

**UNIVERSIDADE FEDERAL DE VIÇOSA**

**Predições de características estruturais e valor nutritivo de *Urochloa decumbens* por meio de imagens aéreas**

Iuly Francisca Rodrigues de Souza  
*Magister Scientiae*

**VIÇOSA - MINAS GERAIS  
2024**

**IULY FRANCISCA RODRIGUES DE SOUZA**

**Predições de características estruturais e valor nutritivo de *Urochloa decumbens* por meio de imagens aéreas**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Zootecnia, para obtenção do título de *Magister Scientiae*.

Orientadora: Fernanda H. M. Chizzotti

Coorientador: Bruno Grossi Costa Homem

**VIÇOSA - MINAS GERAIS  
2024**

**Ficha catalográfica elaborada pela Biblioteca Central da Universidade  
Federal de Viçosa - Campus Viçosa**

T

S729p  
2024 Souza, Iuly Francisca Rodrigues de, 1996-  
Predições de características estruturais e valor nutritivo de  
*Urochloa decumbens* por meio de imagens aéreas / Iuly  
Francisca Rodrigues de Souza. – Viçosa, MG, 2024.  
1 dissertação eletrônica (53 f. ): il. (algumas color.).

Orientador: Fernanda Helena Martins Chizzotti.  
Dissertação (mestrado) - Universidade Federal de Viçosa,  
Departamento de Zootecnia, 2024.

Referências bibliográficas: f. 43-53.

DOI: <https://doi.org/10.47328/ufvbbt.2024.799>

Modo de acesso: World Wide Web.

1. Capim-branquiaria - Cultivo - Sensoriamento remoto.  
2. Aprendizado do computador. 3. Imagens multiespectrais.  
4. Vegetação - Mapeamento. I. Chizzotti, Fernanda Helena  
Martins, 1977-. II. Universidade Federal de Viçosa.  
Departamento de Zootecnia. Programa de Pós-Graduação em  
Zootecnia. III. Título.

CDD 22. ed. 633.2

**IULY FRANCISCA RODRIGUES DE SOUZA**

**Predições de características estruturais e valor nutritivo de *Urochloa decumbens* por meio de imagens aéreas**

Dissertação apresentada à Universidade Federal de Viçosa, como parte das exigências do Programa de Pós-Graduação em Zootecnia, para obtenção do título de *Magister Scientiae*.

APROVADA: 29 de agosto de 2024.

Assentimento:

---

Iuly Francisca Rodrigues de Souza  
Autora

---

Fernanda Helena Martins Chizzotti  
Orientadora

Essa dissertação foi assinada digitalmente pela autora em 17/12/2024 às 16:20:23 e pela orientadora em 17/12/2024 às 17:28:53. As assinaturas têm validade legal, conforme o disposto na Medida Provisória 2.200-2/2001 e na Resolução nº 37/2012 do CONARQ. Para conferir a autenticidade, acesse <https://siadoc.ufv.br/validar-documento>. No campo 'Código de registro', informe o código **2VTA.4UK3.RF1M** e clique no botão 'Validar documento'.

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus pela minha saúde e por estar comigo em todos os momentos da minha vida, me auxiliando a cada passo e me proporcionando aprender e melhorar a cada dia.

Aos meus pais e irmão que sempre me apoiaram em minhas escolhas, principalmente a minha mãe, que sempre me ajudou e me incentivou a batalhar pelos meus objetivos. Espero que um dia eu possa retribuir tudo o que ela fez e faz por mim.

Ao meu noivo pelos momentos de força, diálogo e descontração e por sempre me incentivar a dar o meu melhor.

Aos meus amigos pelos momentos de desabafo, acolhimento e sugestões.

Aos meus orientadores pelas discussões, ensinamentos e mentorias.

A Aureana e Filipe pela concessão do banco de dados experimentais e algumas imagens.

À Universidade Federal de Viçosa, pela oportunidade de realizar a pós-graduação.

Aos professores, colegas e servidores que tive o prazer de conviver ao longo do mestrado.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão da bolsa de estudos. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Enfim, obrigada a todos que contribuíram direta ou indiretamente para que o presente trabalho fosse desenvolvido.

## RESUMO

SOUZA, Iuly Francisca Rodrigues de, M.Sc., Universidade Federal de Viçosa, agosto de 2024. **Predições de características estruturais e valor nutritivo de *Urochloa decumbens* por meio de imagens aéreas.** Orientadora: Fernanda Helena Martins Chizzotti. Coorientador: Bruno Grossi Costa Homem.

