass in monospecific and mixed stands of eucalyptus and black wattle and corn in an agroforestry system. **Cerne**, v. 17, n. 2, p. 259–265, 2011.
- VILLARREYNA, R.; AVELINO, J.; CERDA, R. Ecosystem-based adaptation: Effect of shade trees on ecosystem services in coffee plantations. **Agronomy Mesoamerican**, v. 31, n. 2, p. 499–516, 2020.
- WANG, Y.; SHI, W.; WEN, T. Prediction of winter wheat yield and dry matter in North China Plain using machine learning algorithms for optimal water and nitrogen application. **Agricultural Water Management**, v. 277, p. 108140, 1 mar. 2023.
- WENGERT, M. et al. Assessing Spatial Variability of Barley Whole Crop Biomass Yield and Leaf Area Index in Silvoarable Agroforestry Systems Using UAV-Borne Remote Sensing. **Remote Sensing 2021, Vol. 13, Page 2751**, v. 13, n. 14, p. 2751, 13 jul. 2021.
- WINTER, J. C. F.; GOSLING, S. D.; POTTER, J. Comparing the pearson and spearman correlation coefficients across distributions and sample sizes: A tutorial using simulations and empirical data. **Psychological Methods**, v. 21, n. 3, p. 273–290, 1 set. 2016.
- WITT, T. W. et al. Response to deficit irrigation of morphological, yield and fiber quality traits of upland (*Gossypium hirsutum* L.) and Pima (*G. barbadense* L.) cotton in the Texas High Plains. **Field Crops Research**, v. 249, p. 107759, abr. 2020.
- XU, J. et al. Spatial pattern analysis of *Haloxylon ammodendron* using UAV imagery - A case study in the Gurbantunggut Desert. **International Journal of Applied Earth Observation and Geoinformation**, v. 83, p. 101891, 1 nov. 2019.
- XU, M. et al. The effect of tillage management on microbial functions in a maize crop at different slope positions. **Geoderma**, v. 401, 2021.
- XUE, J.; SU, B. Significant remote sensing vegetation indices: A review of developments and applications. **Journal of Sensors**, v. 2017, 2017.
- ZARCO-TEJADA, P. J. et al. Assessing vineyard condition with hyperspectral indices: Leaf and canopy reflectance simulation in a row-structured discontinuous canopy. **Remote Sensing of Environment**, v. 99, n. 3, p. 271–287, 30 nov. 2005.
- ZHEN, S.; VAN IERSEL, M. W. Far-red light is needed for efficient photochemistry and photosynthesis. **Journal of Plant Physiology**, v. 209, p. 115–122, 1 fev. 2017.
- ZUFFO, A. M. et al. Análise de crescimento e características agronômicas do milho safrinha em sucessão com soja e submetido a doses de nitrogênio. **Revista em Agronegocio e Meio Ambiente**, v. 14, n. 1, p. 73–83, 2021.