



UNIVERSIDADE FEDERAL RURAL PERNAMBUCO- UFRPE
UNIDADE ACADÊMICA DE SERRA TALHADA – UAST
BACHARELADO EM AGRONOMIA

DOUGLAS DOS SANTOS OLIVEIRA

ESTIMATIVA DE ALTURA E BIOMASSA DO CAPIM-ELEFANTE BRS CAPIAÇU
COM SENSOR LIDAR EMBARCADOS EM VANTS NO SEMIÁRIDO
NORDESTINO

SERRA TALHADA – PE
2025

DOUGLAS DOS SANTOS OLIVEIRA

**ESTIMATIVA DE ALTURA E BIOMASSA DO CAPIM-ELEFANTE BRS CAPIAÇU
COM SENSOR LIDAR EMBARCADOS EM VANTS NO SEMIÁRIDO
NORDESTINO**

Trabalho de Conclusão de Curso de
Bacharelado em Agronomia pela
Universidade Federal Rural de Pernambuco
– Unidade Acadêmica de Serra Talhada,
como requisito parcial para obtenção do título
de Engenheiro Agrônomo.

Orientador: Prof. Dr. Alan Cezar Bezerra

**SERRA TALHADA – PE
2025**

Dados Internacionais de Catalogação na Publicação
Sistema Integrado de Bibliotecas da UFRPE
Bibliotecário: Danilo Trindade Barbosa – CRB – 4 2285

O48e Oliveira, Douglas dos Santos.

Estimativa de altura e biomassa do capim-elefante BRS capiaçu com sensor lidar embarcados em vants no semiárido nordestino / Douglas dos Santos Oliveira. – Serra Talhada, 2026.
53 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, PE- BR, 2026.

Inclui referências.

1. Sensoriamento remoto. 2. LiDAR. 3. Veículo aéreo não tripulado (VANT). 4. Forragicultura. 5. Semiárido. I. Bezerra, Alan Cezar, orient.
II. Título.

CDD 630

**ESTIMATIVA DE ALTURA E BIOMASSA DO CAPIM-ELEFANTE BRS CAPIAÇU
COM SENSOR LIDAR EMBARCADOS EM VANTS NO SEMIÁRIDO
NORDESTINO**

Trabalho de Conclusão de Curso de
Bacharelado em Agronomia pela
Universidade Federal Rural de Pernambuco
– Unidade Acadêmica de Serra Talhada,
como requisito parcial para obtenção do título
de Engenheiro Agrônomo.

DEFENDIDA em 10 de fevereiro de 2026

Banca Examinadora

Prof. Dr. Alan Cezar Bezerra (Orientador, UAST/UFRPE)

Prof. Dr. José Raliuson Inácio Silva (1º Examinador, UAST/UFRPE)

Prof. Dr. Aldo Torres Sales (2º Examinador, UAST/UFRPE)

**SERRA TALHADA – PE
2025**

A Deus, por nunca me deixar desistir, e aos meus pais, que fizeram tantos sacrifícios para que este sonho se tornasse realidade. Sem eles, nada disso seria possível.

DEDICO!

AGRADECIMENTOS

Primeiramente, agradeço a Deus, por sempre me abençoar, abrir portas e me conceder oportunidades ao longo da minha vida. Sou grato por me dar paciência, força e coragem para permanecer longe da minha família durante esse período.

Agradeço aos meus pais, Nadinha e Zé Silvio, e ao meu irmão, por todo o apoio, carinho, incentivo e dedicação ao longo da minha vida e da minha caminhada na faculdade. Nada disso seria possível sem o esforço e o amor de vocês.

Aos meus colegas de classe, com quem compartilhei tantos momentos e aprendizados, em especial Carla, Gustavo, Franciê e Cristina, muito obrigado por toda parceria. Em especial também ao meu amigo Vinícius, que iniciou essa caminhada ao meu lado.

Agradeço aos meus colegas da residência estudantil, por toda a amizade, companheirismo e apoio ao longo dessa jornada.

Ao meu orientador, Prof. Alan Cézar Bezerra, que aceitou me orientar desde o início e me deu todo o apoio, tranquilidade e confiança para que este trabalho fosse concluído. Agradeço também a todos os professores do curso e à UAST pela oportunidade e pelo conhecimento compartilhado ao longo desses anos.

A todos(as) aqueles(as) que, de alguma forma, fizeram parte desta jornada, em especial Robson, Neurisvaldo, Júnior, Acássio, Vanessa, Jorge, Pedro e Ed, meu muito obrigado.

Por fim, e não menos importante, agradeço ao grande amor da minha vida, Iasmine Gomes, por quebrar paradigmas, por estar ao meu lado, por ser companheira, leal, meu refúgio e meu porto seguro nos momentos em que mais precisei, e, principalmente, por ter sonhado junto comigo. Estará para sempre em mim.

RESUMO

O acompanhamento do crescimento das culturas tem se tornado cada vez mais relevante para subsidiar a tomada de decisões no manejo agrícola, especialmente em sistemas forrageiros que demandam elevada eficiência produtiva. Nesse contexto, o capim-elefante (*Pennisetum purpureum*), com destaque para a cultivar BRS Capiáçu, apresenta elevado potencial produtivo e ampla utilização na alimentação de ruminantes em regiões semiáridas, exigindo técnicas que permitam o monitoramento contínuo do crescimento e da biomassa. Apesar de sua importância, a aplicação de tecnologias de sensoriamento remoto para esse fim ainda é limitada no Brasil e no mundo. O avanço do sensoriamento remoto aliado ao uso de veículos aéreos não tripulados (VANTs) equipados com sensores LiDAR tem ampliado as possibilidades de obtenção de informações biofísicas de forma rápida, precisa e não destrutiva. Assim, este trabalho teve como objetivo avaliar a aplicação de dados coletados por LiDAR embarcado em VANT para a estimativa da altura e da biomassa acima do solo do capim-elefante BRS Capiáçu. As coletas foram realizadas ao longo do ciclo produtivo da cultura, com análises mensais e uma abordagem global, comparando as estimativas derivadas de métricas estruturais da nuvem de pontos LiDAR com medições biométricas obtidas em campo. Os resultados indicaram desempenho satisfatório na estimativa da altura, com $R^2 \geq 0,70$ e $RMSE < 0,17$ m, e elevado ajuste para a biomassa seca acima do solo, com $R^2 > 0,90$ e $RMSE = 0,041$ kg m⁻², evidenciando a capacidade das métricas LiDAR em representar a variabilidade do dossel da cultura. De forma geral, os resultados demonstram o potencial do LiDAR como ferramenta aplicada ao monitoramento do capim-elefante BRS Capiáçu, contribuindo para o acompanhamento do crescimento e da produtividade, ao mesmo tempo em que indicam que a integração do LiDAR com sensores multiespectrais ou hiperespectrais, bem como a avaliação de diferentes configurações de voo, pode aprimorar ainda mais a estimativa dos parâmetros biofísicos da cultura em estudos futuros, especialmente em sistemas forrageiros do semiárido.

Palavras-chave: sensoriamento remoto; LiDAR; veículos aéreos não tripulados; forragicultura; semiárido.

ABSTRACT

Monitoring crop development has become increasingly important to support decision-making in agricultural management, especially in forage production systems that require high productive efficiency. Elephant grass (*Pennisetum purpureum*), particularly the BRS Capiçu cultivar, stands out for its high biomass yield and wide use in ruminant feeding under semi-arid conditions, demanding techniques that enable continuous and non-destructive monitoring of growth and biomass. In this context, the advancement of remote sensing associated with the use of unmanned aerial vehicles (UAVs) has expanded the potential for acquiring biophysical information with high spatial detail and operational efficiency, although the application of this technology for forage monitoring remains limited in Brazil and worldwide. This study aimed to evaluate the use of UAV-borne LiDAR data to estimate plant height and aboveground biomass of BRS Capiçu. Data acquisition was carried out throughout the crop growth cycle, and LiDAR-derived structural metrics were compared with field-based biometric measurements. Monthly evaluations and a global analysis were performed to assess the consistency of the estimates over crop development. The results demonstrated satisfactory performance of LiDAR for height estimation ($R^2 \geq 0.70$; RMSE < 0.17 m) and high accuracy for biomass estimation using equation-based modeling supported by selected structural metrics ($R^2 \geq 0.90$; RMSE = 0.041 kg m⁻²). These findings highlight the potential of LiDAR as a tool for monitoring elephant grass, contributing to the assessment of growth and productivity and supporting forage management strategies in semi-arid environments. Furthermore, the integration of LiDAR with multispectral or hyperspectral sensors may further enhance the accuracy of biophysical parameter estimation in future studies.

Keywords: Remote sensing; LiDAR; Unmanned aerial vehicles; Forage production; Semi-arid region.

LISTA DE FIGURAS

Figura 1. Mapa de localização da área estudada	23
Figura 2. Parcelas e pontos amostrais da área de estudo	24
Figura 3. Relação entre altura biométrica medida em campo e a métrica LIDAR em setembro	35
Figura 4. Relação entre altura biométrica medida em campo e a métrica LIDAR em novembro	36
Figura 5. Relação entre altura biométrica medida em campo e a métrica LIDAR em dezembro	37
Figura 6. Relação da distribuição: (A) setembro – distribuição da altura biométrica; (B) setembro – distribuição da métrica LiDAR; (C) novembro – distribuição da altura biométrica; (D) novembro – distribuição da métrica LiDAR; (E) dezembro – distribuição da altura biométrica; (F) dezembro – distribuição da métrica LiDAR	38
Figura 7. Relação global entre alturas medidas em campo e a estimada pelo LIDAR (Zq95), considerando conjuntamente os períodos de setembro, novembro e dezembro. A linha representa o ajuste de regressão linear global, e os indicadores estatísticos (R^2 , RSME e d)	39
Figura 8. Seleção de métricas LIDAR pelo pacote Boruta.	41
Figura 9. Diagnósticos dos resíduos	42
Figura 10. Ajuste do modelo da biomassa e a medida observada em campo	43

