



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
UNIDADE ACADÊMICA DE SERRA TALHADA
CURSO DE BACHARELADO AGRONOMIA

EDICLEIFE LINO DOS SANTOS

**USO DE SENSOR MULTIESPECTRAL EMBARCADO EM VANT PARA A
ESTIMATIVA DE CLOROFILA E NITROGÊNIO NA CULTURA DO CAPIAÇU**

SERRA TALHADA-PE
2026

EDICLEIFE LINO DOS SANTOS

**USO DE SENSOR MULTIESPECTRAL EMBARCADO EM VANT PARA A
ESTIMATIVA DE CLOROFILA E NITROGÊNIO, NA CULTURA DO CAPIAÇU**

Trabalho de Conclusão de Curso
apresentado ao Curso de Bacharelado em
Agronomia da Universidade Federal Rural
de Pernambuco, como requisito parcial
para obtenção do título de Engenheiro
Agrônomo

Orientador (a): Alan Cezar Bezerra

SERRA TALHADA-PE

2026

Dados Internacionais de Catalogação na Publicação
Sistema Integrado de Bibliotecas da UFRPE
Bibliotecário(a): Danilo Trindade Barbosa – CRB-4 002285/O

S237u Santos, Edicleife Lino dos.

Uso de sensor multiespectral embarcado em vant para a estimativa de clorofila e nitrogênio na cultura do capiaçu / Edicleife Lino dos Santos. – Serra Talhada, 2026.
49 f.; il.

Orientador(a): Alan Cezar Bezerra.

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal Rural de Pernambuco, Unidade Acadêmica Serra Talhada - UAST, Bacharelado em Agronomia, Serra Talhada, BR-PE, 2026.

Inclui referências.

1. Agricultura de precisão. 2. Sensoriamento remoto. 3. Capim-elefante. 4. Clorofila 5. Nitrogênio. I. Bezerra, Alan Cezar, orient. II. Título

CDD 630

EDICLEIFE LINO DOS SANTOS

**USO DE SENSOR MULTIESPECTRAL EMBARCADO EM VANT PARA A
ESTIMATIVA DE CLOROFILA E NITROGÊNIO NA CULTURA DO CAPIAÇU**

Trabalho de Conclusão de Curso
apresentado ao Curso de Bacharelado em
Agronomia da Universidade Federal Rural
de Pernambuco, como requisito parcial
para obtenção do título de Engenheiro
Agrônomo

Aprovado em: 17/07/2026

BANCA EXAMINADORA

Prof. Dr. Alan César Bezerra
Universidade Federal Rural de Pernambuco

Msc. Wagner Martins dos Santos
Universidade Federal Rural de Pernambuco

Msc. Kátia Elisabete Silva Ribeiro
Universidade Federal Rural de Pernambuco

Dedico a minha mãe que sempre me apoia e cuida de mim desde sempre. Sua história de vida me inspira e me motiva a seguir em frente.

AGRADECIMENTOS

Começo agradecendo a minha família, em especial a minha mãe Quitéria (dona Quitéria), a quem tenho todo amor e admiração. Quem apesar de tudo sempre fez de tudo para que eu estivesse bem, não foram anos fáceis, mas desistir nunca foi uma opção para mim. Tudo que deixei de viver com minha família por conta do curso valerá muito a pena, devo isso a mim mesmo. Cito também meu pai Cleodon (Creó), que em algumas de poucas conversas comentou a admiração que tem pela área da agronomia, creio que foi a forma dele demonstrar algo por mim.

Agradeço aos meus irmãos, inclusive saudade de todos, por de alguma forma me “quebraram” um galho. Flávio e Maria Aparecida (Melha) que me levaram ou buscaram tantas vezes do sítio até o carro ou até a cidade. Além deles, meus primos Mayane, Hugo, Murilo e meu cunhado Rael já fizeram essa jornada. Agradeço a meu irmão Heleno por ter me dado meu notebook, contribuiu muito para meus estudos. Não tive a oportunidade de agradecer da forma como se deveria, mas fica aqui o registro. Além disso, outras pessoas contribuíram para que eu seguisse em frente, minha irmã Juliana sempre solícita, fez parte de momentos muito importantes na minha vida. Agradeço também a Beatrys (cunhada) entrou para a família a pouco tempo mas é como se sempre tivesse feito parte.

Agradeço a Jaison que acabou se tornando um dos principais motivadores na vida, devo a graduação a ele, que sabe da culpa dele por eu estar aqui hoje. Jamais seria tão ingrato a não agradecer por tudo que o mesmo contribuiu em meu desenvolvimento como pessoa.

Agradeço aos meus amigos da graduação: David Matias que esteve comigo sempre, e um se apoiava no outro para poder seguir em frente, obrigado amigo. Também não posso deixar de falar sobre Débora, amiga parceira das vivências na universidade e fora dela, admiro muito. Também compõem nosso grupo: Nátaly, Gislane, Vitor e Márcia. Vocês foram muito importantes nessa jornada. Outros que também merecem: Davi, Bruna, Rodrigo, Cleiton, Laura, Paulo, Antônio, entre outros.

Agradeço enormemente ao meu orientador Alan, estivemos praticamente toda a graduação trabalhando juntos, aprendi muito, foi gratificante, não me arrependo de ter sido orientando dele, não me vejo hoje trabalhando em outra área na graduação que não fosse com ele.

Obrigado a todos que depositaram a sua confiança em mim, acreditaram em mim quando nem eu mesmo acreditava. Agradeço a Deus por ter colocado todos vocês em meu caminho.

RESUMO

A cultura do capim BRS Capião apresenta elevada importância para a produção de forragem, demandando ferramentas que permitam monitorar seu estado nutricional de forma rápida e não destrutiva. Nesse contexto, o presente trabalho teve como objetivo investigar a capacidade de um sensor multiespectral embarcado em veículo aéreo não tripulado para estimar os teores de clorofila e nitrogênio na cultura do capim. O experimento foi conduzido na Universidade Federal Rural de Pernambuco, Unidade Acadêmica de Serra Talhada, utilizando imagens adquiridas por drone equipado com bandas verde, vermelha, borda do vermelho e infravermelho próximo. A partir dessas imagens foram calculados os índices de vegetação NDVI, NDRE, GNDVI, CI Red Edge e MTCI, os quais foram comparados aos teores de clorofila determinados pelo método de Lichtenthaler e ao nitrogênio total obtido pelo método de Kjeldahl. A análise dos dados foi realizada por meio de estatística descritiva e regressão linear simples. Os resultados evidenciaram variações temporais nos teores de clorofila, nitrogênio e índices de vegetação ao longo dos períodos avaliados. Entretanto, as regressões entre as bandas espectrais, os índices de vegetação e as variáveis laboratoriais apresentaram baixos coeficientes de determinação, indicando reduzida capacidade preditiva para estimar os teores de clorofila e nitrogênio na cultura. Conclui-se que, nas condições experimentais avaliadas, o sensoriamento remoto com sensor multiespectral embarcado em veículo aéreo não tripulado não foi suficiente para prever, com precisão, os parâmetros analisados, evidenciando a necessidade de aperfeiçoamentos metodológicos e de novos estudos para ampliar a confiabilidade dessa tecnologia no monitoramento nutricional do capim em condições de semiárido.

Palavras-chave: agricultura de precisão; sensoriamento remoto; veículo aéreo não tripulado; clorofila; nitrogênio; capim BRS Capião.

ABSTRACT

BRS Capiáu grass is an important forage crop, requiring tools that enable rapid and non-destructive monitoring of its nutritional status. In this context, the present study aimed to investigate the ability of a multispectral sensor mounted on an unmanned aerial vehicle (UAV) to estimate chlorophyll and nitrogen contents in BRS Capiáu grass. The experiment was conducted at the Academic Unit of Serra Talhada of the Federal Rural University of Pernambuco, Brazil, using images acquired by a UAV equipped with green, red, red-edge, and near-infrared spectral bands. Based on these images, the vegetation indices NDVI, NDRE, GNDVI, CI Red Edge, and MTCI were calculated and compared with chlorophyll contents determined by the Lichtenthaler method and total nitrogen determined by the Kjeldahl method. Data analysis was performed using descriptive statistics and simple linear regression. The results revealed temporal variations in chlorophyll, nitrogen, and vegetation indices throughout the evaluated periods. However, the regressions between the spectral bands, vegetation indices, and laboratory measurements showed low coefficients of determination, indicating limited predictive ability for estimating chlorophyll and nitrogen contents in the crop. It is concluded that, under the experimental conditions evaluated, remote sensing using a UAV-mounted multispectral sensor was not sufficient to accurately predict the analyzed parameters, highlighting the need for methodological improvements and further studies to increase the reliability of this technology for nutritional monitoring of BRS Capiáu grass under semiarid conditions.