O uso da inteligência artificial, aliado a técnicas de agricultura e zootecnia de precisão, está transformando o monitoramento e a gestão da agropecuária. O sensoriamento remoto, em particular, oferece uma solução inovadora para monitorar a variabilidade espaço-temporal em pastagens, fornecendo informações cruciais sobre diversos parâmetros biofísicos. Nesse contexto, o objetivo com este trabalho foi desenvolver modelos preditivos para a massa de forragem verde e seca, altura do dossel, densidade e concentração de matéria seca (%MS) e proteína bruta (%PB) de pastos de *Urochloa decumbens* (Stapf) R.D. Webster, utilizando aprendizado de máquinas e imagens multiespectrais obtidas por aeronave remotamente pilotada. O experimento foi conduzido na Universidade Federal de Viçosa, entre 2019 e 2020, com diferentes doses de nitrogênio aplicadas após cada corte, com o objetivo de promover variações nas características do capim. Foram avaliados o desempenho dos seguintes modelos: regressão linear simples (RLS), regressão linear múltipla (RLM), e random forest regression (RFR). Para isso, dados multiespectrais foram extraídos de imagens aéreas e combinados à dados meteorológicos para alimentar os modelos preditivos. Os modelos foram avaliados por meio de validação cruzada "Leave-one-out", utilizando métricas como coeficiente de determinação ( $R^2$ ), erro quadrático médio (RMSE) e erro absoluto médio (MAE). As melhores predições foram observadas para massa de forragem verde ( $R^2 = 0,77$ , RMSE = 3.281,29 kg ha<sup>-1</sup>, MAE = 2.361,80 kg ha<sup>-1</sup>) e seca ( $R^2 = 0,71$ , RMSE = 657,46 kg ha<sup>-1</sup>, MAE = 507,53 kg ha<sup>-1</sup>) com RLM, e altura do dossel com RLS ( $R^2 = 0,59$ , RMSE = 8,72 cm, MAE = 7,26 cm). As predições para % MS e % PB não apresentaram desempenho satisfatório para nenhum dos modelos avaliados. Conclui-se que a combinação de imagens aéreas multiespectrais com aprendizado de máquinas oferece uma ferramenta eficaz para prever variáveis como massa verde, massa seca e altura em pastos de capim-brachiaria, podendo contribuir significativamente para a gestão e o manejo das pastagens. Contudo, são necessárias mais pesquisas para otimizar os modelos desenvolvidos.

Palavras-chave: sensoriamento remoto; aprendizado de máquina; imagens multiespectrais; índices de vegetação

## ABSTRACT

SOUZA, Iuly Francisca Rodrigues de, M.Sc., Universidade Federal de Viçosa, August, 2024. **Predictions of structural characteristics and nutritive value of *Urochloa decumbens* using aerial image.** Adviser: Fernanda Helena Martins Chizzotti. Co-adviser: Bruno Grossi Costa Homem.

The use of artificial intelligence, combined with precision agriculture and livestock techniques, is transforming the monitoring and management of agricultural systems. Remote sensing offers an innovative solution for monitoring spatiotemporal variability in pastures, providing crucial information on various biophysical parameters. In this context, the objective of this study was to develop predictive models for fresh and dry forage mass, canopy height, density and dry matter (%DM) and crude protein concentrations (%CP) of signalgrass [*Urochloa decumbens* (Stapf) R.D. Webster] pastures, using machine learning and multispectral images obtained by an unmanned aerial vehicle (UAV). The experiment was conducted at the Federal University of Viçosa between 2019 and 2020, with different nitrogen doses applied after each cut to promote variations in grass characteristics. The performance of the following models was evaluated: simple linear regression (SLR), multiple linear regression (MLR), and random forest regression (RFR). Multispectral images were extracted and combined with meteorological data to feed the predictive models, which were evaluated using Leave-one-out cross-validation, and metrics such as the coefficient of determination ( $R^2$ ), root mean square error (RMSE) and mean absolute error (MAE). The best predictions were obtained for fresh forage mass ( $R^2 = 0.77$ , RMSE = 3,281.29 kg ha<sup>-1</sup>, MAE = 2,361.80 kg ha<sup>-1</sup>) and dry forage mass ( $R^2 = 0.71$ , RMSE = 657.46 kg ha<sup>-1</sup>, MAE = 507.53 kg ha<sup>-1</sup>) using MLR, and for canopy height using SLR ( $R^2 = 0.59$ , RMSE = 8.72 cm, MAE = 7.26 cm). Predictions for % DM and % CP were unsatisfactory. The findings demonstrate that combining multispectral imagery with machine learning effectively predicts forage mass and canopy height of signalgrass pastures, supporting improved grazing management, though further refinement of models is needed.