LISTA DE ABREVIACÕES E SIGLAS

- AGB** – Biomassa Acima do Solo (*Aboveground Biomass*)
- CHM** – Modelo de Altura do Dossel (*Canopy Height Model*)
- CSF** – Filtro de Simulação de Tecido (*Cloth Simulation Filter*)
- d** – Índice de Concordância de Willmott (*Willmott's Index of Agreement*)
- ET₀** – Evapotranspiração de Referência (*Reference Evapotranspiration*)
- GNSS** – Sistema Global de Navegação por Satélite (*Global Navigation Satellite System*)
- LIDAR** – Detecção e Medição por Luz (*Light Detection and Ranging*)
- MDS** – Modelo Digital de Superfície (*Digital Surface Model*)
- MDT** – Modelo Digital do Terreno (*Digital Terrain Model*)
- RMSE** – Raiz do Erro Quadrático Médio (*Root Mean Square Error*)
- RTK** – Cinemática em Tempo Real (*Real Time Kinematic*)
- SfM** – Estrutura a partir do Movimento (*Structure from Motion*)
- SOR** – Remoção Estatística de Outliers (*Statistical Outlier Removal*)
- SR** – Sensoriamento remoto
- SVM** – Máquina de Vetores de Suporte (*Support Vector Machine*)
- TIN** – Rede Triangular Irregular (*Triangulated Irregular Network*)
- VANT** – Veículo Aéreo Não Tripulado (*Unmanned Aerial Vehicle – UAV*)
- VLOS** – Linha de Visada Visual (*Visual Line of Sight*)
- zmax** – Altura Máxima da Nuvem de Pontos (*Maximum Height*)
- zmean** – Altura Média da Nuvem de Pontos (*Mean Height*)
- zq95** – Percentil 95 da Altura da Nuvem de Pontos (*95th Height Percentile*)

Sumário

1 INTRODUÇÃO	11
2 OBJETIVO GERAL	14
2.1 OBJETIVOS ESPECÍFICOS:	14
3 REVISÃO DE LITERATURA	14
3.1 CAPIM-ELEFANTE BRS CAPIAÇU	14
3.2 APLICAÇÕES DO SENSORIAMENTO REMOTO NA AVALIAÇÃO DE FORRAGEIRA	17
3.3 APLICAÇÕES DO SENSORIAMENTO REMOTO COM DADOS LIDAR NA AGRICULTURA	20
4 METODOLOGIA	22
4.1 LOCALIZAÇÃO DA ÁREA EXPERIMENTAL	22
4.2 DADOS BIOMÉTRICOS	25
4.3 AQUISIÇÃO DE IMAGENS AÉREAS COM VANT	25
4.4 PLANO DE VOO	27
4.5 PROCESSAMENTO DAS IMAGENS	28
4.6 ANÁLISE ESTATÍSTICA E MODELAGEM	31
5 RESULTADOS E DISCUSSÕES	33
5.1 ALTURA DO CAPIAÇU	33
5.1.1 Análise Descritiva Dos Dados	33
5.1.2 Avaliação Da Correlação	33
5.1.3 Distribuição Espacial Das Métricas Por Bloco Experimental	37
5.1.4 Correlação Global Integrada	39
5.2 SELEÇÃO DAS VARIÁVEIS	41
5.3 MODELAGEM DA BIOMASSA USANDO O LIDAR	42
6 CONCLUSÃO	45
7 REFERÊNCIAS	46

1 INTRODUÇÃO

O semiárido brasileiro é uma região que ocupa uma área de 1.335.298 km², abrangendo nove estados do Nordeste (Alagoas, Bahia, Ceará, Maranhão, Paraíba, Pernambuco, Piauí, Rio Grande do Norte, Sergipe) e o norte de Minas Gerais, totalizando mais de 1.400 municípios (BRASIL, 2005). É uma região ligada a desafios climáticos, tendo um regime de chuvas irregular e escasso, com prolongados períodos de estiagem.

Tais condições, no entanto, estabelecem um contexto desafiador para a atividade agrícola. Apesar dessas dificuldades, a produção agropecuária no semiárido é consideravelmente diversificada e necessária para a subsistência de milhões de pessoas, bem como para a economia local. Distante de ser uma área que não produz, o semiárido tem desenvolvido, ao longo do tempo, sistemas de produção adaptados e resilientes, que permitem o cultivo de várias culturas e a criação de animais, demonstrando a capacidade de superação e inovação dos agricultores familiares e das comunidades rurais (Silva et al., 2019; FAO, 2021).

Nesse contexto de produção agropecuária, a pecuária exerce um papel de grande importância, tanto para a segurança alimentar e renda dos produtores rurais locais quanto para a sua contribuição no PIB do país. O Brasil consolidou sua posição como um líder global no setor, sendo atualmente o maior exportador mundial de carne bovina e o segundo maior produtor, detendo um dos maiores rebanhos do planeta (BRASIL, 2024). Essa informação enfatiza a importância estratégica da pecuária para a economia brasileira como um todo, com as atividades agrícolas desenvolvidas em regiões como o semiárido contribuindo significativamente para essa performance.

Contudo, as características da região, com clima de baixa precipitação, alta temperatura e longos períodos de seca, impõem um grande desafio no que diz respeito à produção de forragem, base da alimentação animal. Diante dessa vulnerabilidade, a busca por cultivares resistentes e adaptadas é fundamental para garantir a alimentação animal. Nesse sentido, o capim-elefante BRS Capiacu, desenvolvido pela Embrapa, destaca-se por sua alta produção de biomassa (até 77.350 kg MS/ha/ano) e potencial para silagem e picado verde, oferecendo uma alternativa nutritiva e robusta (Retore et al., 2021).

Além disso, o manejo agrônomo é crucial para o sucesso da produção de forragem no semiárido. Práticas como a fertilidade do solo e a adubação são pilares

para um desenvolvimento vegetal vigoroso e mais resistente à seca (Moura et al., 2024). Complementarmente, o controle da idade de rebrota e da densidade de plantio otimiza a quantidade e a qualidade nutritiva da forragem, garantindo um uso eficiente dos recursos e maximizando a produção de biomassa por área (Pereira et al., 2016; Monção et al., 2020). A combinação dessas estratégias é essencial para a sustentabilidade da pecuária na região.

O monitoramento de parâmetros biofísicos das forrageiras também é um desses aspectos importantes que ajudam no bom desempenho em climas hostis. É através desses acompanhamentos que se criam estratégias de manejo operacional e se prevê a produtividade dos pastos (Baroni et al., 2007). Tradicionalmente, grande parte dessas avaliações é feita de forma direta, com coletas e análises em campo, que, embora precisas, são trabalhosas, demoradas e, às vezes, limitadas a pequenas áreas.

Como alternativa aos métodos tradicionais, surge o sensoriamento remoto, uma ferramenta de agricultura de precisão, proporcionando a obtenção de dados em larga escala e em tempo real, auxiliando na tomada de decisões mais rápida e assertiva sobre o manejo da forragem (Oliveira et al., 2024). Isso é vital para otimizar o uso da água e dos nutrientes, definir o melhor momento de pastejo ou corte e planejar a suplementação alimentar dos animais.

Estudos já reforçam as diversas possibilidades de utilizar veículos aéreos não tripulados (VANTs) equipados com sensores ópticos, especialmente RGB, para monitorar culturas quanto a aspectos como doenças, produtividade e estresse hídrico. Sensores que, utilizando a técnica SfM (Structure from Motion), possibilitam a geração de nuvens de pontos, fornecendo informações valiosas sobre o cultivo. Além disso, a integração de tecnologias como o LiDAR (Light Detection and Ranging) permite a modelagem tridimensional da área agrícola, ampliando as análises espaciais e da estrutura das plantas (Sonfonia et al., 2019; Zang et al., 2021; Rivera et al., 2023).

Outras pesquisas já demonstraram a eficiência dessas tecnologias no monitoramento de forragem para determinar fatores biofísicos cruciais (Silva et al., 2024; Oliveira, 2025; Andrade et al., 2024). Essas geotecnologias avançadas contribuem significativamente para o aprimoramento da produção pecuária, oferecendo informações detalhadas e em tempo hábil. Isso é especialmente relevante em regiões com condições climáticas desafiadoras como o semiárido, onde a

agilidade na resposta e a precisão no manejo podem fazer a diferença na sustentabilidade e rentabilidade da atividade.

Apesar dos estudos já citados indicarem que o sensoriamento remoto é uma ferramenta com grande potencial para auxiliar no acompanhamento de culturas, especialmente de forrageiras, ainda há uma escassez significativa de pesquisas voltadas para sua aplicação no monitoramento do capim-elefante BRS Capiapu, sobretudo em regiões semiáridas. A maior parte dos trabalhos existentes concentra-se em manejos mais convencionais, como adubação, idade de corte e valor nutricional (Retore et al., 2021; Monção, 2019). Por outro lado, o uso de tecnologias com sensores embarcados em drones, que permitem a coleta de dados sobre parâmetros importantes como altura e biomassa, ainda é pouco explorado nessa forrageira. Essa lacuna evidencia a necessidade de novos estudos que integrem o sensoriamento remoto ao manejo do BRS Capiapu, contribuindo para um planejamento mais eficiente e decisões técnicas mais assertivas na pecuária desta região.

Dessa maneira, este trabalho busca avaliar a eficiência do sensoriamento remoto no monitoramento de parâmetros agronômicos do capim-elefante BRS Capiapu no semiárido, por meio da utilização do sensor LiDAR, embarcado em Veículos Aéreos Não Tripulados (VANTs).

2 OBJETIVO GERAL

Avaliar a capacidade de estimativa de parâmetros agronômicos do capim-elefante BRS Capiapu por meio de dados LiDAR obtidos com veículo aéreo não tripulado (VANT), visando monitorar o crescimento da cultura no semiárido.

2.1 OBJETIVOS ESPECÍFICOS:

1. Obter dados LiDAR embarcados em veículo aéreo não tripulado (VANT);
2. Determinar parâmetros como as alturas, e biomassa da cultura a partir dos produtos gerados pelo sensor LiDAR
4. Validar a acurácia das estimativas de altura obtidas por sensoriamento remoto, comparando com os dados coletados em campo.

3 REVISÃO DE LITERATURA

3.1 CAPIM-ELEFANTE BRS CAPIAÇU

As forrageiras desempenham papel central na alimentação de ruminantes no Brasil, constituindo a base da dieta em sistemas de produção de leite e carne. Entretanto, em regiões submetidas a longos períodos de estiagem, como o semiárido brasileiro, a produção forrageira é fortemente afetada pela sazonalidade climática, o que compromete a regularidade na oferta de volumoso ao longo do ano. Nesse contexto, a adoção de espécies forrageiras adaptadas às condições ambientais, com elevado rendimento de biomassa e adequado valor nutritivo, torna-se fundamental para a manutenção da produtividade animal e a sustentabilidade dos sistemas produtivos (PEREIRA et al., 2016).

Entre as cultivares mais promissoras está a BRS Capiáçu, um tipo de capim-elefante (*Pennisetum purpureum* Schum.) desenvolvido pela Embrapa Gado de Leite, com foco na produção de silagem e fornecimento de forragem picada verde. De acordo com Rosa et al. (2019), essa cultivar reúne importantes vantagens morfológicas e estruturais, como touceiras eretas, colmos grossos e resistência ao acamamento, o que favorece o manejo mecanizado. Sua elevada produção de biomassa e adaptabilidade a diferentes condições edafoclimáticas a consolidam como uma alternativa viável à silagem de milho, principalmente em sistemas baseados em forragem tropical.