Keywords: precision agriculture; remote sensing; unmanned aerial vehicle (UAV); chlorophyll; nitrogen; BRS Capiáu grass.

LISTA DE ILUSTRAÇÕES

Figura 1 - BRS Capiacu: cultivar de alto rendimento para produção de silagem de baixo custo.....	15
Figura 2 - Mapa de localização da área de estudo.....	23
Figura 3 - Pontos de controle utilizados no georreferenciamento.....	24
Figura 4 - a) Criação do buffer, b) Estatística zonal.....	25
Figura 5 - Regressão linear simples entre banda e valores de clorofila.....	32
Figura 6 - Regressão linear simples entre índices e valores de clorofila.....	35
Figura 7 - Regressão linear simples entre bandas e N (%).....	39
Figura 8 - Regressão linear simples entre índices e N(%).....	40

LISTA DE TABELAS

Tabela 1 - Resumos dos índices utilizados.....	26
Tabela 2 - Estatística descritiva de clorofila total e carotenoides totais (mg/L) nas folhas.....	29
Tabela 3 - Estatística descritiva do nitrogênio (%) nas folhas.....	30
Tabela 4 - Estatística descritiva dos índices de vegetação da cobertura vegetal do capiaçu.....	30
Tabela 5 - Resumo da regressão linear simples entre as banda e valores de clorofila	31
Tabela 6 - Resumo da regressão linear simples entre os índices e valores de clorofila.....	35
Tabela 7 - Resumo da regressão linear simples entre as bandas e valores de Nitrogênio.....	39
Tabela 8 - Resumo da regressão linear simples entre os índices e valores de Nitrogênio.....	40

SUMÁRIO

1. INTRODUÇÃO	12
2. OBJETIVOS	14
2.1. Objetivo Geral	14
2.2. Objetivos Específicos	14
3. REFERENCIAL TEÓRICO	14
3.1. Cultura do Capiáçu	14
3.2. Clorofila e Estado Nutricional das Plantas	16
3.3. Nitrogênio (N)	17
3.4. Sensoriamento Remoto na Agricultura	18
3.5. Sensores multiespectrais	20
4. MATERIAL E MÉTODO	22
4.1. Caracterização da área de estudo	22
4.2. Obtenção das imagens	23
4.3. Processamento das imagens	24
4.5. Análise de clorofila	26
4.6. Determinação de nitrogênio total em tecido vegetal	27
4.6.1. <i>Preparo da amostra:</i>	27
4.6.2. <i>Preparo dos Reagentes:</i>	28
5. RESULTADOS E DISCUSSÃO	29
6. CONSIDERAÇÕES FINAIS	43
7. REFERÊNCIAS	44

1. INTRODUÇÃO

A cultura do Capiáçu (*Pennisetum purpureum* Schum. cv. BRS Capiáçu), desenvolvida pela Embrapa Gado de Leite, visa atender a demanda por cultivares para corte (picado verde) e silagem, apresentando elevado potencial de produção, bom valor nutritivo e facilidade de mecanização (Embrapa, 2021). Além de produtivo, essa variedade possui tolerância a condições de escassez hídrica e adaptabilidade a diferentes tipos de solo (PEREIRA *et al.*, 2016).

A crescente demanda por maior eficiência produtiva na agricultura tem impulsionado o uso de tecnologias que auxiliem no manejo racional dos insumos agrícolas, especialmente dos fertilizantes nitrogenados (Li *et al.*, 2024). Sendo o nitrogênio (N) um dos nutrientes mais exigidos pelas plantas, diretamente relacionado à síntese de clorofila, ao crescimento vegetativo e à produtividade das culturas (TAIZ *et al.*, 2017). Contudo, o uso inadequado desse nutriente pode ocasionar perdas econômicas e impactos ambientais significativos, como a lixiviação de nitrato e a contaminação de corpos hídricos (Cantarella, 2007).

A clorofila constitui o principal pigmento fotossintético das plantas, desempenhando um papel essencial na captação da energia luminosa e na sua conversão em energia química durante a fotossíntese. Além de sua importância na absorção e no transporte da luz, esse pigmento participa diretamente dos mecanismos bioquímicos responsáveis pela produção de compostos orgânicos necessários ao crescimento e ao desenvolvimento vegetais. Os pigmentos fotossintéticos podem ser classificados em diferentes grupos, destacando-se as clorofilas a e b, os carotenoides e as xantofilas, como a luteína. Enquanto a maior parte da clorofila a e toda a clorofila b atuam na absorção e transferência da energia luminosa, apenas uma pequena fração da clorofila a está diretamente envolvida nas reações fotoquímicas de conversão da energia (TAIZ *et al.*, 2017). Wang *et al.* (2021), afirma que a capacidade fotossintética, a clorofila e o nitrogênio são características foliares estreitamente relacionadas e determinantes para a fotossíntese e produtividade. Além disso, o teor de clorofila apresenta forte correlação com a disponibilidade de nitrogênio, uma vez que esse nutriente integra a estrutura molecular da clorofila e participa da

síntese de proteínas e enzimas essenciais ao metabolismo vegetal (POORTER; EVANS, 1998; TAKASHIMA *et al.*, 2004)

A agricultura de precisão vem ganhando espaço como importante ferramenta aliada na otimização do manejo nutricional das culturas, ao possibilitar a identificação da variabilidade espacial no campo e a aplicação localizada de insumos (MOLIN; AMARAL; COLAÇO, 2015). Entre as ferramentas utilizadas, o sensoriamento remoto destaca-se por permitir a obtenção rápida e não destrutiva de informações sobre o dossel vegetal, em diferentes escalas espaciais e temporais (Omia *et al.*, 2023).

O avanço dos veículos aéreos não tripulados (VANTs) vem generalizando o uso do sensoriamento remoto em nível de campo, proporcionando imagens de alta resolução espacial e maior flexibilidade operacional em comparação às plataformas orbitais (HUNT *et al.*, 2018). A integração de sensores embarcados em VANTs (por exemplo, RGB, multiespectrais e hiperespectrais) possibilita o monitoramento detalhado e o manejo do desenvolvimento das culturas, favorecendo a identificação de deficiências nutricionais.

Os sensores multiespectrais têm sido amplamente empregados na agricultura para a avaliação do estado fisiológico das plantas, por meio de análises da reflectância em bandas específicas do espectro eletromagnético (YANG *et al.*, 2020). A partir dessas informações obtidas, é possível calcular índices de vegetação relacionados à clorofila, que apresentam forte correlação com o teor de nitrogênio nas plantas (XIE *et al.*, 2020).

Pelo Capiáu ser uma variedade com ampla distribuição na região devido às suas características desejáveis, há a necessidade de que se desenvolvam estudos voltados ao monitoramento da cultura, pois, apesar de sua importância, ainda são escassos os estudos que avaliam o uso de ferramentas, como sensores multiespectrais embarcados em VANTs, para a estimativa de nutrientes nessa cultura, principalmente quando voltados às condições do semiárido, evidenciando uma lacuna a ser investigada.

Dessa forma, o trabalho foi desenvolvido sobre a hipótese da relação entre dados obtidos a partir do sensoriamento remoto e dados extraídos de material vegetal do Capiáu, buscando assim, o desenvolvimento de metodologias baseadas em sensores multiespectrais embarcados em VANTs

para a estimativa do teor de clorofila e nitrogênio do Capiáu, podendo contribuir para o uso mais eficiente dos fertilizantes, redução de impactos ambientais e fortalecimento da agricultura de precisão aplicada à produção de forragens, além de contribuir para o banco de dados de estudos voltados ao tema.

2. OBJETIVOS

2.1. Objetivo Geral

Investigar a estimativa de clorofila e nutrientes no capim BRS Capiáu (*Cenchrus purpureus* (Schumach.) Morrone cv. BRS Capiáu) com o uso de sensor multiespectral embarcado em VANT.

2.2. Objetivos Específicos

- Analisar o teor de clorofila e nitrogênio *in situ* no capiaçu;
- Capturar imagens das coberturas vegetais com veículo aéreo não tripulado (VANT);
- Gerar índices de vegetação relacionados a clorofila e nitrogênio;
- Investigar a correlação entre dados estimados e medidos.

3. REFERENCIAL TEÓRICO

3.1. Cultura do Capiáu

A cultivar BRS Capiáu (Figura 1) foi obtida pela Embrapa Gado de Leite pela seleção e clonagem de uma das progênies resultantes do cruzamento, realizado em 1991, entre os acessos do Banco Ativo de Germoplasma de capim-elefante - BAGCE, Guaco IZ2 (BAGCE 60) e Roxo (BAGCE 57). Esse híbrido (clone) foi avaliado em 23 locais, em todas as regiões brasileiras, ao longo de vários anos, destacando-se na maioria dos ambientes (Embrapa, 2021).