Keywords: remote sensing; machine learning; multispectral imagery; vegetation indices

## LISTA DE ILUSTRAÇÕES

Figura 1 - Área experimental de 0,7 ha de <i>Urochloa decumbens</i> localizada em Viçosa, MG.....	19
Figura 2 - Dados de precipitação acumulada e temperaturas médias em Viçosa, MG, entre 2019/2020.....	20
Figuras 3 e 4 - Drone Matrice 100 DJI e câmera multiespectral Micasense REDEEDGE. Fonte: LISBOA, 2020.....	21
Figura 5 - Amostragem da forragem de <i>Urochloa decumbens</i> com dois quadros amostrais de um metro quadrado cada. Fonte: LISBOA, 2020.....	22
Figura 6 - Adubação com diferentes doses de ureia na área experimental de <i>Urochloa decumbens</i> .....	22
Figura 7 - Início do fluxograma de trabalho: coleta das imagens em campo, pré-processamento das imagens no software Agisoft até a obtenção dos ortomosaicos..	24
Figura 8 - Ortomosaicos gerados no software Agisoft a partir das imagens capturadas em cada voo com drone.....	24
Figura 9 - Continuação do fluxograma de trabalho: pré-processamento das imagens no software QGIS até a obtenção das variáveis preditoras.....	25
Figura 10 - Esquema de validação cruzada Leave-one-out.....	27
Figura 11 - Fluxograma de trabalho: desde a coleta das imagens em campo, passando pela fase de pré-processamento das imagens nos softwares Agisoft e QGIS, até o processamento dos dados no Spyder.....	29
Figura 12 - Matriz de correlação entre as variáveis preditoras e as variáveis de interesse, com correlações significativas indicadas por * ( $P < 0,05$ , teste t-Student)...	31
Figura 13 - Números ideais de variáveis preditoras para estimar as variáveis de interesse por Regressão Linear Múltipla. RMSE - Erro quadrático médio e MS - Matéria seca.....	32
Figura 14 - Números ideais de variáveis preditoras para estimar as variáveis de interesse por Random Forest Regressor. RMSE - Erro quadrático médio e MS - Matéria seca.....	33
Figura 15 - Predições da massa verde, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente.....	36

Figura 16 - Predições da massa seca, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente.....	36
Figura 17 - Predições da altura, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente.....	37
Figura 18 - Predições da densidade, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente. MS - Massa seca.....	37
Figura 19 - Predições da concentração de matéria seca, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente. MS - Matéria seca.....	38
Figura 20 - Predições da proteína bruta, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente.....	38

## LISTA DE TABELAS

Tabela 1 - Estatísticas descritivas das variáveis de massa verde e seca, altura, densidade, concentração de matéria seca e proteína bruta do pasto.....	23
Tabela 2 - Índices de vegetação.....	25
Tabela 3 - Variáveis preditoras selecionadas para os modelos.....	34
Tabela 4 - Hiperparâmetros selecionados por RFR.....	35
Tabela 5 - Modelos de Regressão Linear Simples para previsão das variáveis de interesse.....	35

## SUMÁRIO

1. INTRODUÇÃO.....	10
2. REVISÃO DE LITERATURA.....	12
2.1. Sensoriamento remoto em pastagens frente as mudanças climáticas.....	12
2.2. Monitoramento das pastagens via satélite versus ARP.....	13
2.3. Índices de vegetação.....	16
3. MATERIAL E MÉTODOS.....	18
3.1. Localização e caracterização do experimento.....	18
3.2. Aquisição das imagens multiespectrais e avaliações na forragem.....	20
3.3. Pré-processamento das imagens.....	23
3.4. Modelagem.....	26
4. RESULTADOS.....	29
4.1. Correlação entre as variáveis e seleção das variáveis preditoras.....	29
4.2. Modelos Finais.....	35
5. DISCUSSÃO.....	38
6. CONCLUSÕES.....	42
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	43

## 1. INTRODUÇÃO

O Brasil possui o maior rebanho bovino comercial do mundo, com mais de 234 milhões de cabeças de gado (IBGE, 2022). A maior parte desses animais são mantidos em pastagens, que constituem a principal fonte de alimento devido ao seu baixo custo de produção em comparação com outras culturas de interesse agrônômico (Pereira et al., 2018). Entre as gramíneas forrageiras tropicais mais utilizadas destaca-se o gênero *Urochloa*, responsável por cerca de 85% das pastagens cultivadas no Brasil, devido à maior tolerância a solos ácidos e de baixa fertilidade, em comparação com outras, e por apresentar bom potencial produtivo na estação chuvosa (Corrêa et al., 2020; Machado et al., 2020; Jank et al., 2014).