A cultivar foi lançada em 2016, fruto do cruzamento entre os acessos Guaco IZ2 e Roxo, ambos do Banco Ativo de Germoplasma de Capim-Elefante (BAGCE). Sua seleção baseou-se em atributos superiores como alta produtividade de matéria seca, resistência ao acamamento e tolerância ao estresse hídrico, além de excelente estrutura de planta (PEREIRA et al., 2016; ROSA et al., 2019).

Segundo Pereira et al. (2017), a BRS Capiáçu apresenta produtividade de matéria seca superior a 50 t/ha/ano, o que representa cerca de 33% a mais em comparação com cultivares tradicionais como Cameroon e Mineiro. Esses números, aliados à sua rusticidade, tornam a cultivar uma opção estratégica para regiões de clima seco, como o semiárido, onde a demanda por alternativas de baixo custo e alta eficiência é prioritária para garantir a segurança alimentar dos rebanhos.

Estudos como o de Retore et al. (2021) demonstram que o valor nutricional do Capiáu está diretamente relacionado à idade de corte. À medida que a planta amadurece, ocorre um processo de lignificação dos tecidos, o que reduz a digestibilidade da forragem. Aos 120 dias, por exemplo, a cultivar pode atingir até 4,6 metros de altura, com 252,6 t/ha de matéria verde e 64,11 t/ha de matéria seca, mas com queda no teor de proteína bruta para 7,63%, comprometendo seu aproveitamento nutricional.

Por essa razão, a recomendação técnica é que o corte ocorra entre 60 e 90 dias após a rebrota, período em que a planta possui maior concentração de folhas, melhor digestibilidade e teores mais equilibrados de proteína (ALVES et al., 2021).

De acordo com Monção et al (2019)., a aplicação de 100 a 150 kg/ha de nitrogênio tem se mostrado eficaz para maximizar a produção de biomassa e proteína bruta da BRS Capiáu, promovendo um bom equilíbrio entre qualidade nutricional e viabilidade econômica. Além disso, práticas adequadas de manejo, como o corte entre 60 e 90 dias após a rebrota, são determinantes para obtenção de um volumoso com alto valor nutritivo. Nesse contexto, a altura da planta se torna uma variável biométrica essencial, pois está diretamente associada ao estágio fisiológico do capim e, portanto, indica o momento ideal para o corte, permitindo maximizar o aproveitamento nutricional da forragem.

Em estudos voltados ao manejo e cultivo da BRS Capiáu, Moura et al. (2024) evidenciam sua alta resiliência ao estresse hídrico, característica que favorece sua adoção em regiões semiáridas. Os autores também compilam informações importantes sobre exigências nutricionais, espaçamento entre linhas, densidade de plantio, época ideal de corte e estratégias de conservação, demonstrando que, embora seja uma cultivar rústica, o Capiáu responde significativamente ao uso adequado da adubação, especialmente nitrogenada, para alcançar seu pleno potencial produtivo.

Complementando essas evidências, Alves (2021) confirma o excelente desempenho do Capiáu sob diferentes condições de manejo. A autora observa que, mesmo sem o uso de aditivos na silagem, a cultivar mantém bom valor nutricional e produtividade elevada, desde que seja manejada com cortes a cada 90 dias e com adubação nitrogenada adequada. Esses resultados reforçam a viabilidade técnica e econômica da BRS Capiáu para pequenos produtores, sobretudo em sistemas forrageiros de baixo custo.

Por fim, vale destacar a importância da biometria vegetal como ferramenta de apoio ao manejo da BRS Capiáçu. Variáveis como altura de planta, acúmulo de biomassa e diâmetro do colmo são indicativos diretos da produtividade e da qualidade da forragem. Segundo Monção et al. (2019), a mensuração desses parâmetros permite estabelecer estratégias mais precisas de corte e adubação, contribuindo diretamente para o desempenho da cultura tanto em termos nutricionais quanto produtivos.

3.2 APLICAÇÕES DO SENSORIAMENTO REMOTO NA AVALIAÇÃO DE FORRAGEIRAS

O avanço tecnológico no campo tem promovido transformações significativas na agricultura moderna, especialmente com a incorporação de tecnologias digitais que possibilitam o monitoramento e a tomada de decisão de forma mais precisa e eficiente. Entre essas tecnologias, o sensoriamento remoto (SR) destaca-se como uma ferramenta indispensável no contexto da Agricultura de Precisão, permitindo a coleta de informações detalhadas sobre a superfície terrestre sem a necessidade de contato físico direto, por meio da captação e análise da radiação refletida ou emitida pelos alvos (SHIRATSUCHI et al., 2014).

O sensoriamento remoto pode ser realizado por meio de diferentes plataformas, como satélites, aeronaves tripuladas e veículos aéreos não tripulados (VANTs). Essas plataformas carregam sensores capazes de captar imagens em diferentes espectros, como o visível, o infravermelho próximo e o infravermelho de ondas curtas. A partir dessas imagens, é possível calcular índices espectrais que fornecem informações sobre a saúde e o vigor das plantas, auxiliando no planejamento do manejo agrícola e na detecção precoce de estresses ambientais.

No Brasil, a introdução do sensoriamento remoto na agricultura ocorreu de forma gradual, inicialmente restrita a culturas como soja, milho e cana-de-açúcar. Contudo, estudos recentes têm demonstrado o potencial dessa tecnologia também no monitoramento de forrageiras, área que historicamente enfrentou limitações no uso de ferramentas digitais.

Neste cenário, o sensoriamento remoto surge como uma tecnologia complementar de grande utilidade. O uso de sensores embarcados em VANTs permite a estimativa não destrutiva e em larga escala de atributos como índice de área foliar (IAF), altura da planta e biomassa. Geipel et al. (2021) demonstraram que

câmeras hiperespectrais e RGB acopladas a drones, associadas a modelos de regressão PLSR, conseguem prever com alta precisão variáveis nutricionais da forragem, como FDN e proteína bruta. De forma semelhante, Avneri et al. (2022) aplicaram imagens RGB combinadas com algoritmos de aprendizado de máquina (SVM e PLS-R) para estimar biomassa e IAF, alcançando coeficientes de determinação (R^2) de até 0,96. Por sua vez, Wang et al. (2023) destacaram o uso de imagens multiespectrais e texturais para prever o IAF de pastagens tropicais, com R^2 superiores a 0,80.

Saldanha et al. (2024) destacam que o sensoriamento remoto pode ser utilizado com sucesso na estimativa da massa de forragem, teor de nitrogênio e produtividade de pastagens. Por meio da análise de índices espectrais como NDVI e SAVI, torna-se possível identificar variações no vigor vegetativo e planejar o manejo de forma mais precisa, contribuindo para o aumento da eficiência na produção de alimentos para os rebanhos.

A aplicação do SR em culturas forrageiras também foi evidenciada por Andrade et al. (2025), que utilizaram imagens multiespectrais obtidas por satélite para monitorar a palma forrageira em diferentes estágios de desenvolvimento. Os autores observaram que a reflectância espectral varia conforme a idade da cultura, permitindo a identificação de áreas que demandam manejo diferenciado.

Grüner et al. (2019) demonstraram, em estudo conduzido com gramíneas temperadas, que a utilização de imagens obtidas por drones equipados com câmeras RGB, associadas à técnica de Structure from Motion (SfM), possibilita a estimativa precisa da biomassa seca e da altura do dossel. A pesquisa evidenciou que o uso de drones para esse fim reduz a necessidade de medições manuais, tornando o processo de monitoramento mais ágil e menos oneroso.

Sensores de baixo custo acoplados a drones, com capacidade para captar imagens no visível e no infravermelho próximo, podem estimar variáveis importantes como biomassa e índice de área foliar em forrageiras de clima temperado, como o azevém. Esses avanços mostram que o acesso às tecnologias de sensoriamento remoto não está mais restrito a grandes produtores, como ficou evidenciado no estudo de Fan et al. (2017).

Além disso, estudos demonstram que imagens captadas por VANTs podem ser utilizadas para estimar a altura das plantas com base em modelos fotogramétricos, evidenciando que essa abordagem pode ser adaptada para outras culturas, incluindo

gramíneas forrageiras, oferecendo dados precisos para o manejo e a colheita (MARTELLO, 2017).

Outro exemplo da aplicação do sensoriamento remoto em pastagens foi apresentado por Pessanha (2020), que utilizou imagens dos satélites Landsat-8 e Sentinel-2 para monitorar áreas de pastagem no estado do Rio de Janeiro. O estudo demonstrou que a análise temporal das imagens permite identificar o comportamento sazonal das pastagens, auxiliando no planejamento da produção forrageira. Contudo, o autor ressalta que o uso de imagens orbitais pode ser limitado por condições climáticas adversas, como a presença de nuvens.

Essa limitação também foi discutida por Moriya (2015), que, ao empregar sensores hiperespectrais embarcados em VANTs para detecção de doenças em cana-de-açúcar, destacou a importância das plataformas aéreas para superar as barreiras impostas por imagens orbitais. O estudo evidenciou a relevância da calibração radiométrica e da seleção adequada de bandas espectrais para a identificação precoce de alterações fisiológicas nas plantas.

A aplicação do sensoriamento remoto combinada com inteligência artificial também tem sido explorada em pesquisas recentes. Coelho (2024) desenvolveu uma metodologia inovadora para a previsão da massa de forragem em cultivares do gênero *Cynodon* utilizando imagens multiespectrais obtidas por drones e algoritmos de aprendizado de máquina, como Random Forest e SVM. Os modelos apresentados demonstraram alta acurácia na classificação das áreas e na estimativa da produtividade, destacando o potencial do SR como ferramenta preditiva no manejo forrageiro.

De forma complementar, Silva et al. (2025) utilizaram imagens RGB captadas por drones para estimar a altura e a matéria seca do capim-sudão (*Sorghum sudanense*). Os resultados indicaram forte correlação entre os índices espectrais calculados e as variáveis biofísicas da cultura, evidenciando que mesmo sensores simples e de baixo custo podem fornecer informações confiáveis para o manejo agrônomo de forrageiras.

A revisão de Tsouros et al. (2019) reforça essas constatações ao destacar as múltiplas aplicações dos UAVs na agricultura de precisão, enfatizando a variedade de sensores disponíveis e os benefícios operacionais associados ao uso dessas plataformas. Shiratsuchi et al. (2014), por sua vez, apresentam uma abordagem

abrangente sobre o sensoriamento remoto, descrevendo suas aplicações desde os conceitos básicos até os usos mais avançados na agricultura de precisão.

3.3 APLICAÇÕES DO SENSORIAMENTO REMOTO COM DADOS LIDAR NA AGRICULTURA

Com o avanço da agricultura de precisão, o sensoriamento remoto tem se destacado como uma das principais ferramentas para o monitoramento eficiente de culturas agrícolas. Entre as tecnologias disponíveis, o LiDAR (Light Detection and Ranging) tem se consolidado como uma solução inovadora e promissora, capaz de fornecer dados estruturais tridimensionais de alta resolução e acurácia, mesmo em condições adversas (RIVERA et al., 2023).