Figura 1 – BRS Capiaçú: cultivar de alto rendimento para produção de silagem de baixo custo



Foto: Antônio Vander Pereira.

Devido ao seu porte elevado e ao potencial de produção, a cultivar recebeu a denominação BRS Capiaçú (em tupi-guarani, capiaçu significa “capim grande”). A cultivar foi registrada no Ministério da Agricultura, Pecuária e Abastecimento (Mapa) sob o nº 33503 em 08/01/2015, bem como recebeu certificado de proteção de cultivares nº 20150124, em 23/01/2015. A Embrapa lançou essa cultivar em outubro de 2016.

A BRS Capiaçú caracteriza-se por apresentar plantas de porte alto (acima de 4,0 m); folhas verdes, largas (média de 5,2 cm) e compridas (média de 106 cm), com nervura central branca; ausência de joçal (pêlos) na planta adulta; colmos grossos (diâmetro médio de 1,6 cm); e internódios compridos (média de 16 cm). A cultura apresenta crescimento vegetativo vigoroso, rápida expansão foliar e intenso perfilhamento basal e axilar. As touceiras são eretas, com elevada densidade de perfilhos (média de 30 perfilhos/m²), o que confere boa resistência ao tombamento, bem como facilidade à colheita mecanizada. O florescimento é tardio e ocorre entre os meses de junho e julho, na maioria das regiões brasileiras. Outra característica favorável desta cultivar é a tolerância ao estresse hídrico moderado, o que a torna alternativa para cultivo em regiões com alto risco de ocorrência de veranicos (Embrapa, 2021).

A BRS Capiaçú pode ser cultivada em regiões de clima tropical e subtropical e é recomendada para o bioma da Mata Atlântica. A cultura não deve ser plantada em áreas com solos úmidos ou encharcados. Embora, apresente boa tolerância ao estresse hídrico, em locais sujeitos a períodos secos prolongados, o uso da irrigação garante a manutenção da produção de forragem. Devido ao seu elevado potencial de produção, a BRS Capiaçú extrai

grandes quantidades de nutrientes do solo, razão pela qual deve ser cultivada em solos profundos, bem drenados e de boa fertilidade. O uso de fertilizantes químicos e orgânicos é fundamental para alcançar alta produtividade (Embrapa, 2021).

A cultura é indicada para o cultivo de capineiras, visando à suplementação volumosa na forma de silagem ou de picado verde. Devido ao seu elevado potencial de produção, também pode ser cultivada para produção de biomassa energética (Embrapa, 2021).

3.2. Clorofila e Estado Nutricional das Plantas

A clorofila é o principal pigmento fotossintético das plantas, responsável pela absorção da radiação luminosa utilizada na conversão da energia solar em energia química durante a fotossíntese. Esse pigmento está localizado nos cloroplastos e desempenha um papel fundamental no crescimento, desenvolvimento e produtividade vegetal (TAIZ *et al.*, 2017).

Nas plantas superiores predominam dois tipos de clorofila: a clorofila a e a clorofila b. A clorofila a atua como pigmento fotossintético primário, participando diretamente das reações fotoquímicas, enquanto a clorofila b funciona como pigmento acessório, ampliando o espectro de absorção da radiação solar e transferindo a energia absorvida para a clorofila a. Apesar de apresentarem estruturas químicas semelhantes, diferem por um pequeno grupo funcional em sua molécula, o que resulta em diferenças nos comprimentos de onda absorvidos e contribui para maior eficiência da captação de luz pelas plantas (TAIZ *et al.*, 2017; RAVEN; EVERT; EICHHORN, 2014).

Métodos padrão de determinação de clorofila em laboratório, como os de Arnon (1949) e Lichtenthaler (1987), ainda que fáceis, necessitam de reagentes e equipamentos específicos com elevado custo de aquisição, além disso, os métodos apresentam desvantagens, como a coleta destrutiva do material vegetal, a extração por maceração com acetona e a leitura em espectrofotômetro. Com o advento de medidores portáteis (Yadava, 1986), a determinação de clorofila tornou-se mais fácil e rápida, podendo ser realizada diretamente em campo.

3.3. Nitrogênio (N)

O nitrogênio é um macronutriente que influencia diversos processos fisiológicos, moleculares e metabólicos das plantas, sendo determinante para o crescimento vegetal, a produtividade das culturas e a sustentabilidade ambiental (Ostria-Gallardo; Bascuñán-Godoy; Fernández Del-Saz, 2024). Embora a atmosfera seja rica em nitrogênio, a maior parte dele encontra-se na forma gasosa (N_2), o que impossibilita sua utilização direta pela maioria das plantas. Exceção feita às leguminosas, capazes de realizar a fixação biológica do nitrogênio (FBN). Como macronutriente essencial ao desenvolvimento vegetal, o nitrogênio participa de diversos processos metabólicos e está diretamente ligado à fotossíntese, à nutrição orgânica das plantas e à síntese de proteínas, enzimas, coenzimas, ácidos nucleicos e clorofila (Hashimoto *et al.*, 2024). Sua disponibilidade adequada no solo favorece a expansão foliar, resultando em maior área fotossintética e, conseqüentemente, maior capacidade produtiva das culturas (Barbosa *et al.*, 2023).

Em pastagens, o nitrogênio também é um dos elementos-chave da ciclagem de nutrientes no sistema solo-planta-animal, sendo o uso de leguminosas forrageiras consorciadas com gramíneas uma estratégia eficaz para elevar seu teor no solo e reduzir os custos com adubação nitrogenada (Nascimento *et al.* 2024).

Além disso, o nitrogênio é um elemento extremamente dinâmico, sujeito a diferentes transformações microbianas, como a nitrificação e a desnitrificação, que ocorrem quando o fertilizante nitrogenado é aplicado (DUCHEIKO *et al.*, 2025). Essas transformações também explicam por que o manejo da adubação nitrogenada é um dos fatores que mais influenciam as emissões de óxido nitroso (N_2O), um gás de efeito estufa com elevado potencial de aquecimento global, o que torna a agricultura uma das principais fontes desse gás (DUCHEIKO *et al.*, 2025; CORRÊA *et al.*, 2021). Estudos conduzidos em pastagens de clima quente mostram que a fertilização nitrogenada afeta significativamente as emissões cumulativas de N_2O e CO_2 , ainda que a fonte específica de nitrogênio utilizada (ureia, nitrato de amônio ou sulfato de amônio) nem sempre as altere de forma significativa (CORRÊA *et al.*, 2021).

3.4. Sensoriamento Remoto na Agricultura

O sensoriamento remoto consiste na obtenção de dados sobre objetos ou superfícies sem que haja contato físico direto entre o sensor e o alvo. Na agricultura, essa tecnologia utiliza sensores embarcados em satélites, aeronaves e veículos aéreos não tripulados (VANTs ou drones) para captar a radiação eletromagnética refletida ou emitida pelas plantas, pelo solo e pela atmosfera. Essas informações permitem monitorar as condições das culturas agrícolas em diferentes escalas espaciais e temporais, fornecendo assim subsídios para a tomada de decisão de forma rápida, precisa e não destrutiva (Khanal *et al.*, 2020; Queiroz *et al.*, 2020).

Os sensores utilizados no sensoriamento remoto podem ser classificados em sensores passivos e ativos. Os sensores passivos dependem da radiação solar refletida pelos alvos e incluem câmeras RGB, sensores multiespectrais e hiperespectrais, amplamente empregados na agricultura para avaliação da cobertura vegetal, do vigor das plantas e da produtividade. Já os sensores ativos, como o LiDAR e o radar de abertura sintética (SAR), emitem sua própria energia eletromagnética e apresentam a vantagem de operar mesmo sob condições de baixa luminosidade ou elevada cobertura de nuvens (Khanal *et al.*, 2020).

Além dos diferentes tipos de sensores, o sensoriamento remoto é caracterizado por quatro resoluções fundamentais: espacial, espectral, temporal e radiométrica. A resolução espacial refere-se ao tamanho mínimo do objeto detectável; a resolução espectral corresponde ao número e à largura das bandas espectrais registradas; a resolução temporal está relacionada à frequência de aquisição das imagens; enquanto a resolução radiométrica representa a capacidade do sensor em discriminar pequenas diferenças na intensidade da energia refletida (LILLESAND; KIEFER; CHIPMAN, 2015; JENSEN, 2016). A escolha adequada dessas características depende do objetivo do monitoramento agrícola e da escala de análise desejada.