A área total de pastagens no Brasil compreende mais de 160 milhões de hectares (ha), dos quais mais de 60% se encontram em diferentes estágios de degradação (Projeto MapBiomass, 2023). As principais causas da degradação das pastagens, incluem a escolha inadequada da forrageira, a falta de adubação para reposição dos nutrientes exportados durante o pastejo e o excesso de animais em relação à quantidade disponível de forragem (Sousa et al., 2022). Além disso, a variação das condições climáticas, como precipitação e temperatura afetam a evapotranspiração, a retenção de umidade do solo e a produtividade do pasto ao longo do tempo (Keller et al., 2021; Ojima et al., 2013; Polley et al., 2013).

Dessa forma, a estimativa precisa da massa de forragem, altura e valor nutritivo das forrageiras é extremamente importante para o manejo eficiente do sistema de produção. Contudo, devido à heterogeneidade das áreas de pastagens em termos de solo, relevo e espécies, seu manejo é frequentemente dificultado (Bretas et al., 2021). A aferição da massa e da concentração de proteína da forragem, realizada por métodos tradicionais, como corte, secagem e análises laboratoriais, é inviável e onerosa, além de causar perda de material potencialmente consumível pelo animal (Delevatti et al., 2019).

Nesse contexto, o sensoriamento remoto (SR) e o aprendizado de máquinas surgem como soluções promissoras para o manejo de pastagens, oferecendo abordagens eficientes e acuradas. O uso de imagens obtidas por sensores acoplados a aeronaves remotamente pilotadas (ARP) pode auxiliar no monitoramento em tempo real, proporcionando dados com alta resolução temporal e espacial, viabilizando o

acompanhamento detalhado de culturas (Alvarez-Mendoza et al., 2022; Sangjan et al., 2022; Batistoti et al., 2019).

De acordo com Morota et al., (2018), os avanços em inteligência artificial e no aprendizado de máquinas permitem o uso de algoritmos para prever variáveis de interesse agrícola. Quando associadas a algoritmos de aprendizado de máquinas, as imagens obtidas por SR possibilitam previsões acuradas das características das pastagens, suportando a tomada de decisão (D'Oliveira et al., 2023). Diversos estudos já demonstraram o potencial de detecção de características com base em imagens de alta resolução associadas a algoritmos de técnicas de aprendizado de máquinas (David et al., 2020; Wang et al., 2017). Por exemplo, o algoritmo Random Forest Regressor (RFR), ao utilizar imagens capturadas por sensores multiespectrais ou hiperespectrais em ARP, pode ajudar na predição da massa de forragem e no rendimento das culturas (Alvarez-Mendoza et al., 2022).

Para predição de variáveis relacionadas ao pasto é possível utilizar modelos mais simples, como a regressão linear simples (RLS), ou modelos mais complexos, como RFR (Alvarez-Mendoza et al., 2022). Também é possível aplicar diferentes técnicas de validação, como a validação cruzada "Leave-One-Out" (Viljanen et al., 2018). Segundo Brovelli et al., (2008), esse método é especialmente eficaz em cenários com um número reduzido de amostras, pois utiliza todo o conjunto de dados disponível para avaliar a precisão do modelo de forma exaustiva e robusta.

Portanto, este trabalho partiu da premissa de que técnicas de machine learning aplicadas a dados multiespectrais coletados por ARP, podem resultar em modelos acurados para as predições de características estruturais e valor nutritivo de capim-brachiaria [*Urochloa decumbens* (Stapf) R.D. Webster]. O objetivo com este trabalho foi desenvolver modelos preditivos utilizando aprendizado de máquinas e imagens aéreas multiespectrais para prever a massa de forragem verde e seca, altura do dossel, densidade, e a concentração de matéria seca e proteína bruta do capim-braquiária. Para isso, três modelos de predição foram desenvolvidos utilizando técnicas de aprendizado de máquinas, com os algoritmos RLS, Regressão Linear Múltipla (RLM) e RFR.

## **2. REVISÃO DE LITERATURA**

### **2.1. Sensoriamento remoto em pastagens frente as mudanças climáticas**

O aquecimento global faz com que as secas e tempestades sejam cada vez mais frequentes e severas, em consequência do aumento das concentrações atmosféricas de gases, potencializando o efeito estufa (Polley et al., 2013). Essas variações no clima geram vários distúrbios no ecossistema, como por exemplo, no ciclo de desenvolvimento das plantas. O clima é um dos principais fatores que interferem no crescimento das plantas (Keller et al., 2021). Além de afetar a quantidade e qualidade da forragem, reduz a capacidade de acúmulo de carbono no solo e pode conferir maior degradação da área, principalmente quando associado a ações antrópicas errôneas (Polley et al., 2013).