Ao contrário dos sensores ópticos passivos, que dependem da luz solar, o LiDAR opera como sensor ativo, emitindo pulsos de laser e medindo o tempo de retorno da luz refletida pela superfície das plantas ou do solo. Essa abordagem permite mapear com precisão atributos biofísicos da vegetação, como altura do dossel, volume de biomassa, estrutura interna, índice de área foliar (IAF) e variações espaciais de produtividade (ZHANG et al., 2021; GAO et al., 2022).

Rivera et al. (2023) classificam as aplicações do LiDAR em quatro grandes categorias: (i) estimativas métricas da cultura, (ii) digitalização tridimensional de plantas, (iii) detecção e navegação em campo, e (iv) apoio à tomada de decisão agrônoma. Essas aplicações vêm sendo amplamente exploradas em culturas como cana-de-açúcar, milho, sorgo, algodão e forrageiras tropicais, como o capim-elefante.

No contexto da fenotipagem vegetal, estudos como o de Jin et al. (2021) destacam que o LiDAR tem ampliado a capacidade de caracterização estrutural, permitindo avaliações não destrutivas da arquitetura de plantas, o que é essencial para programas de melhoramento genético. Esses autores também apontam que a integração de dados LiDAR com imagens espectrais e algoritmos de aprendizado profundo (deep learning) potencializa a predição de atributos agrônômicos com alta confiabilidade.

Na comparação entre LiDAR e fotogrametria baseada em imagens RGB, os resultados têm favorecido o primeiro. Maimaitijiang et al. (2020), por exemplo, demonstraram que, em áreas de cultivo de sorgo, o LiDAR apresentou melhor desempenho na estimativa de altura das plantas e IAF, sobretudo em estágios

avançados de desenvolvimento e em áreas com dossel denso. Resultados semelhantes foram obtidos por Zhou et al. (2020), ao monitorarem alterações na altura do milho acamado, obtendo coeficientes de determinação superiores a 0,96.

A tecnologia LiDAR também tem se mostrado eficaz na estimativa da variabilidade espacial da altura de culturas como o algodão (LIU et al., 2020), e no mapeamento da altura de pastagens, ajustando a distorção causada pelo ângulo de varredura do laser (XU et al., 2023). Em uma abordagem integrativa, Gao et al. (2022) combinaram dados LiDAR e imagens RGB para localizar e estimar com precisão a altura individual de plantas de milho no campo.

Além disso, o LiDAR tem sido empregado com sucesso na fenotipagem de culturas em parcelas experimentais, como evidenciado no estudo de Zang et al. (2021), em que o uso de LiDAR embarcado em VANTs permitiu estimar com precisão a altura média das plantas e o volume dos cultivos.

Ainda que os benefícios do LiDAR sejam amplamente reconhecidos — como a penetração no dossel e a independência de iluminação solar —, desafios como o alto custo dos equipamentos, a complexidade no processamento de nuvens de pontos e a necessidade de softwares específicos ainda limitam sua ampla adoção em propriedades agrícolas de menor escala (OMIA et al., 2023).

Entretanto, os desafios persistem. O custo elevado dos sensores LiDAR, a necessidade de algoritmos avançados para segmentação e análise de nuvens de pontos, bem como a integração com plataformas meteorológicas e espectrais, são barreiras apontadas na literatura. Apesar disso, a tendência é de democratização do uso, especialmente com o barateamento de UAVs e o desenvolvimento de softwares open source para processamento de dados.

Em resumo, a aplicação do sensoriamento remoto com LiDAR representa um avanço importante para a agricultura de precisão. A possibilidade de obter medições estruturais detalhadas e realizar análises automatizadas contribui diretamente para um manejo mais eficiente, sustentável e orientado por dados. Para culturas como o capim-elefante BRS Capiapu, reconhecido por sua elevada produtividade e valor forrageiro, o LiDAR surge como uma alternativa promissora para o monitoramento da biometria de forma não destrutiva e em larga escala, favorecendo a otimização das estratégias de colheita e manejo nutricional.


4 METODOLOGIA

4.1 LOCALIZAÇÃO DA ÁREA EXPERIMENTAL

O estudo foi conduzido em uma área experimental composta por cultivos da cultivar BRS Capiáu (*Pennisetum purpureum* Schum.), localizada na Universidade Federal Rural de Pernambuco (UFRPE), Unidade Acadêmica de Serra Talhada (UAST), no município de Serra Talhada – PE. A área experimental encontra-se nas coordenadas 7°58'20" S; 38°17'32" O, a uma altitude média de 499 metros acima do nível do mar (Figura 1).


Segundo a classificação climática de Köppen-Geiger, a região enquadra-se no tipo BSw'h', caracterizado como semiárido, quente e seco, com chuvas concentradas nos períodos de verão e outono, uma pluviosidade média anual de cerca de 632 mm e temperaturas médias superiores a 25 °C durante todo o ano (ALVARES et al., 2013; DUBREUIL et al., 2018).

Figura 1. Mapa de localização da área estudada



A área experimental foi organizada em quatro blocos, cada um composto por quatro parcelas, totalizando 16 parcelas experimentais, com quatro linhas de plantio por parcela (Figura 2). O cultivo foi implantado com espaçamento de 0,20 m entre plantas e 1,0 m entre linhas, e cada parcela apresentou dimensões de 5 m de comprimento por 4 m de largura, resultando em uma área de 20 m² por unidade experimental. Assim, a área total do experimento correspondeu a 320 m².

Figura 2. Parcelas e pontos amostrais da área de estudo



O sistema de irrigação adotado foi o de gotejamento, por ser mais eficiente e adequado às exigências hídricas do capim BRS Capiáçu, sobretudo nas condições semiáridas da região de Serra Talhada–PE. As parcelas foram submetidas a diferentes lâminas de irrigação, correspondentes a 50%, 75%, 100% e 125% da capacidade de campo, com o objetivo de avaliar a eficiência hídrica da cultura sob distintos níveis de disponibilidade de água no solo. A distribuição das lâminas ocorreu de forma diferenciada entre as parcelas, conforme os tratamentos estabelecidos.

Os gotejadores utilizados apresentaram vazão média de 1,59 L h⁻¹, operando sob pressão de 1 atm, e foram conectados a uma caixa d'água com capacidade de 5.000 litros, responsável pelo abastecimento das linhas de cultivo, com auxílio de uma bomba periférica.

A qualidade da água utilizada na irrigação foi monitorada, como a questão da condutividade elétrica, de forma a evitar efeitos negativos sobre o solo e a fisiologia da planta. Antes do início do experimento, foi avaliada a uniformidade de distribuição do sistema, segundo a metodologia de Keller e Karmeli (1974), medindo-se a vazão de 16 gotejadores em um tempo fixo, com três repetições.

O manejo da irrigação foi baseado na evapotranspiração da cultura (ET_c), calculada a partir da evapotranspiração de referência (ET₀), segundo o modelo Penman–Monteith, conforme recomendado pela FAO-56 (ALLEN et al., 1998). A equação utilizada é:

$$ET_0 = \frac{0.408 \cdot \Delta (R_n - G) + \gamma \cdot \frac{900}{T + 273} \cdot u_2 (e_s - e_a)}{\Delta + \gamma (1 + 0.34 \cdot u_2)}$$

onde:

- **ET₀**: evapotranspiração de referência (mm/dia)
- **R_n**: radiação líquida na superfície (MJ m⁻² dia⁻¹)
- **G**: fluxo de calor no solo (MJ·m⁻²·dia⁻¹)
- **T**: temperatura média do ar (°C)
- **u₂**: velocidade do vento a 2 m de altura (m/s)
- **e_s**: pressão de saturação de vapor (kPa)
- **e_a**: pressão de vapor atual (kPa)
- **Δ**: declividade da curva de pressão de vapor (kPa/°C)
- **γ**: constante psicrométrica (kPa/°C)

4.2 DADOS BIOMÉTRICOS

As avaliações biométricas foram realizadas no capim-elefante cv. BRS Capiáçu, após o terceiro corte da cultura, com o objetivo de acompanhar o crescimento vegetativo e o acúmulo de biomassa ao longo do novo ciclo produtivo. A primeira coleta ocorreu logo após o restabelecimento da rebrota, e as demais foram conduzidas em intervalos mensais, permitindo uma amplitude maior nos dados e evitando repetições desnecessárias em períodos de baixo crescimento, já que o desenvolvimento morfológico do capim é mais evidente em intervalos prolongados.

As medições foram executadas utilizando fita métrica, paquímetro digital e planilhas de campo específicas para o registro das variáveis observadas. Foram selecionadas duas plantas por parcela, escolhidas sempre nas linhas centrais de cultivo, com o intuito de eliminar o efeito de bordadura.

Plantas destinadas à biometria foram marcadas com fitas de cetim roxas, de modo a garantir a identificação visual e a repetição das medições nos mesmos indivíduos ao longo das diferentes campanhas de coleta. Foi avaliada a variável de altura das plantas.

A biomassa acima do solo foi estimada a partir da massa seca (MS) das plantas, obtida por amostragem destrutiva. Em cada parcela, duas plantas foram coletadas e secas até peso constante, sendo calculada a biomassa média por planta. Esse valor foi extrapolado para o total de plantas da parcela 100 plantas e, posteriormente, normalizado pela área da parcela (20 m^2), expressando a biomassa em kg m^{-2} . A utilização da massa seca mostrou-se mais adequada para a estimativa da biomassa e sua relação com métricas LiDAR, por representar de forma mais estável a estrutura do dossel vegetal, sem a interferência da umidade presente na massa fresca.

4.3 AQUISIÇÃO DE IMAGENS AÉREAS COM VANT

As coletas de imagens e dados provenientes do sensoriamento remoto foram realizadas com o uso de um veículo aéreo não tripulado (VANT) do tipo multirotor, modelo DJI Matrice 350

RTK.

O equipamento foi configurado com a carga útil necessária para voo, composta pela câmera Zenmuse L2, que integra um sistema LiDAR de alta precisão,

uma unidade de medição inercial (IMU) desenvolvida pela própria fabricante e uma câmera de mapeamento RGB CMOS 4/3. Essa combinação tecnológica permite a aquisição simultânea de informações multidimensionais, englobando dados estruturais e geométricos da vegetação, fornecendo produtos geoespaciais com elevada resolução e confiabilidade. (Dji enterprise, 2023)

Os voos foram realizados mensalmente, sempre nas mesmas datas das coletas biométricas em campo, de modo a permitir a correlação direta entre as informações tridimensionais e os parâmetros físicos observados nas plantas.

Para garantir o georreferenciamento preciso da área experimental e a compatibilidade espacial entre os dados obtidos em campo e os produtos derivados do sensoriamento remoto, foi utilizado um sistema GNSS com correção em tempo real (RTK – Real Time Kinematic).