O desenvolvimento da agricultura de precisão, associado aos avanços nas tecnologias de sensoriamento remoto, tem ampliado a capacidade de monitoramento e manejo das culturas agrícolas (OMIA *et al.*, 2023). Nesse

contexto, imagens provenientes de satélites como o Sentinel-2 e o Landsat, bem como de drones equipados com sensores multiespectrais, hiperespectrais e térmicos, possibilitam o monitoramento contínuo da variabilidade espacial das lavouras (Clevers e Kooistra, 2025). A partir dessas informações, torna-se possível identificar precocemente deficiências nutricionais, estresse hídrico, ocorrência de plantas daninhas, pragas e doenças, além de estimar a biomassa, o índice de área foliar, o teor de clorofila e a produtividade das culturas (Queiroz et al., 2020; Khanal et al., 2020).

Entre as ferramentas mais utilizadas, destacam-se os índices de vegetação, especialmente o NDVI (*Normalized Difference Vegetation Index*), que permite avaliar o vigor vegetativo por meio da relação entre as bandas do vermelho e do infravermelho próximo (TUCKER, 1979; XUE e SU, 2017). Outros índices, como NDRE (*Normalized Difference Red Edge*), GNDVI (*Green Normalized Difference Vegetation Index*), SAVI (*Soil-Adjusted Vegetation Index*) e EVI (*Enhanced Vegetation Index*), também são empregados para estimar a atividade fotossintética, o estado nutricional e o desenvolvimento das culturas em diferentes estádios fenológicos. Essas informações subsidiam práticas de manejo localizado, reduzindo o desperdício de insumos e aumentando a eficiência produtiva (KHANAL et al., 2020; QUEIROZ et al., 2020).

Na agricultura de precisão, o sensoriamento remoto integra-se a sistemas de informação geográfica (SIG), receptores GNSS, sensores de campo e algoritmos de inteligência artificial para apoiar a tomada de decisões em tempo real. Os dados obtidos permitem elaborar mapas de fertilidade, mapas de produtividade, mapas de infestação de plantas daninhas, mapas de estresse hídrico e mapas de aplicação em taxa variável de fertilizantes, corretivos, sementes e defensivos agrícolas (MOLIN; AMARAL; COLAÇO, 2015; GEBBERS; ADAMCHUK, 2010). Essa integração contribui para maior eficiência no uso dos recursos naturais, redução dos custos operacionais e diminuição dos impactos ambientais (Queiroz et al., 2020).

Outro aspecto importante refere-se ao uso crescente da inteligência artificial e do aprendizado de máquina associados ao sensoriamento remoto. Técnicas de aprendizado profundo têm permitido a classificação automática de culturas, a identificação precoce de doenças, a detecção de pragas e a estimativa da produtividade com níveis cada vez maiores de precisão (Liakos et

al., 2018; Dos Santos *et al.*, 2026). Modelos que combinam imagens multitemporais provenientes dos satélites Sentinel-2, Landsat e drones apresentam elevado potencial para o monitoramento agrícola contínuo e para o desenvolvimento de sistemas inteligentes de suporte à decisão (Kuunya *et al.*, 2026).

Entre as principais vantagens do sensoriamento remoto, destacam-se a rapidez na aquisição de informações, a cobertura de grandes áreas em curto período de tempo, a possibilidade de monitoramento contínuo das culturas, a redução da necessidade de amostragem destrutiva, a identificação precoce de problemas fitossanitários e nutricionais, além do apoio ao manejo localizado, característico da agricultura de precisão. Essas características proporcionam aumento da produtividade, redução de custos com insumos e maior sustentabilidade ambiental (Khanal *et al.*, 2020; Queiroz *et al.*, 2020).

Entretanto, o emprego dessa tecnologia ainda apresenta algumas limitações. A qualidade das imagens ópticas pode ser comprometida pela presença de nuvens, sombras e condições atmosféricas adversas (Jensen, 2015). Além disso, sensores de alta resolução espacial têm custos elevados, enquanto o processamento das imagens exige softwares especializados, infraestrutura computacional adequada e profissionais capacitados para a interpretação dos dados. Outro desafio consiste na integração de diferentes fontes de informação e na validação em campo dos modelos empregados, especialmente quando se recorre a técnicas de inteligência artificial (Khanal *et al.*, 2020; Kuunya *et al.*, 2026).

3.5. Sensores multiespectrais

Os sensores multiespectrais são ferramentas capazes de captar a energia eletromagnética refletida ou emitida pelos objetos da superfície terrestre em diferentes regiões específicas do espectro eletromagnético, denominadas bandas espectrais (Lillesand, Kiefer e Chipman, 2015). Diferentemente das câmeras convencionais, que registram apenas três bandas do espectro visível (vermelho, verde e azul – RGB), os sensores multiespectrais registram simultaneamente informações em bandas adicionais, como o infravermelho próximo (*Near Infrared* – NIR) e a região da borda do

vermelho (*Red Edge*), permitindo uma análise mais detalhada das características físicas, químicas e fisiológicas da vegetação (Jensen, 2016; Thenkabail et al., 2018).

O princípio de funcionamento desses sensores baseiam-se na interação da radiação eletromagnética com os alvos terrestres. A radiação solar incide sobre a superfície e, ao atingir a vegetação, parte da energia é absorvida, parte é transmitida e parte é refletida (JENSEN, 2015; LILLESAND, KIEFER E CHIPMAN, 2015). A quantidade de energia refletida varia conforme o comprimento de onda e as características biofísicas da planta, como teor de clorofila, conteúdo de água, estrutura interna das folhas e estado nutricional (Knipling, 1970). Essa resposta espectral é registrada pelo sensor em diferentes bandas, possibilitando a identificação de alterações fisiológicas que muitas vezes não são visualmente perceptíveis (LILLESAND; KIEFER; CHIPMAN, 2015; JENSEN, 2016).

Na vegetação saudável, a radiação incidente na região do vermelho (aproximadamente 620–700 nm) é intensamente absorvida pelos pigmentos fotossintéticos, principalmente a clorofila, durante o processo de fotossíntese (DRECCER et al., 2022). Em contraste, a região do infravermelho próximo (700–1300 nm) apresenta elevada reflectância devido ao intenso espalhamento da radiação na estrutura interna do mesófilo foliar, especialmente nas interfaces entre as paredes celulares e os espaços intercelulares (GATES et al., 1965; KNIPLING, 1970; PONZONI, SHIMABUKURO & KUPLICH, 2012; JONES & VAUGHAN, 2010). Já a região conhecida como *Red Edge* representa a transição entre essas duas faixas e é altamente sensível às variações na concentração de clorofila e no estado nutricional das plantas. Por essa razão, sensores que possuem bandas *Green*, *Red*, *Red Edge* e NIR são amplamente empregados em estudos voltados ao monitoramento da saúde das culturas, estimativa de biomassa, detecção de estresses bióticos e abióticos e avaliação do teor de nitrogênio e clorofila (Thenkabail et al., 2018).

O funcionamento do sensor envolve a utilização de filtros ópticos ou detectores específicos que isolam intervalos determinados do espectro eletromagnético. Cada banda registra a intensidade da radiação refletida em um comprimento de onda específico, gerando imagens independentes para cada faixa espectral (Schowengerdt, 2007). Posteriormente, essas imagens

podem ser processadas individualmente ou combinadas matematicamente para gerar índices espectrais, como o Índice de Vegetação por Diferença Normalizada (NDVI), o Índice de Vegetação por Diferença Normalizada da Banda Verde (GNDVI), o Índice de Vegetação da Borda do Vermelho (NDRE) e os Índices de Clorofila (CIgreen e CIred-edge). Esses índices apresentam elevada correlação com parâmetros agronômicos, como vigor vegetativo, área foliar, teor de clorofila e concentração de nitrogênio nas plantas (Xue; Su, 2017).

Nos últimos anos, a adaptação dos sensores e sua integração com veículos aéreos não tripulados (VANTs ou drones) ampliaram significativamente sua aplicação na agricultura de precisão. Os drones equipados com sensores multiespectrais possibilitam a aquisição de imagens de alta resolução espacial e temporal, permitindo o monitoramento detalhado das lavouras ao longo do ciclo de desenvolvimento. Essas informações auxiliam na identificação precoce de deficiências nutricionais, falhas de plantio, estresse hídrico, ataques de pragas e doenças, além de subsidiar o manejo localizado de fertilizantes e irrigação, contribuindo para o aumento da produtividade e a redução dos custos de produção (Zhu *et al.*, 2020; Thieme *et al.*, 2025).