O receptor base foi instalado em ponto fixo adjacente à área experimental, permanecendo ativo durante todo o período de aquisição dos dados e por mais duas horas após o término dos voos, prática recomendada para aumentar a estabilidade e a qualidade das correções diferenciais. Quanto maior o tempo de operação do RTK base, maior é a precisão do posicionamento geodésico obtido, pois o equipamento coleta um volume mais robusto de dados de satélite, reduzindo ruídos e incertezas nos cálculos de coordenadas.

De forma complementar, o sistema contou com o uso de um receptor RTK rover, empregado para a coleta de pontos de controle em campo. Esses pontos foram levantados diretamente sobre as plantas submetidas às análises biométricas, assegurando que as medições realizadas em campo estivessem espacialmente compatíveis com os produtos gerados a partir do sensoriamento remoto.

O receptor base permaneceu rastreando continuamente os sinais das principais constelações globais de navegação por satélite (GNSS) — GPS (EUA), BeiDou (China), Galileo (União Europeia) e GLONASS (Rússia). Essa integração de múltiplas constelações garantiu uma alta disponibilidade de satélites e precisão centimétrica nos dados coletados, assegurando a correspondência exata entre as coordenadas dos pontos de campo e os produtos gerados pelos voos, como as nuvens de pontos LiDAR tridimensionais.

4.4 PLANO DE VOO

Antes das missões de campo, foi definido um plano de voo padrão, elaborado diretamente no rádio controle da aeronave. O objetivo foi garantir a padronização entre os voos realizados ao longo do experimento, assegurando comparabilidade entre as campanhas de imageamento. O sensor LiDAR operou com capacidade de até cinco retornos por pulso, resultando em densidade estimada da nuvem de pontos de aproximadamente $1.555 \text{ pontos m}^{-2}$.

O voo foi realizado a uma altura de 20 metros em relação ao solo, valor escolhido para proporcionar uma alta resolução espacial das imagens e representar fielmente a estrutura do dossel da vegetação. Essa altura favorece a detecção de variações biométricas (como altura, densidade e volume do capim), além de reduzir distorções geométricas, facilitando a integração com as medições de campo.

O intervalo de captura entre as fotografias foi configurado para 1,02 segundos, resultando em uma cobertura densa de pontos e possibilitando a geração de modelos digitais de alta fidelidade. Foram adquiridas de quatro a seis linhas de voo para área de estudo, enquanto a velocidade média de deslocamento do VANT foi ajustada para $1,3 \text{ m s}^{-1}$, assegurando estabilidade de voo e evitando desfoques nas imagens.

O plano de voo foi configurado com sobreposição de 80% entre as faixas, tanto lateral quanto frontal, atendendo às recomendações metodológicas para mapeamentos agrícolas de alta precisão descritas por Tondato Arantes et al. (2021).

Os voos para aquisição dos dados LiDAR foram realizados em setembro, novembro e dezembro, sempre no período entre 12:00 e 14:00 h, faixa horária que favorece a uniformidade da iluminação solar e reduz a ocorrência de sombras projetadas. Embora o sensor LiDAR não dependa diretamente de condições óticas favoráveis para realizar as medições, é recomendado que os voos sejam executados em condições atmosféricas estáveis, a fim de evitar interferências operacionais e garantir a qualidade geral do levantamento.

Durante todas as campanhas, o céu apresentou-se predominantemente limpo, com baixa cobertura de nuvens visível a olho nu, e a velocidade do vento permaneceu abaixo de $10 \text{ m} \cdot \text{s}^{-1}$, conforme recomendações descritas por Dandois et al. (2015) para levantamentos aerofotogramétricos.

Os voos foram conduzidos no modo Visual Line of Sight (VLOS), obedecendo às orientações e requisitos operacionais estabelecidos pela Agência Nacional de Aviação Civil (ANAC) para pilotagem de Veículos Aéreos Não Tripulados (VANT).

4.5 PROCESSAMENTO DAS IMAGENS

O processamento inicial dos dados LiDAR foi realizado no software DJI Terra, o qual permite o tratamento e a organização de nuvens de pontos provenientes de sensores LiDAR, bem como a geração de produtos tridimensionais e raster. Nessa etapa, foram aplicados procedimentos de limpeza e otimização da nuvem de pontos, incluindo a remoção de ruídos e a organização dos retornos, visando garantir maior consistência e qualidade aos dados espaciais.

Durante o processamento, adotou-se alta densidade de pontos, possibilitando maior detalhamento da superfície do terreno e da estrutura da vegetação. A classificação inicial dos retornos foi conduzida por meio do método padrão do software, permitindo a distinção entre pontos correspondentes ao solo e à vegetação. As nuvens de pontos resultantes foram exportadas no formato LAS (.las), amplamente utilizado em aplicações LiDAR, assegurando compatibilidade com diferentes ambientes de processamento e elevada precisão espacial.

O georreferenciamento dos dados foi realizado com base em coordenadas obtidas por receptor GNSS, o qual apresenta precisão horizontal aproximada de $\pm 0,01$ m e precisão vertical de $\pm 0,02$ m. Esses dados foram utilizados para assegurar a acurácia posicional dos produtos gerados.

As etapas subsequentes de processamento foram conduzidas no ambiente R (R Core Team, 2023) com script automatizado, utilizando principalmente o pacote lidR, com apoio dos pacotes sf, terra, exactextractr e dplyr. Inicialmente, a nuvem de pontos LiDAR foi importada e submetida a uma verificação preliminar para assegurar sua integridade. Em seguida, foi carregado o polígono da área experimental, ajustando-se o sistema de referência de coordenadas para garantir compatibilidade espacial entre os dados vetoriais e a nuvem LiDAR. Para minimizar possíveis perdas de informação nas bordas da área de estudo, aplicou-se um buffer de 1 m ao polígono antes do recorte da nuvem de pontos.

Após o recorte, procedeu-se à remoção de ruídos presentes na nuvem de pontos por meio do algoritmo *Statistical Outlier Removal* (SOR), que identifica retornos

isolados com base na distância média em relação aos seus vizinhos mais próximos. Em seguida, a classificação dos pontos de terreno foi realizada utilizando o algoritmo *Cloth Simulation Filter* (CSF), método amplamente empregado para a separação entre retornos do solo e da vegetação.

Com os pontos de solo devidamente classificados, foi gerado o Modelo Digital do Terreno (MDT) por meio de interpolação baseada em *Triangulated Irregular Network* (TIN), adotando-se resolução espacial de 0,5 m. O MDT foi utilizado como referência altimétrica para a normalização da nuvem de pontos, procedimento realizado pela subtração da elevação do terreno da coordenada vertical (Z) de cada retorno LiDAR, permitindo a obtenção das alturas relativas da vegetação. Após a normalização, foram removidos pontos com valores negativos ou superiores a 3 m, considerando-se a altura máxima esperada para a cultura avaliada.

O Modelo Digital de Superfície (MDS) foi gerado a partir da nuvem de pontos original, utilizando o método *Point-to-Raster* (p2r), com resolução espacial de 0,5 m, representando a elevação máxima dos objetos presentes na superfície. O Modelo de Altura do Dossel (CHM) foi obtido a partir da nuvem de pontos normalizada, também pelo método p2r, com resolução de 0,25 m, visando maior detalhamento da estrutura do dossel. Valores negativos eventualmente gerados foram corrigidos, sendo ajustados para zero.

A extração das métricas LiDAR foi realizada com base nas coordenadas centrais das parcelas experimentais e das plantas georreferenciadas em campo. As métricas estruturais foram obtidas a partir da nuvem de pontos LiDAR normalizada e do Modelo de Altura do Dossel (CHM), utilizando o pacote lidR (Roussel et al., 2021).

Entre as métricas extraídas destacam-se a altura máxima (zmax), a altura média (zmean), os percentis de altura (zqx) e a proporção de retornos acima de limiares específicos, amplamente utilizados na literatura para a caracterização da estrutura vertical da vegetação e para a estimativa de atributos como altura do dossel e biomassa (Yip et al., 2024).

Tabela 1. Métricas tradicionais obtidas a partir de dados LiDAR

Tipo	Métrica	Descrição
Altura do dossel	zmax	Altura máxima dos retornos LiDAR
	zmean	Altura média da distribuição de alturas
	zsd	Desvio padrão da distribuição de alturas

Cobertura / estrutura do dossel	zskew	Assimetria da distribuição de alturas
	zkurt	Curtose da distribuição de alturas
	zqx (ex.: zq95, zq90, zq75)	Percentil x da distribuição de alturas
	zpcumx	Percentual cumulativo de retornos por camada vertical
	angle	Ângulo médio absoluto de varredura
	n	Número total de retornos LiDAR
	area	Área efetiva analisada
	pzabovemean	Percentual de retornos acima da altura média
	pzabovex	Percentual de retornos acima de uma altura de referência
	pground	Percentual de retornos classificados como solo
	pxth	Percentual do x-ésimo retorno
	zentropy	Entropia da distribuição vertical dos retornos
	itot	Soma total das intensidades
	imax	Intensidade máxima
	imean	Intensidade média
Intensidade (estrutura)	isd	Desvio padrão da intensidade
	iskew	Assimetria da intensidade
	ikurt	Curtose da intensidade
	ipground	Percentual da intensidade retornada pelo solo
	ipcumzqx	Intensidade acumulada abaixo de um percentil de altura
	ip1st	Intensidade associada ao primeiro retorno
	ip2nd	Intensidade associada ao segundo retorno
	ip3rd	Intensidade associada ao terceiro retorno
	ipxth	Intensidade associada ao x-ésimo retorno

Fonte: Elaboração própria, 2026.

4.6 ANÁLISE ESTATÍSTICA E MODELAGEM

A análise estatística foi conduzida no ambiente RStudio, por meio da linguagem de programação R, assegurando a integridade dos dados numéricos e evitando problemas de conversão de formato e separador decimal comumente associados ao uso de planilhas eletrônicas. Inicialmente, realizou-se uma análise descritiva, contemplando medidas de tendência central e de dispersão, com o objetivo de

caracterizar a variabilidade das alturas biométricas e das métricas estruturais derivadas do LiDAR.

Entre as métricas extraídas da nuvem de pontos LiDAR, o percentil 95 da distribuição de alturas (zq95) foi selecionado como principal variável explicativa da altura biométrica das plantas, por representar de forma mais adequada o topo do dossel e apresentar menor sensibilidade a valores extremos quando comparado à altura máxima (zmax). As demais métricas LiDAR foram avaliadas de maneira exploratória, sendo o zq95 adotado nas análises principais em função de seu melhor desempenho e maior robustez.

A capacidade do LiDAR em estimar a altura das plantas foi avaliada a partir da relação entre as estimativas obtidas pela métrica zq95 e as medições biométricas realizadas em campo, consideradas como referência. Essa relação foi analisada por meio de modelos de regressão, nos quais a altura biométrica foi considerada como variável dependente e a métrica zq95 como variável independente.

Para a estimativa da biomassa acima do solo (AGB), foram consideradas múltiplas métricas estruturais derivadas da nuvem de pontos LiDAR. A seleção das variáveis explicativas foi realizada por meio do algoritmo Boruta (Kursa; Rudnicki, 2022), baseado no método Random Forest, com o objetivo de identificar as métricas mais relevantes na explicação da variabilidade da biomassa medida em campo. Após essa etapa, as métricas mais importantes foram integradas no ambiente R juntamente com as medições de AGB de campo, sendo utilizadas para o ajuste de um modelo de regressão múltipla para a estimativa da biomassa a partir das métricas.

O desempenho das estimativas de altura e de biomassa foi avaliado por meio do coeficiente de determinação (R^2), do erro quadrático médio da raiz (RMSE) e do índice de concordância de Willmott (d), calculados conforme as Equações (1), (2) e (3). O coeficiente R^2 expressa a proporção da variabilidade da variável resposta explicada pelo modelo, o RMSE quantifica o erro médio de predição e o índice d indica o grau de concordância entre os valores observados em campo e aqueles estimados a partir das métricas LiDAR.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad 1.$$

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

$$d = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (|\hat{y}_i - \bar{y}| + |y_i - \bar{y}|)^2} \quad 3.$$

Onde:

- y_i = Valor observado na i-ésima observação
- $\hat{y}_i$ = Valor estimado ou simulado na i-ésima observação
- $\bar{y}$ = Média dos valores observados
- $\sum$ = Somatório para todos os dados
- n = Número total de observações,

5 RESULTADOS E DISCUSSÕES

5.1 ALTURA DO CAPIAÇU

5.1.1 Análise Descritiva Dos Dados

A estatística descritiva da altura biométrica e da métrica zq 95 evidenciou variação temporal ao longo dos três períodos de avaliação (Tabela 2). Verificou-se incremento da altura média das plantas ao longo do ciclo, acompanhado pelo aumento dos valores médios do sensor, indicando a capacidade do mesmo em representar a evolução da estrutura vertical do dossel.

Observou-se aumento dos valores de desvio-padrão para ambas as variáveis nos períodos mais avançados, sugerindo maior heterogeneidade entre parcelas e blocos experimentais. Esses resultados subsidiam a análise da relação entre as estimativas obtidas por LiDAR e as medições biométricas em campo,

Tabela 2. Análise descritiva dos dados de Biometria e da métrica LIDAR


Parâmetros Estatísticas	BIOMETRIA (m)			LIDAR		
	SETEMBRO	NOVEMBRO	DEZEMBRO	SETEMBRO	NOVEMBRO	DEZEMBRO
Mínimo	0,8	0,95	0,77	0,178	0,4	0,42
Máximo	1,49	2,3	2,3	0,735	1,75	1,94
Média	1,08	1,43	1,49	0,41	1,01	1,07
Desvio-padrão	0,15	0,34	0,41	0,12	0,32	0,36

Fonte: Elaboração própria, 2026.

5.1.2 Avaliação Da Correlação

No mês de setembro (Figura 3), correspondente ao período logo após a rebrota, observou-se correlação fraca entre a altura medida em campo e a métrica LiDAR zq95, com maior dispersão dos pontos em torno da linha de regressão. Esse comportamento é refletido no valor de $R^2 = 0,375$, indicando que pouco mais de um terço da variação da altura biométrica foi explicada pelos dados obtidos pelo sensor LiDAR nesse período.

Figura 3. Relação entre altura biométrica medida em campo e a métrica LiDAR em setembro




Fonte: Elaboração própria, 2026.

Visualmente, nota-se que os pontos apresentam maior espalhamento, evidenciando menor precisão das estimativas. Esse resultado está associado ao baixo porte da cultura após a rebrota, quando a área do dossel ainda é reduzida, dificultando a adequada caracterização da estrutura vertical pelo LiDAR. Estudos anteriores indicam que, em vegetação baixa, o LiDAR pode subestimar a altura real devido à menor densidade de retornos acima do solo, o que reduz temporariamente a capacidade preditiva das métricas de altura (Xu et al., 2023; Kafle & Kankare et al., 2025).

Apesar disso, o RMSE de 0,118 m mostra que o erro absoluto ainda foi relativamente baixo, e o índice de Willmott ($d = 0,72$) indica uma concordância moderada entre os valores observados e estimados. Esses resultados mostram que, mesmo no início da rebrota, o LiDAR já consegue captar parte da variabilidade da altura, embora com limitações naturais associadas ao baixo porte da cultura.

No mês de novembro (Figura 4), observou-se correlação positiva significativa entre a altura biométrica medida em campo e a métrica LiDAR zq95. O valor de $R^2 = 0,771$ indica que aproximadamente 77% da variação da altura em campo foi explicada pelo sensor LiDAR, evidenciando um ajuste muito mais consistente quando comparado ao mês de setembro.

Figura 4. Relação entre altura biométrica medida em campo e a métrica LIDAR em novembro.




Fonte: Elaboração própria, 2026.

Essa melhoria é facilmente percebida no gráfico, no qual os pontos se concentram mais próximos da linha de regressão, indicando maior estabilidade e confiabilidade das estimativas. A equação da reta apresenta coeficiente angular próximo de 1, mostrando que as variações detectadas pelo LiDAR acompanham de forma proporcional o crescimento real da cultura.

O RMSE de 0,158 m, embora superior ao observado em setembro, pode estar associado ao maior porte da cultura e ao aumento da amplitude dos valores de altura. Ainda assim, o índice de Willmott ($d = 0,931$) indica elevada concordância entre os valores estimados e observados.

De forma semelhante, no mês de dezembro (Figura 5), os resultados mantiveram o bom desempenho observado em novembro. O coeficiente de determinação $R^2 = 0,784$ foi o mais elevado entre os três períodos, indicando excelente capacidade explicativa da métrica LiDAR. A equação da regressão apresentou coeficiente angular praticamente igual à unidade, evidenciando forte correspondência entre as alturas estimadas pelo LiDAR e aquelas medidas em campo.

Figura 5. Relação entre altura biométrica medida em campo e a métrica LIDAR em dezembro.




Fonte: Elaboração própria, 2026.

Embora o RMSE tenha aumentado para 0,185 m, esse comportamento é esperado em função do maior crescimento da cultura. Walter et al. (2019) demonstraram que a precisão das estimativas de altura por LiDAR em culturas agrícolas tende a aumentar com o desenvolvimento da planta, especialmente quando o dossel passa a oferecer maior quantidade de retornos superiores relevantes. Ainda assim, o índice de Willmott permaneceu elevado ($d = 0,936$), indicando que o aumento do erro absoluto não comprometeu a concordância geral entre os métodos.

5.1.3 Distribuição Espacial Das Métricas Por Bloco Experimental

A análise conjunta das distribuições por bloco evidencia que a variabilidade da altura esteve presente em todos os períodos de avaliação, tanto nas medições de campo quanto nas estimativas obtidas por LiDAR. No mês de setembro, quando a cultura ainda apresentava menor porte, observou-se maior dispersão dos valores dentro dos blocos, especialmente para a métrica LiDAR, indicando maior limitação do sensor em representar um dossel ainda pouco estruturado. (Figura 6)

Figura 6. Relação da distribuição: (A) setembro – distribuição da altura biométrica; (B) setembro – distribuição da métrica LiDAR; (C) novembro – distribuição da altura biométrica; (D) novembro – distribuição da métrica LiDAR; (E) dezembro – distribuição da altura biométrica; (F) dezembro – distribuição da métrica LiDAR.



Fonte: Elaboração própria, 2026.


Nos meses de novembro e dezembro, com o avanço do desenvolvimento vegetativo, as distribuições tornam-se mais consistentes e organizadas, com redução da assimetria e maior proximidade entre os padrões observados nos dados de campo e nas estimativas LiDAR. Esse comportamento sugere que, à medida que o dossel se

torna mais contínuo e estruturalmente complexo, o LiDAR passa a representar com maior estabilidade tanto a magnitude da altura quanto sua variação espacial entre os blocos, complementando os resultados obtidos pela análise de regressão e reforçando o potencial do sensor para o monitoramento da altura da cultura ao longo do ciclo de desenvolvimento.

5.1.4 Correlação Global Integrada

A análise da correlação global, construída a partir da integração dos dados de setembro, novembro e dezembro em uma única avaliação, permite analisar o desempenho do LiDAR de forma contínua ao longo do ciclo de desenvolvimento da cultura (Figura 7). O coeficiente de determinação global ($R^2 = 0,77$) indica que grande parte da variabilidade da altura biométrica medida em campo é explicada pelas estimativas derivadas do LiDAR, mesmo diante das diferenças estruturais do dossel observadas entre os períodos avaliados.

Figura 7. Relação global entre alturas medidas em campo e a estimada pelo LiDAR (Zq95), considerando conjuntamente os períodos de setembro, novembro e dezembro. A linha representa o ajuste de regressão linear global, e os indicadores estatísticos (R^2 , RSME e d)



Fonte: Elaboração própria, 2026.

Embora esse valor pudesse ser mais elevado, a dispersão observada pode estar relacionada a fatores operacionais do levantamento LiDAR, bem como a características intrínsecas da cultura ou a fatores externos não considerados na análise. Nesse sentido, Xu et al. (2023) destacam que aspectos associados à


geometria de aquisição dos dados, como o ângulo de varredura do sensor, podem influenciar as estimativas de altura, contribuindo para a redução do ajuste estatístico.

Apesar disso, os valores de *RMSE* (0,17 m) e do índice de concordância de Willmott ($d = 0,93$) indicam boa concordância entre os valores estimados e observados, evidenciando desempenho satisfatório do modelo ao longo dos diferentes períodos avaliados. Resultados semelhantes foram relatados por Dhami et al. (2020) e Zhou et al. (2020), que observaram desempenho consistente do LiDAR na estimativa da altura de culturas agrícolas, mesmo diante de variações estruturais do dossel e das condições de aquisição. Assim, a análise global complementa as regressões realizadas individualmente por mês e confirma o potencial do LiDAR para o monitoramento estrutural da cultura de forma integrada e temporalmente consistente

5.2 SELEÇÃO DAS VARIÁVEIS

A análise e importância das variáveis, realizada por meio do algoritmo Boruta, indicou que a estimativa da biomassa foi mais influenciada por métricas associadas à altura e à estrutura vertical do dossel (Figura 8). Observou-se maior destaque para a altura máxima (z_{max}) e para os percentis superiores de altura ($zq80$, $zq85$ e $zq90$), indicando que parcelas com maiores valores nessas métricas apresentaram maior contribuição para a variação da AGB. O desvio padrão das alturas (isd) também apareceu entre as métricas mais importantes, evidenciando que a variação vertical do dossel está relacionada ao acúmulo de biomassa. Por outro lado, métricas como a assimetria da distribuição de alturas ($zskew$) e a curtose da intensidade dos retornos ($zkurt$) apresentaram baixa importância, indicando menor influência dessas variáveis na explicação da biomassa observada. Essa seleção é amplamente reconhecida como adequada para determinar biomassa (Zhang et al., 2024)

Figura 8. Seleção de métricas LIDAR pelo pacote Boruta.