4. MATERIAL E MÉTODO


4.1. Caracterização da área de estudo

O experimento foi realizado na Universidade Federal Rural de Pernambuco (UFRPE), na Unidade Acadêmica de Serra Talhada (UAST), localizada no município de Serra Talhada, no Estado de Pernambuco. A região é caracterizada pelo clima BSw'h' — semiárido, quente e seco segundo Köppen —, com precipitação média anual de 657 mm e temperatura média de 25,8 °C (ALVARES *et al.*, 2013; LINS *et al.*, 2017).

A área experimental (Figura 2) está localizada nas coordenadas geográficas 7°57'16.95"S e 38°17'42.61"O, com altitude média de aproximadamente 500 m. O delineamento da área é composto por quatro blocos, cada um subdividido em quatro parcelas, totalizando 16 unidades experimentais. Cada parcela implantada possui quatro linhas de cultivo, sendo

as duas externas utilizadas como bordaduras. O arranjo do plantio segue o espaçamento de 0,20 m entre plantas e de 1,0 m entre fileiras. As parcelas possuem dimensões de 5 m de comprimento por 4 m de largura, perfazendo uma área individual de 20 m² e, em conjunto, uma área experimental total de 320 m².

Figura 2 - Mapa de localização da área de estudo



Fonte: Autor, 2026.

4.2. Obtenção das imagens


As imagens foram coletadas usando um VANT Mavic 3M (DJI, Shenzhen, China) equipado com um sensor RGB de 20 MP (CMOS 4/3) e quatro sensores multiespectrais de 5 MP (CMOS 1/2,8) cobrindo as bandas verde (560 ± 16 nm), vermelha (650 ± 16 nm), vermelho-borda (RE, 730 ± 16 nm) e infravermelho próximo (NIR, 860 ± 26 nm). O plano de voo foi executado a uma altitude de 20 m (resultando em um GSD de 0,92 cm). pixel⁻¹ para permitir a identificação de texturas finas de folhas e extração de pixels puros), uma velocidade de 1,1 m s⁻¹ para evitar desfoque de movimento) e 80% de sobreposição frontal e 85% lateral (para garantir reconstrução geométrica de

alta qualidade em densas copas de forragem)(Dos Santos *et al.*, 2026). As coletas ocorreram nos meses de março, maio e junho de 2026.

4.3. Processamento das imagens

Os produtos das bandas espectrais de cada período geradas pelo Pix4Dmapper (*green, nir, red, red edge*) foram georreferenciadas (Figura 3) em um software de sistema de informações geográficas Qgis versão da série 3.28 (QGIS Development Team, 2022), a partir de 6 pontos de controle distribuídos na área, esses tiveram suas respectivas coordenadas captadas utilizando o sistema de posicionamento por satélite do modelo RTK Stonex (S850A).


Figura 3 - Pontos de controle utilizados no georreferenciamento



Fonte: Autor, 2026.

Em ambiente Qgis foi criada uma camada buffer de acordo com a coordenada de cada planta de Capiáu (Figura 4a), com diâmetro de 0,5 m, onde foi possível a extração da estatística zonal com o valor médio das bandas espectrais (Figura 4b).

Figura 4 - a) Criação do buffer, b) Estatística zonal



Fonte: Autor, 2026.

4.4. Índices de vegetação

A partir dos produtos extraídos no Pix4Dmapper e processadas em ambiente Qgis para extração dos valores referente as bandas para cada ponto, sendo esses valores transferidos para um programa editor de planilhas Google Planilhas (Google, 2026), foram calculados os índices de vegetação (IVs) apresentados na tabela 1: índice de vegetação por diferença normalizada (NDVI), o índice de borda vermelha por diferença normalizada (NDRE), o Índice de Vegetação Verde por Diferença Normalizada (GNDVI), o Índice de Clorofila Borda Vermelha (CI Red Edge) e o Índice de Clorofila Terrestre MERIS (MTCI).

Tabela 1. Resumos dos índices utilizados

Índices	Bandas	Referência
---------	--------	------------

NDVI -Índice de vegetação por diferença normalizada	$NDVI = (NIR - RED) / (NIR + RED)$	Rouse (1974).
NDRE -Índice de borda vermelha por diferença normalizada	$(NIR - RedEdge) / (NIR + RedEdge)$	Barnes et al. (2000).
CI Red Edge -Índice de Clorofila Borda Vermelha	$(NIR / RedEdge) - 1$	Gitelson & Merzlyak (1994)
GNDVI -Índice de Vegetação Verde por Diferença Normalizada	$(NIR - Green) / (NIR + Green)$	Gitelson, Kaufman e Merzylak (1996)
MTCI -Índice de Clorofila Terrestre MERIS	$(NIR - RedEdge) / (RedEdge - Red)$	Dash & Curran (2004)

Fonte: Autor, 2026.

Esses índices são amplamente utilizados para estimar, de forma indireta e não destrutiva, o estado nutricional das plantas, especialmente o teor de clorofila e de nitrogênio (N).

4.5. Análise de clorofila

O método proposto por Lichtenthaler (1987) é amplamente utilizado devido à sua precisão e simplicidade, por empregar solventes orgânicos e leitura espectrofotométrica, e tem como objetivo extrair e quantificar as clorofilas a e b e os carotenoides totais presentes em tecidos vegetais. Foram cortados, retirando-se as nervuras centrais das folhas, e pesados, aproximadamente, 0,1 a 0,2 g de tecido vegetal fresco e triturado no almofariz com cerca de 5 a 10 mL de acetona a 80%, mantendo o ambiente protegido da luz direta. Em seguida foram filtrados o extrato vegetal em papel de filtro (ou centrifugar a 3000 rpm por 10 minutos) para separar os resíduos sólidos. Foi medida a absorbância (A) do extrato em espectrofotômetro, nos seguintes

comprimentos de onda: 663 nm (Clorofila a), 646 nm (Clorofila b) e 470 nm (Carotenoides totais).

As concentrações foram determinadas pelas equações de Lichtenthaler (1987):

$$\text{Clorofila a (mg/L)} = 12,25 \times A_{663} - 2,79 \times A_{646};$$

$$\text{Clorofila b (mg/L)} = 21,50 \times A_{646} - 5,10 \times A_{663};$$

$$\text{Carotenoides totais (mg/L)} = [1000 \times A_{470} - 1,82 \times \text{Chl a} - 85,02 \times \text{Chl b}] / 198.$$

4.6. Determinação de nitrogênio total em tecido vegetal

4.6.1. *Preparo da amostra:*

- Coleta: coletado tecidos representativos (folha), evitando contaminação
- Secagem: seco em estufa ventilada a 60–70 °C até massa constante (48–72 h).
- Moagem: moído as amostras secas em moinho até obter pó homogêneo (passado em peneira de ~1 mm).
- Armazenamento: armazenado em frascos secos e identificados, em local seco.

Quantidade de ensaio: 0,1 g de material seco.

1. Pesados 100mg de uma amostra vegetal. Transferido para um tubo digestor e adicionado 7 mL da mistura digestora;
2. Adaptado o tubo digestor a um bloco digestor localizado em uma capela e colocado para aquecer obedecendo a seguinte sequência de tempo e temperatura: Uma hora a 100°C, Uma hora a 200°C e Uma hora a 300°C;
3. Após esfriar, foi dissolvido o digerido com cerca de 10 mL de água destilada e acoplado o tubo digestor ao destilador de Kjeldahl;
4. Procedido à destilação com o auxílio de 25mL de NaOH (50%) e recolhido o destilado em um erlenmeyer contendo 10mL de ácido bórico com indicador misto;

5. Titulado a amônia destilada usando uma solução padrão de H_2SO_4 0,05 N. Para a mistura de indicador utilizada, o ponto final da titulação correspondeu à mudança de cor: de verde para vermelho claro;
6. Procedendo aos cálculos expressando o teor de N total em termos percentuais.

4.6.2. *Preparo dos Reagentes:*

a. Mistura digestora 175ml de água destilada; 3,6g de selênio de sódio (Na_2SeO_3) anidro ou 5,47g de selenito de sódio pentahidratado ($\text{Na}_2\text{SeO}_3 \cdot 5\text{H}_2\text{O}$); 4,0g de sulfato de cobre penta hidratado ($\text{CuSO}_4 \cdot 5\text{H}_2\text{O}$); 21,3g de sulfato de sódio (Na_2SO_4) anidro ou 48,5g de sulfato de sódio deca hidratado ($\text{Na}_2\text{SO}_4 \cdot 10\text{H}_2\text{O}$). 200 mL de ácido sulfúrico (H_2SO_4) concentrado (36 N).

b. Solução de ácido bórico com indicador misto. Dissolvido 20g de ácido bórico em 1 litro de água destilada e acrescentado 15ml de uma solução alcoólica a 0,1% de verde de bromocresol e 6ml de solução alcoólica de vermelho de metila a 0,1%.

c. Solução de ácido sulfúrico (0,05 N). Colocou-se cerca de 500mL de água destilada em um balão volumétrico de 1000mL e em seguida acrescentado 1,4 mL de ácido sulfúrico concentrado (36 N) e padronizado.