Fonte: Elaboração própria, 2026.

5.3 MODELAGEM DA BIOMASSA USANDO O LIDAR

Às 16 métricas LiDAR previamente selecionadas como importantes foram utilizadas na etapa de modelagem da biomassa. Após o ajuste do modelo e a avaliação da contribuição individual das variáveis, apenas seis métricas permaneceram na equação final, formando um modelo mais complexo composto por z_{max} , z_{mean} , isd , zsd , $zskew$ e $zpcum3$. equação (4).


$$AGB = -2,011 + 0,0001346 \times z_{max} + 0,8125 \times z_{mean} - 5,683 \times zsd + 2,53 \times 10^{-8} \times zskew - 2,33 \times 10^{-7} \times zpcum + 3,064 \times 10^{-7} \times isd$$

4.

Os gráficos de diagnóstico do modelo indicam que a equação ajustada, composta pelas métricas LiDAR previamente selecionadas, apresentou desempenho estatisticamente adequado para a estimativa da biomassa acima do solo. O gráfico de resíduos em função dos valores ajustados demonstra distribuição aleatória dos resíduos em torno de zero, sem padrões definidos, sugerindo que a relação linear

assumida entre as variáveis explicativas e a AGB foi satisfatoriamente atendida. De forma complementar, o gráfico Q-Q aponta que os resíduos seguem, de modo geral, a distribuição normal, com leves desvios nas extremidades, comportamento comum em dados ambientais. (Figura 9).

Figura 9. Diagnósticos dos resíduos




Fonte: Elaboração própria, 2026.

O gráfico Scale-Location evidencia variância aproximadamente constante dos resíduos ao longo dos valores ajustados, indicando homocedasticidade, enquanto o gráfico de resíduos versus alavancagem não revela observações com influência excessiva sobre o modelo, conforme os limites da distância de Cook. Esses resultados reforçam a consistência do modelo final. (Figura 9).

Os resultados obtidos com o modelo ajustado indicam desempenho excelentes na estimativa da biomassa, evidenciado pela forte concordância entre os valores estimados e aqueles medidos em campo. Observa-se que a maior parte dos pontos apresenta distribuição próxima à linha 1:1, o que demonstra a capacidade do modelo em representar adequadamente a variabilidade da AGB observada. O elevado coeficiente de determinação ($R^2 = 0,946$) indica que grande parte da variação da

biomassa medida em campo é explicada pelas métricas estruturais selecionadas, enquanto o baixo valor de erro médio ($RMSE = 0,041 \text{ kg m}^{-2}$) reforça a precisão das estimativas obtidas (Figura 10).

Figura 10. Ajuste do modelo da biomassa e a medida observada em campo



Fonte: Elaboração própria, 2026.

Para complementar, o alto índice de concordância de Willmott ($d = 0,986$) evidência elevada consistência entre os valores estimados e observados, confirmando o bom ajuste do modelo proposto. Resultados semelhantes foram observados por Rodrigues (2025), ao empregar a fusão de dados LiDAR e hiperespectrais para estimativa da biomassa acima do solo, destacando a relevância de métricas estruturais na explicação da biomassa. De forma complementar, Walter et al. (2019), ao avaliarem o uso de dados LiDAR em culturas agrícolas, também relataram elevados coeficientes de determinação e baixos erros de estimativa, reforçando que atributos relacionados à estrutura vertical da vegetação apresentam forte relação com a biomassa acima do solo. Assim, os resultados obtidos neste estudo estão em consonância com a literatura, evidenciando a adequação da abordagem adotada para a estimativa da biomassa acima do solo.

6 CONCLUSÃO

Os resultados demonstraram que métricas estruturais derivadas de dados LiDAR embarcados em VANT são capazes de descrever com precisão a altura e a biomassa acima do solo do capim-elefante BRS Capiáçu. As estimativas de altura apresentaram bom ajuste com as medições de campo, com R^2 global de 0,77 e RMSE de 0,17 m, evidenciando a capacidade do LiDAR em representar a variação estrutural do dossel ao longo do ciclo produtivo.

O principal achado do estudo foi que o modelo de regressão múltipla, que utiliza métricas LiDAR como variáveis de entrada, demonstrou elevada capacidade para descrever o acúmulo de biomassa do capim-elefante BRS Capiáçu, alcançando R^2 superior a 0,90, RMSE de 0,041 kg m⁻² e alto índice de concordância. Esses resultados confirmam que as métricas estruturais extraídas da nuvem de pontos foram suficientes para explicar a maior parte da variabilidade da biomassa observada em campo.

Outro resultado relevante foi que, à medida que a altura do capim aumentou, a relação entre as estimativas LiDAR e as medições de campo tornou-se mais consistente, indicando maior capacidade do sensor em descrever o dossel em estádios mais avançados de desenvolvimento.

De forma geral, o estudo confirma o potencial do LiDAR como ferramenta eficiente para o monitoramento não destrutivo do crescimento e da produtividade do capim-elefante BRS Capiáçu, consolidando sua aplicação no manejo forrageiro e em estudos de agricultura de precisão no semiárido.

7 REFERÊNCIAS

- ALVARES, C. A. et al. Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, v. 22, n. 6, p. 711–728, 2013.
- ALVES, Joyce Pereira. *Potencial forrageiro das cultivares BRS Kurumi e BRS Capiaçu*. 2021. 92 f. Dissertação (Mestrado em Zootecnia) – Universidade Federal da Grande Dourados, Dourados, MS, 2021. Disponível em: <http://repositorio.ufgd.edu.br/jspui/handle/prefix/4589>.
- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. *Evapotranspiração das culturas: Diretrizes para o cálculo das necessidades hídricas das culturas*; Organização das Nações Unidas para a Alimentação e a Agricultura: Roma, Itália, 1998.
- ANDRADE, J. S. C. de O.; PESSOA, C. A. S.; SILVA, J. B. L. da; SILVA, T. G. F. da; CAVALCANTE, A. C. R.; ZOLIN, C. A. Assinatura espectral da palma forrageira sob diferentes idades de cultivo no semiárido pernambucano. *Revista Brasileira de Agricultura Irrigada*, v. 19, n. 1, p. 58–72, 2025. DOI: <https://periodicos.ufrn.br/revistadoregne/article/view/37541>
- ANDRADE, OBd; Montenegro, AAdA; Silva Neto, MAd; Sousa, LdBd; Almeida, TAB; de Lima, JIMP; Carvalho, AAd; Silva, MVd; Medeiros, VWCd; Soares, RGF; et al. Classificação de palma forrageira consorciada baseada em VANT: uma comparação entre espaços amostrais RGB e multiespectral usando aprendizado de máquina em uma área irrigada. *AgriEngineering* 2024, 6, 509-525. <https://doi.org/10.3390/agriengineering6010031>
- AVNERI, Asaf et al. UAS-based imaging for prediction of chickpea crop biophysical parameters and yield. *Computers and Electronics in Agriculture*, v. 200, p. 107581, 2022. Disponível em: <https://doi.org/10.1016/j.compag.2022.107581>.
- BARIONI, Luiz Gustavo; FERREIRA, Ana Carolina. Monitoramento da massa da forragem e altura para ajuste da taxa de lotação em fazenda agropecuária na região do Serrado. *Boletim de Pesquisa e Desenvolvimento*, ISSN 1676-918X, out. 2007.
- BRASIL. Ministério da Integração Nacional. Nova delimitação do Semiárido brasileiro. Brasília, DF, 2024.
- BRASIL*. Ministério da Agricultura e Pecuária. Carne bovina é um dos principais produtos pecuários nas exportações brasileiras. Brasília, 14 out. 2024.
- COELHO, Rigles Maia. *Caracterização do estabelecimento e previsão da massa de forragem de pastos de capins Cynodon spp. por sensoriamento remoto*. 2024(Mestrado em Zootecnia) – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2024. Disponível em: <https://doi.org/10.11606/D.11.2024.tde-08102024-162721>.
- DANDOIS, J.; OLANO, M.; ELLIS, E. Optimal Altitude, Overlap, and Weather Conditions for Computer Vision UAV Estimates of Forest Structure. *Remote Sensing*, v. 7, n. 10, p.13895–13920, 2015. Disponível em: <https://www.mdpi.com/2072-4292/7/10/13895>.

DHAMI, Harnaik et al. Crop height and plot estimation for phenotyping from unmanned aerial vehicles using 3D LiDAR. In: *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, Las Vegas, 2020. p. 2643–2649. Disponível em: <https://doi.org/10.1109/IROS45743.2020.9341343>.

DJI ENTERPRISE. Zenmuse L2: LiDAR + Câmera RGB de Alta Precisão. [S.l.]: DJI, [202?]. Disponível em: <https://enterprise.dji.com/pt-br/zenmuse-l2>. Acesso em: 16 nov. 2025.

DJI ENTERPRISE. Zenmuse L2: LiDAR + Câmera RGB de Alta Precisão. [S.l.]: DJI, [202?]. Disponível em: <https://enterprise.dji.com/pt-br/zenmuse-l2>. Acesso em: 16 nov. 2025.

DUBREUIL, V. et al. Climate change evidence in Brazil from Köppen's climate annual types frequency. *International Journal of Climatology*, v. 1, p. 1-14, 2018. DOI: 10.1002/joc.5893.

FAN, Xinyan et al. Low-cost visible and near-infrared camera on an unmanned aerial vehicle for assessing the herbage biomass and leaf area index in an Italian ryegrass field. *Grassland Science*, v. 63, n. 4, p. 179–193, 2017. Disponível em: <https://doi.org/10.1111/grs.12184>.

GAO, Min et al. Estimativa de localização e altura individual de milho em campo a partir de imagens LiDAR e RGB transportadas por UAV. *Remote Sensing*, v. 14, n. 10, p. 2292, 2022. Disponível em: <https://doi.org/10.3390/rs14102292>.

GEIPEL, J. et al. Forage yield and quality estimation by means of UAV and hyperspectral imaging. *Precision Agriculture*, v. 22, p. 1437–1463, 2021. Disponível em: <https://doi.org/10.1007/s11119-021-09790-2>.

GRÜNER, Ester et al. Previsão de biomassa em pastagens temperadas heterogêneas usando uma abordagem SfM baseada em imagens de UAV. *Agronomy*, v. 9, n. 2, p. 54, 2019. Disponível em: <https://doi.org/10.3390/agronomy9020054>.

JIN, Shichao et al. LiDAR lança nova luz sobre a fenômica de plantas para melhoramento e manejo de plantas: avanços recentes e perspectivas futuras. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 171, p. 202–223, 2021. Disponível em: <https://doi.org/10.1016/j.isprsjprs.2020.11.006>.