4.7. Análise Estatística

Foi realizada uma análise estatística descritiva, incluindo os valores máximo, mínimo, médio e desvio padrão dos índices de vegetação, clorofila a, clorofila b, clorofila total, carotenoides totais e nitrogênio. Também foi aplicada a análise de regressão linear simples a partir dos produtos de sensoriamento remoto, onde foram avaliados com base nos coeficientes de determinação, raiz do erro quadrático médio e erro médio absoluto. A análise dos modelos foi desenvolvida em ambiente de R (R CORE TEAM, 2023), utilizando o pacote ggplot2 para geração dos gráficos.

5. RESULTADOS E DISCUSSÃO

As análises laboratoriais, informadas na tabela 2, não demonstram haver um padrão nos valores médios de clorofila a (Chl a) ao longo dos meses. A clorofila total apresentou valores crescentes entre os períodos, enquanto os carotenoides totais tiveram uma ligeira diminuição. Como os carotenoides atuam na fotoproteção e na dissipação de excesso de energia luminosa (DELGADO-VARGAS; JIMÉNEZ; PAREDES-LÓPEZ, 2000), essa razão pode ser interpretada como sinal de estresse oxidativo e de dossel fotossinteticamente menos eficiente nos meses de maio e junho. Deve-se considerar que, em março, o Capiáçu encontrava-se em estágio avançado de desenvolvimento, período em que foram observados os maiores valores das características vegetativas avaliadas, enquanto no mês de maio a cultura encontrava-se em fase intermediária, com plantas medianas e baixa cobertura vegetal, e em junho as plantas apresentavam um dossel mais desenvolvido e denso.

Tabela 2- Estatística descritiva de clorofila a, b, total e carotenoides totais (mg/L) nas folhas

Mês		Chl a	Chl b	Chl total	Carotenoides totais
Março	<i>Méd</i>	17.025	3.232	20,257	4,857
	<i>Máx</i>	28.774	7.586	36,360	11,035
	<i>Mín</i>	6.220	-5.935	7,387	1,411
	<i>DP</i>	7.442	3.750	9,622	2,410
Maio	<i>Méd</i>	16.414	4.662	21,076	4,748
	<i>Máx</i>	23.355	6.568	29,923	8,233
	<i>Mín</i>	12.429	3.876	16,305	3,715
	<i>DP</i>	2.805	0.704	3,464	1,103
Junho	<i>Méd</i>	18.861	4.983	23,844	4,694
	<i>Máx</i>	24.215	6.372	30,588	6,114
	<i>Mín</i>	11.266	3.913	15,179	2,691

<i>DP</i>	3.656	0.711	4,266	0,887
-----------	-------	-------	-------	-------

Méd. = média; Máx. = máximo; Mín. = mínimo; DP = desvio-padrão

Fonte: Autor, 2026.

Os teores de nitrogênio (Tabela 3) apresentaram padrão irregular ao longo dos meses: 14,71% (março), 28,15% (maio) e 15,85% (junho), com desvios-padrão elevados, sobretudo em junho (7,32), indicando forte heterogeneidade espacial ou temporal na absorção/translocação de N pela planta. O pico observado em maio, associado ao menor coeficiente de variação relativo desse mês, pode refletir um momento de maior disponibilidade de nitrogênio no solo (rebrotas recentes após o corte), já que, em gramíneas de corte como o capiaçu, o nitrogênio foliar tende a ser mais alto logo após a rebrota, decrescendo com a maturação do tecido foliar (LELIS *et al.*, 2025).

Tabela 3 - Estatística descritiva do nitrogênio (%) nas folhas

Mês	Méd	Máx	Mín	DP
Março	14,71	19,82	5,13	4,488
Maio	28,15	33,60	24,15	2,727
Junho	15,85	38,76	7,49	7,319

Fonte: Autor, 2026.

A tabela 4 evidenciou variações temporais no comportamento espectral da vegetação entre os meses de março, maio e junho. Observou-se que todos os índices avaliados (NDVI, NDRE, CI Red Edge, GNDVI e MTCl) apresentaram redução nos valores médios em maio, seguida de recuperação em junho.

Tabela 4 - Estatística descritiva dos índices de vegetação da cobertura vegetal do capiaçu

Mês	NDVI	NDRE	CI Red Edge	GNDVI	MTCl
<i>Méd</i>	0,852	0,375	1,211	0,732	1,463
<i>Máx</i>	0,891	0,431	1,516	0,777	1,774
Março <i>Mín</i>	0,786	0,294	0,831	0,672	1,024

Maio	<i>DP</i>	0,033	0,041	0,206	0,034	0,215
	<i>Méd</i>	0,788	0,314	0,919	0,686	1,184
	<i>Máx</i>	0,842	0,351	1,084	0,725	1,339
	<i>Mín</i>	0,694	0,266	0,723	0,626	0,993
	<i>DP</i>	0,047	0,029	0,121	0,035	0,101
Junho	<i>Méd</i>	0,848	0,381	1,237	0,752	1,512
	<i>Máx</i>	0,883	0,423	1,466	0,786	1,732
	<i>Mín</i>	0,791	0,326	0,968	0,713	1,188
	<i>DP</i>	0,025	0,025	0,128	0,020	0,129

Fonte: Autor, 2026.

A regressão linear buscou avaliar e quantificar a relação entre uma variável independente (X) e uma variável dependente (Y), permitindo verificar se alterações em X estão associadas a mudanças em Y. Além disso, a regressão possibilita construir um modelo matemático capaz de estimar ou prever os valores da variável resposta. A tabela 5 mostra um resumo da análise de correlação entre as bandas e dados de clorofila (Chl a, Chl b, Chl total e Carotenoides totais).

Tabela 5 - Resumo da regressão linear simples entre as bandas e valores de clorofila.

Banda	Chl a		Chl b		Chl total		Carotenoides totais	
	R²	RMSE	R²	RMSE	R²	RMSE	R²	RMSE
Green	0.0646	4.8276	0.0034	2.2908	0.0653	6.3418	0.0355	1.5325
Nir	0.079	4.7903	0,0004	2.2945	0.1216	6.1477	0.0109	1.5519
Red	0.0044	4.9806	0.0091	2.2842	0.0065	6.5383	0.0037	1.5575
Red Edge	0.0784	4.792	0,0007	2.294	0.1095	6.19	0.0172	1.5469

Fonte: Autor, 2026.


Observou-se baixa relação linear entre os dados obtidos, com coeficientes de determinação (R²) muito próximos ou iguais a zero.

Independentemente das combinações entre bandas espectrais e tipos de clorofila avaliados, os resultados não demonstraram relação linear suficientemente consistente que pudesse indicar capacidade preditiva assertiva.





A figura 5 mostra a análise gráfica da regressão linear dos dados, onde visualizamos a alta dispersão dos pontos.

Figura 5 - Regressão linear simples entre banda e valores de clorofila



Banda Green vs Chl a, b, totais e Carotenoides totais





Banda Nir vs Chl a, b, totais e Carotenoides totais







Banda Red vs Chl a, b, totais e Carotenoides totais





Banda Red Edge vs Chl a, b, totais e Carotenoides totais



Fonte: Autor, 2026.

A relação com os IVs seguiu o mesmo padrão obtido com as bandas, nenhum índice se destacou na comparação com os valores e clorofila. O modelo não explica as variâncias da clorofila. Isso é, na prática, nenhuma capacidade explicativa relevante. A tabela 6 apresenta um resumo do R² e RMSE determinado pela regressão linear simples entre os dados.



Tabela 6 - Resumo da regressão linear simples entre os índices e valores de clorofila



	Chl a		Chl b		Chl total		Carotenoides totais	
Índice	R ²	RMSE	R ²	RMSE	R ²	RMSE	R ²	RMSE
CI Red Edge	0.0276	4.9224	0,0003	2.2944	0.0598	6.3605	0,0001	1.5604
GNDVI	0.0233	4.9331	0,0001	2.2946	0.0636	6.3475	0,0008	1.5598
MTCI	0.028	4.9213	0,0002	2.2945	0.0635	6.3478	0	1.5604
NDRE	0.0288	4.9193	0,0001	2.2946	0.063	6.3495	0	1.5604
NDVI	0.0247	4.9297	0.0067	2.2871	0.0456	6.4085	0,0002	1.5602

Fonte: Autor, 2026.





A figura 6 evidencia a discrepância entre os índices de vegetação e os valores da clorofila.

Figura 6 - Regressão linear simples entre índices e valores de clorofila
CI Red Edge x Chl a, b, totais e Carotenoides totais











GNDVI x Chl a, b, totais e Carotenoides totais





MTCI x Chl a, b, totais e Carotenoides totais







NDRE x Chl a, b, totais e Carotenoides totais





NDVI x Chl a, b, totais e Carotenoides totais



Fonte: Autor, 2026.

A relação das bandas com o nitrogênio apresentou valores superiores quando comparados à clorofila, no entanto, ainda explica pouco a variância (Tabela 7).

Tabela 7 - Resumo da regressão linear simples entre as bandas e valores de Nitrogênio



Banda	Nitrogênio	
	R ²	RMSE
Green	0.1951	7.0809
Nir	0.3521	6.3526
Red	0.001	7.8871
Red Edge	0.3232	6.4929

Fonte: Autor, 2026.

Apenas o red demonstrou precisamente um R² igual a 0, enquanto os demais chegaram no máximo R² = 0,35, ou seja, o modelo só explica 35% da variância (Figura 7).

Figura 7 - Regressão linear simples entre bandas e N (%)

Bandas (green, nir, red, red edge) vs Nitrogênio





Fonte: Autor, 2026.

O modelo também apresenta limitações para estimar precisamente a relação dos índices com o nitrogênio, como observado na tabela 8 com o resumo dos valores da regressão.

Tabela 8 - Resumo da regressão linear simples entre os índices e valores de Nitrogênio






Nitrogênio		
Índice	R ²	RMSE
CI Red Edge	0.2365	6.8962
GNDVI	0.2174	6.982
MTCI	0.2252	6.9472
NDRE	0.2383	6.8882
NDVI	0.2193	6.9736

Fonte: Autor, 2026.

Assim como nas análises de correlação das bandas vs N, os valores de R² apresentaram uma baixa capacidade preditiva. Na figura 8, os gráficos de dispersão evidenciam a baixa correlação.

Figura 8 - Regressão linear simples entre índices e N (%)

Índices (CI Red Edge, GNDVI, MTCI, NDRE e NDVI) vs Nitrogênio



Fonte: Autor, 2026.

Assim como encontrado por XU et al.,(2021), essa variação na precisão pode ter sido baseada no uso de diferentes índices de vegetação, nos modelos estatísticos aplicados e nos diferentes períodos de amostragem durante o ciclo

de crescimento. Além desses fatores, diversos outros fatores no campo do sensoriamento remoto podem afetar a qualidade da análise de imagens.

Os pontos de controle terrestre (GCPs) são usados para georreferenciar e dimensionar modelos fotogramétricos e para fins de calibração da câmera. Geralmente, um número mínimo de três GCPs é necessário para pequenas áreas (Yu et al., 2020), no presente estudo foram utilizados 6 GCPs distribuídos sobre a área para obter imagens georreferenciadas com precisão, além da coleta dos referidos pontos com o coletor RTK. No entanto, a precisão do georreferenciamento pode introduzir variações e grandes erros dependendo do terreno, da dificuldade da área e da variação do nível do solo (Oniga; Breaban; Statescu, 2018; Park; Yeom, 2021). Além disso, as condições ambientais em datas específicas podem causar problemas de calibração. Ao converter as imagens brutas em reflectância, o painel de calibração sob condições ambientais variáveis pode causar erros inesperados na geração de dados de reflectância e, portanto, aumentar a incerteza dos índices de vegetação.

Além disso, a maioria das imagens para fins de calibração de reflectância foi reconhecida pelo Pix4D; no entanto, segundo o Pix4D, a medição do alvo radiométrico apresenta um erro de 5%, erro que contribui para a precisão geral da metodologia. Além disso, XU et al. (2021) citou que o tamanho do buffer pode causar maior viés no teor de clorofila, pois como esse fator está concentrado nas folhas, portanto, zonas de amortecimento menores são preferíveis para incluir menos caules. Sugeriu-se então, para medir com precisão o índice de vegetação para cada local da planta, precisaria criar informações sobre o tamanho de cada planta em campo. Este desafio pode ser abordado em estudos futuros utilizando o perímetro exato de cada planta na população.

6. CONSIDERAÇÕES FINAIS

As análises demonstraram baixa capacidade de estimar a relação entre os dados obtidos pelo sensor multiespectral embarcado em VANT e aqueles obtidos a partir do material vegetal do capiaçu. Os resultados reforçam a premissa de que, embora essa tecnologia constitua uma ferramenta eficiente e não destrutiva para a aquisição de dados, ainda são necessários ajustes

metodológicos que permitam determinar com maior precisão a relação entre os produtos gerados e os dados obtidos em campo. Além disso, o reduzido número de estudos voltados à cultura do capiaçu em condições de semiárido limita a disponibilidade de subsídios científicos que sustentem a obtenção de resultados mais consistentes.

Nesse contexto, recomenda-se que pesquisas futuras explorem novos índices de vegetação e técnicas de modelagem estatística e aprendizado de máquina. Tais avanços poderão contribuir para o desenvolvimento de modelos mais robustos e confiáveis, favorecendo a utilização dessa tecnologia como ferramenta de apoio ao monitoramento nutricional e ao manejo de precisão da cultura do capiaçu no semiárido

7. REFERÊNCIAS

- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES, G.; LEONARDO, J.; & SPAROVEK, G., 2013: Köppen's Climate Classification Map for Brazil. **Meteorologische Zeitschrift**, 22 (6), 711-728. 2013.
- ARNON, D. I. Copper enzymes in isolated chloroplasts. Polyphenoloxidase in *Beta vulgaris*. *Plant Physiology*, v. 24, n. 1, p. 1–15, 1949.
- BARBOSA, R. D.; BENTES, J. L. S.; & FERREIRA E FERREIRA, A. F. T. A. (2023). *Manejo da nutrição mineral e doenças de plantas: uma revisão*. **Revista Agrária Acadêmica**, 6(5), 10–26, 2023.
- BARNES, E. M. et al. Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data. In: **Proceedings of the fifth international conference on precision agriculture, Bloomington, MN, USA**. 2000.
- BRS CAPIAÇU E BRS KURUMI**: cultivo e uso / Antonio Vander Pereira ... [et al.]. - Brasília, DF : Embrapa, 2021.
- CANTARELLA, H. Nitrogênio. In: NOVAIS, R. F.; ALVAREZ, V. H.; BARROS, N. F.; FONTES, R. L.; CANTARUTTI, R. B.; NEVES, J. C. L. (eds.). *Fertilidade do solo*. Viçosa: **Sociedade Brasileira de Ciência do Solo**, p. 375–470. 2007.
- CLEVERS, J. G. P. W.; KOOISTRA, L. Remote sensing for precision agriculture: developments and future perspectives. **Remote Sensing**, 2025.
- CORRÊA, D. C. C.; CARDOSO, A. S.; FERREIRA, M. R.; SINISCALCHI, D.; TONIELLO, A. D.; LIMA, G. C.; REIS, R. A.; RUGGIERI, A. C. **Are soil CH₄, CO₂, and N₂O emissions affected by N sources and rates in warm-season pastures?** *Atmosphere*, Basel, v. 12, n. 6, art. 697, 2021. Disponível em: <https://doi.org/10.3390/atmos12060697>. Acesso em: 9 jul. 2026.
- DASH, J. & CURRAN, P.J. The MERIS terrestrial chlorophyll index. **Int. J. Remote Sens.** 25, 5003–5013, 2004.
- DELGADO-VARGAS, F.; JIMÉNEZ, A. R.; PAREDES-LÓPEZ, O. Natural pigments: carotenoids, anthocyanins, and betalains—characteristics,

biosynthesis, processing, and stability. **Critical Reviews in Food Science and Nutrition**, v. 40, n. 3, p. 173–289, 2000.

DOS SANTOS, W. M.; JARDIM, A. M. D. R. F.; MARTINS, L. D. C. D. S.; DE MOURA, M. B. M.; DA SILVA, E. F.; BEZERRA, A. C.; NETO, A. J. S.; DA SILVA, M. V.; DA SILVA, J. L. B.; DE SOUZA, L. S. B.; TANG, X. Forage crop classification in heterogeneous environments using UAV, machine learning, and RGB-multispectral fusion. **IEEE Transactions on Geoscience and Remote Sensing**, v. 64, art. 4410915, 2026.

DRECCER, M. F. et al. *Wheat yield potential can be maximized by increasing red to far-red light conditions at critical developmental stages*. Plant, Cell & Environment, 2022.