KAFLE, B.; KANKARE, V.; KAARTINEN, H.; VÄÄTÄINEN, K.; HYYTI, H.; FAITLI, T.; HYYPPÄ, J.; KUKKO, A.; KÄRHÄ, K. Assessing the consistency of low vegetation characteristics estimated using harvester, handheld, and drone light detection and ranging (LiDAR) systems. *Silva Fennica*, Helsinque, v. 59, n. 2, art. 25013, 2025. DOI: <https://doi.org/10.14214/sf.25013>

KELLER, J.; KARMELI, D. Trickle irrigation design parameters. *Transactions of the ASAE*, v. 17, p. 678-684, 1974.

KURSA, Miron B.; RUDNICKI, Witold R. Feature selection with the Boruta package. *Journal of Statistical Software*, Vienna, v. 36, n. 11, p. 1–13, 2010. Atualizado em 2022.

LIU, Kuan; DONG, Xiaoya; QIU, Baijing. Analysis of cotton height spatial variability based on UAV-LiDAR. *International Journal of Precision Agriculture Aviation*, v. 3, n. 3, p. 72–76, 2020. Disponível em: <https://doi.org/10.33440/j.ijpaa.20200303.79>.

MAIMAITIJIANG, M. et al. Monitoramento do crescimento de sorgo por VANT: uma análise comparativa de LiDAR e fotogrametria. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v. V-3-2020, p. 489–496, 2020. Disponível em: <https://doi.org/10.5194/isprs-annals-V-3-2020-489-2020>.

MARTELLO, Maurício. *Controle automático de irrigação por meio de sensores capacitivos para manutenção do nível de umidade do solo*. 2017. Dissertação (Mestrado em Engenharia de Sistemas Agrícolas) – Escola Superior de Agricultura Luiz de Queiroz, Piracicaba, 2017. Disponível em: <https://doi.org/10.11606/D.11.2017.tde-16102017-170204>.

MONÇÃO, F. P. et al. Yield and nutritional value of BRS Capião grass at different regrowth ages / Produtividade e valor nutricional do Capim-Elefante cv. BRS Capião em diferentes idades de rebrota. *Semina: Ciências Agrárias*, v. 40, n. 5, p. 2045–2056, 2019. Disponível em: <https://doi.org/10.5433/1679-0359.2019v40n5p2045>.

MORIYA, Érika Akemi Saito. *Identificação de bandas espectrais para detecção de cultura de cana-de-açúcar sadia e doente utilizando câmara hiperespectral embarcada em VANT*. 2015. 147 f. Tese (Doutorado em Ciências Cartográficas) – UNESP, Presidente Prudente, 2015. Disponível em: <https://repositorio.unesp.br/server/api/core/bitstreams/2ae6a7b9-b720-407c-9572-ff126943adf5/content>.

MOURA, M. M. A. et al. Estratégias de manejo para a cultivar BRS Capião: uma revisão de literatura. *Brazilian Journal of Animal and Environmental Research*, v. 7, n. 2, p. 1425–1437, 2024. Disponível em: <https://doi.org/10.34188/bjaerv7n2-052>.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS PARA A ALIMENTAÇÃO E A AGRICULTURA (FAO). Resiliência ajudou agricultores do semiárido brasileiro a enfrentar crises. Brasília, DF: FAO, 2021. Disponível em: <https://brasil.un.org/pt-br/146392-fao-aponta-que-resili%C3%Aancia-ajudou-agricultores-do-semi%C3%A1rido-na-pandemia>.

OMIA, Emmanuel et al. Remote sensing in field crop monitoring: a comprehensive review of sensor systems, data analyses and recent advances. *Remote Sensing*, v. 15, n. 2, p. 354, 2023. Disponível em: <https://doi.org/10.3390/rs15020354>.

OLIVEIRA, H.F.E.; de Castro, L.E.V.; Sousa, C.M.; Alves Júnior, L.R.; Mesquita, M.; Silva, J.A.O.S.; Faria, L.C.; da Silva, M.V.; Giongo, P.R.; de Oliveira Júnior, J.F.; et al. Geotechnologies in Biophysical Analysis through the Applicability of the UAV and Sentinel-2A/MSI in Irrigated Area of Common Beans: Accuracy and Spatial Dynamics. *Remote Sens.* 2024, 16, 1254. <https://doi.org/10.3390/rs16071254>

PEREIRA, A. V. et al. BRS Kurumi and BRS Capião – New elephant grass cultivars for grazing and cut-and-carry system. *Crop Breeding and Applied Biotechnology*, v. 17, n. 1, p. 59–62, 2017. Disponível em: <https://doi.org/10.1590/1984-70332017v17n1c9>.

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.

(Comunicado Técnico, 79). Disponível em: <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1056288>.

PESSANHA, Mariane dos Santos. *Biometria e índices de vegetação por sensoriamento remoto em área de pastagem no município de Cachoeiras de Macacu, RJ*. 2020. 63 f. Dissertação (Mestrado em Engenharia Agrícola e Ambiental) – UFRRJ, Seropédica, RJ, 2020. Disponível em: <https://tede.ufrrj.br/jspui/handle/jspui/6289>.

RETORE, M. et al. *Manejo do capim BRS Capiáçu para aliar produtividade à qualidade*. 2021. Disponível em: <http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1134720>.

RIVERA, Gilberto et al. LiDAR applications in precision agriculture for cultivating crops: a review of recent advances. *Computers and Electronics in Agriculture*, v. 205, p. 107737, 2023. Disponível em: <https://doi.org/10.1016/j.compag.2023.107737>.

ROSA, P. P. et al. Características do capim-elefante *Pennisetum purpureum* (Schumach) e suas novas cultivares BRS Kurumi e BRS Capiáçu. *Pesquisa Agropecuária Gaúcha*, v. 25, n. 1, p. 270–284, 2019. Disponível em: <https://doi.org/10.36812/pag.2019251/270-84>.

SHIRATSUCHI, L. S. et al. Sensoriamento remoto: conceitos básicos e aplicações na agricultura de precisão. In: BERNARDI, A. C. C. et al. *Agricultura de precisão: resultados de um novo olhar*. Brasília, DF: Embrapa, 2014. p. 58–73. Disponível em: <https://www.researchgate.net/publication/269633209>.

SILVA, H. F. da et al. ESTIMATIVA DE PARÂMETROS BIOFÍSICOS DE CAPIM-SUDÃO (*Sorghum sudanense* L.) POR ANÁLISE ESPECTRAL A PARTIR DE IMAGENS DE DRONE. *Journal of Media Critiques*, v. 11, n. 27, e217, 2025. <https://doi.org/10.17349/jmcv11n27-025>

SILVA, G.I.N.d.; Jardim, A.M.d.R.F.; Santos, W.M.d.; Bezerra, A.C.; Alba, E.; Silva, M.V.d.; Silva, J.L.B.d.; Souza, L.S.B.d.; Marinho, G.T.B.; Montenegro, A.A.d.A.; et al. Estimation of Biophysical Parameters of Forage Cactus Under Different Agricultural Systems Through Vegetation Indices and Machine Learning Using RGB Images Acquired with Unmanned Aerial Vehicles. *Agriculture* 2024, 14, 2166. <https://doi.org/10.3390/agriculture14122166>

SILVA, A. F. et al. Agricultura familiar dependente de chuva no Semiárido brasileiro. Brasília, DF: Embrapa, 2019. Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/bitstream/doc/1114220/1/Agriculturafamiliardependentedechuvanosemiarido2019.pdf>

SOFONIA, Jeremy et al. Monitoramento da resposta do crescimento da cana-de-açúcar a diferentes taxas de aplicação de nitrogênio: uma comparação entre UAV SLAM LiDAR e fotogrametria. *International Journal of Applied Earth Observation and Geoinformation*, v. 80, p. 71–82, 2019. Disponível em: <https://doi.org/10.1016/j.jag.2019.05.011>.

TSOUROS, D. C.; BIBI, S.; SARIGIANNIDIS, P. G. A review on UAV-based applications for precision agriculture. *Information*, v. 10, n. 11, p. 349, 2019. Disponível em: <https://doi.org/10.3390/info10110349>.

WANG, Xiaoxue et al. Monitoramento do índice de área foliar da pastagem semeada consorciada por meio de imagem multiespectral de VANT e características de textura.

Computers and Electronics in Agriculture, v. 209, p. 108333, 2023. Disponível em: <https://doi.org/10.1016/j.compag.2023.108333>.

WALTER, J. D. C.; EDWARDS, J.; McDONALD, G.; KUCHEL, H. Estimating biomass and canopy height with LiDAR for field crop breeding. *Frontiers in Plant Science*, Lausanne, v. 10, art. 1145, 2019. DOI: <https://doi.org/10.3389/fpls.2019.01145>

WILLMOTT, Cort J. On the validation of models. *Physical Geography*, v. 2, n. 2, p. 184–194, 1981. <http://dx.doi.org/10.1080/02723646.1981.10642213>.

WOEBBECKE, D. et al. Shape features for identifying young weeds using image analysis. *Transactions of the ASAE*, v. 38, n. 1, p. 271–281, 1995.

XU, Cong et al. Correction of UAV LiDAR-derived grassland canopy height based on scan angle. *Frontiers in Plant Science*, v. 14, p. 1108109, 2023. DOI: 10.3389/fpls.2023.1108109.

XU, C.; ZHAO, D.; ZHENG, Z.; ZHAO, P.; CHEN, J.; LI, X.; ZHAO, X.; ZHAO, Y.; LIU, W.; WU, B.; ZENG, Y. Correction of UAV LiDAR-derived grassland canopy height based on scan angle. *Frontiers in Plant Science*, Lausanne, v. 14, e1108109, 2023. DOI: <https://doi.org/10.3389/fpls.2023.1108109>

YIP, Ka Hei Anson; LIU, Rui; WU, Jin; HAU, Billy Chi Hang; LIN, Yinyi; ZHANG, Hongsheng. Community-based plant diversity monitoring in a species-rich tropical forest using airborne LiDAR data. *Ecological Indicators*, v. 158, p. 111346, jan. 2024.

ZHANG, Chongyuan et al. High-throughput phenotyping of canopy height in cool-season crops using sensing techniques. *Agronomy Journal*, v. 113, n. 2, p. 1501–1513, 2021. Disponível em: <https://doi.org/10.1002/agj2.20632>.

ZHANG, Xiaofang; et al. Forest above-ground biomass estimation based on strongly collinear variables derived from airborne laser scanning data. *Ecological Indicators*, v. 166, p. 112517, set. 2024.

ZHOU, Longfei et al. Análise de mudanças na altura das plantas de milho acamado usando dados UAV-LiDAR. *Agriculture*, v. 10, n. 5, p. 146, 2020. Disponível em: <https://doi.org/10.3390/agriculture10050146>.