DUCHEIKO, H. A. S.; FREITAS, L. C. N. de; ZANATTA, J. A.; BAYER, C.; DIECKOW, J. Fontes nitrogenadas e aditivos de eficiência aumentada para mitigar óxido nitroso em cultivo de milho. In: REUNIÃO PARANAENSE DE CIÊNCIA DO SOLO, 9., 2025, Curitiba. Anais [...] : diversidade, funções e usos do solo: desafios e oportunidades. Curitiba: Núcleo Estadual Paraná da Sociedade Brasileira de Ciência do Solo; Universidade Federal do Paraná, p. 251-254, 2025.

GATES, D. M. et al. Spectral properties of plants. *Applied Optics*, v. 4, n. 1, p. 11–20, 1965.

GEBBERS, R.; ADAMCHUK, V. I. Precision agriculture and food security. *Science*, v. 327, n. 5967, p. 828–831, 2010.

GOOGLE. Google Planilhas. *Mountain View: Google*, 2026.

HUNT, E. R. et al. Acquisition of NIR-Green-Blue digital photographs from unmanned aircraft for crop monitoring. *Remote Sensing*, v. 10, n. 1, p. 1–19, 2018.

JENSEN, J. R. **Introductory Digital Image Processing: A Remote Sensing Perspective**. 4. ed. New York: Pearson, 2015.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente: uma perspectiva em recursos terrestres**. 2. ed. São José dos Campos: Parêntese, 2016.

JONES, H. G.; VAUGHAN, R. A. *Remote Sensing of Vegetation: Principles, Techniques, and Applications*. Oxford: Oxford University Press, 2010.

KHANAL, S.; KC, K.; FULTON, J. P.; SHEARER, S.; OZKAN, E. Remote sensing in agriculture: accomplishments, limitations, and opportunities. *Remote Sensing*, v. 12, n. 22, art. 3783, 2020.

KNIPLING, E. B. Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. ***Remote Sensing of Environment***, v. 1, p. 155–159, 1970.

KUUNYA, R.; MOHAMMED, E. A. H.; OSMAN, M. M. Ahmed.; SSEMUGENZE, B.; TAMÁS, A.; RAGÁN, P. **Leveraging Remote Sensing Technologies: A Review of Precision Cropping Challenges and Research Trend Analysis**. *Journal of the Indian Society of Remote Sensing*, 2026.

LELIS, D. L.; PACIULLO, C. S. D.; MORENZ, M. J. F.; GOMIDE, C. A. M.; ROSEIRA, J. P. S.; LOPES, F. C. F.; OLIVEIRA, J. S.; PEREIRA, O. G.; SILVA, V. P.; CHIZZOTTI, F. H. M. Produção de biomassa e qualidade da silagem de capim-elefante BRS Capiacu ensilado em diferentes idades de rebrota e alturas de resíduos. ***Sci Rep*** 15 , 4016, 2025.

LI, D.; YANG, S.; DU, Z.; XU, X.; ZHANG, P.; YU, K.; ZHANG, J.; SHU, M. **Application of unmanned aerial vehicle optical remote sensing in crop nitrogen diagnosis: a systematic literature review**. *Computers and Electronics in Agriculture*, 2024.

LIAKOS, K. G. et al. Machine learning in agriculture: A review. *Sensors*, v. 18, n. 8, 2674, 2018.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. **Remote Sensing and Image Interpretation**. 7. ed. Hoboken: John Wiley & Sons, 2015.

LICHTENTHALER, Helmut K. Chlorophylls and carotenoids: pigments of photosynthetic biomembranes. ***Methods in Enzymology***, San Diego, v. 148, p. 350–382, 1987.

LINS, F. A. C.; SILVA, J. B.; MOURA, G. B. A.; ORTIZ, P. F. S.; OLIVEIRA, J. D. A.; ALVES, M. V. C. Quantile technique to precipitation, rainfall anomaly index and biophysical parameters by remote sensing in Serra Talhada, Pernambuco. *Journal of Hyperspectral Remote Sensing*, 7 (6), 334-344, 2017.

MOLIN, J. P.; AMARAL, L. R.; COLAÇO, A. F. *Agricultura de precisão*. 1. ed. São Paulo: Oficina de Textos, 2015.

NASCIMENTO, D. B.; LOPES, M. L. S.; IZIDRO, J. L. P. S.; BEZERRA, R. C. A.; GOIS, G. C.; AMARAL, T. N. E.; DIAS, W. S.; BARROS, M. M. L.; OLIVEIRA, A. R. S.; FARIAS SOBRINHO, J. L.; & MEDEIROS, J. F. *Ciclagem de nitrogênio, fósforo e potássio em ecossistemas de pastagem. Ciência Animal Brasileira*, 25, e76743P, 2024.

OMIA, E.; BAE, H.; PARK, E.; KIM, M. S.; BAEK, I.; KABENGE, I.; CHO, B.-K. Remote sensing in field crop monitoring: a comprehensive review of sensor systems, data analyses and recent advances. *Remote Sensing*, v. 15, n. 2, 354, 2023.

OSTRIA-GALLARDO, E.; BASCUÑÁN-GODOY, L.; FERNÁNDEZ DEL-SAZ, N. Editorial: Nitrogen metabolism in crops and model plant species. *Frontiers in Plant Science*, v. 15, 2024.

PEREIRA, A. V. et al. **BRS Capião: cultivar de capim-elefante de alto rendimento para produção de silagem**. Juiz de Fora: Embrapa Gado de Leite, 2016. 6 p. (Embrapa Gado de Leite. Comunicado Técnico, 79).

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. *Sensoriamento Remoto da Vegetação*. 2. ed. São Paulo: Oficina de Textos, 2012.

POORTER, H.; EVANS, J. R. Photosynthetic nitrogen-use efficiency of species that differ inherently in specific leaf area. *Oecologia*, v. 116, n. 1–2, p. 26–37, 1998.

QGIS DEVELOPMENT TEAM. *QGIS Geographic Information System*. Version 3.28. Open Source Geospatial Foundation Project, 2022.

QUEIROZ, D. M.; COELHO, A. L. Freitas.; VALENTE, D. S. M.; SCHUELLER, J. Sensors applied to digital agriculture: a review. **Revista Ciência Agronômica**, v. 51, n. esp., e20207751, 2020.

RAVEN, P. H.; EVERT, R. F.; EICHHORN, S. E. **Biologia vegetal**. 8. ed. Rio de Janeiro: Guanabara Koogan, 2014.

R CORE TEAM. **R Development Core Team. R: A Language and Environment for Statistical Computing**. , 2023.

ROUSE, J.W.; HAAS, R.H.; SCHELL, J.A.; DEERING, D.W. Monitoring vegetation systems in the Great Plains with ERTS. **Third Symposium of ERTS, Greenbelt, Maryland NASA**, p. 309–317, Washington DC, 1974.

SCHOWENGERDT, R. A. **Remote Sensing: Models and Methods for Image Processing**. 3. ed. Burlington: Academic Press, 2007.

TAKASHIMA, T.; HIKOSAKA, K.; HIROSE, T. Photosynthesis or persistence: nitrogen allocation in leaves of evergreen and deciduous *Quercus* species. **Plant, Cell & Environment**, v. 27, n. 8, p. 1047–1054, 2004.

TAIZ, L.; ZEIGER, E.; MOLLER, I. M.; MURPHY, A. **Fisiologia e desenvolvimento vegetal**. 6º ed. Porto Alegre: Artmed. 888 p. 2017.

THIEME, M. et al. Multispectral red-edge indices accurately estimate nitrogen content in winter cereal cover crops. **Precision Agriculture**, 2025.

THENKABAIL, P. S. (Ed.). **Hyperspectral Remote Sensing of Vegetation**. 2. ed. Boca Raton: CRC Press, 2018.

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

XIE, Q. et al. Monitoring nitrogen status of crops using unmanned aerial vehicle-based multispectral imagery: a review. **Remote Sensing**, v. 12, n. 20, p. 1–23, 2020.

XUE, J.; SU, B. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. **Journal of Sensors**, v. 2017, p. 1–17, 2017.

YADAVA, U. L. A rapid and nondestructive method to determine chlorophyll in intact leaves. *HortScience*, v. 21, n. 6, p. 1449–1450, 1986.

YANG, G. et al. Unmanned Aerial Vehicle Remote Sensing for Field-Based Crop Phenotyping: Current Status and Perspectives. ***Frontiers in Plant Science***, v. 11, 2020.

ZHU, Y. et al. Estimating leaf chlorophyll content of crops via optimal UAV hyperspectral data at multi-scales. ***Computers and Electronics in Agriculture***, v. 173, 2020.