Dessa forma, são necessárias estratégias de gestão que diminuam os impactos das mudanças climáticas nas pastagens (Ojima et al., 2013). O SR pode ser utilizado como uma ferramenta de gestão, visando otimizar o manejo do pasto diante das adversidades climáticas. O SR conta com sensores a bordo de satélites e drones que conseguem captar e coletar dados das áreas de produção agrícola, pecuária e até mesmo de pastagens degradadas (Ferreira e Ferreira Neto, 2018; Pereira et al., 2018). Por meio de informações espectrais, temporais e espaciais é possível estimar parâmetros da vegetação, minimizando assim os esforços com coletas de campo e procedimentos de laboratório, facilitando o manejo e conservação das pastagens (Filho et al., 2019).

O SR permite medições rápidas e automatizadas de parâmetros como massa e clorofila, com alta resolução espacial e temporal em uma variedade de escalas espaciais (Lussem et al., 2019). Para isso, são utilizadas imagens digitais que podem ser de origem hiperespectral, multiespectral, RGB e/ou radar, fotogrametria, varredura a laser e combinações de vários sensores em diferentes plataformas (Atzberger, 2013; Mulla, 2013). Essas câmeras podem ser acopladas a satélites e aeronaves não tripuladas, permitindo a aquisição de radiação visível, infravermelho próximo (NIR), radiação infravermelha de ondas curtas refletida e radiação infravermelha distante emitida pela cultura, para estimar o potencial de rendimento e o estresse ambiental (Atzberger, 2013).

Os dados de SR permitem a caracterização e estimativa da massa de forragem (Jia et al., 2016; Dusseux et al., 2015). Neste contexto, o índice de área foliar (IAF) e a massa acima do solo são as principais métricas biofísicas para caracterizar o crescimento e as condições das pastagens (Baghdadi et al., 2016; Klemas, 2013). A massa acima do solo está fortemente correlacionada com a altura do dossel, tradicionalmente medida com um bastão, um medidor de capacitância eletrônico ou um medidor de placa ascendente (Lussem et al., 2019). Com o desenvolvimento tecnológico nas últimas décadas, os dispositivos tornaram-se mais sofisticados (Lussem et al., 2019).

Hoje em dia, sensores permitem o registro e a transferência direta de dados (Lussem et al., 2019). As principais aplicações do sensoriamento remoto na vegetação são baseadas nos seguintes espectros de luz: região do ultravioleta (UV), que vai de 10 a 380 nm; espectros visíveis, que são compostos pelas regiões de comprimento de onda azul (450-495 nm), verde (495-570 nm) e vermelho (620-750 nm); e a banda do infravermelho próximo e médio (850–1700 nm) (Rahim et al., 2016). Sensores ópticos de SR, detecção e alcance de rádio (Radar) e detecção e alcance de luz (LiDAR) fornecem as três principais fontes de dados do sensoriamento remoto para estimativa de massa e valor nutritivo da forragem (Wachendorf, 2017).

Portanto, dada a importância do acesso a informações precisas com relação a massa do pasto e sua distribuição espacial, há uma grande necessidade do desenvolvimento de métodos acurados e transferíveis para a sua estimativa (Eisfelder et al., 2014). A acurácia na estimativa da massa é fundamental para identificar a capacidade de suporte do pasto, permitindo ajustar as taxas de lotação e os momentos adequados de colheita de forragem. Isso não apenas otimiza a produtividade animal, mas também promove o manejo sustentável dos recursos naturais, garantindo a produção de um pasto de qualidade, em quantidade suficiente e de forma sustentável, o que confere benefícios a pecuária, ao meio ambiente e à biodiversidade (Otgonbayar et al., 2018).

## **2.2. Monitoramento das pastagens via satélite versus ARP**

O sensoriamento remoto por satélite tornou-se uma ferramenta essencial para medir e monitorar o desempenho do ecossistema em grandes áreas devido à sua ampla cobertura e alta resolução espacial e temporal (Gu et al., 2012; Zhang et al.,

2011; Gu e Wylie, 2010; Wylie et al., 2008). A obtenção das informações de reflectância de ondas eletromagnéticas das partes aéreas das plantas é realizada por meio de sensores passivos (Xue e Su, 2017). A reflectância da vegetação é determinada mediante as características químicas e morfológicas da superfície dos órgãos vegetais (Zhang e Kovacs, 2012). No entanto, alguns desafios ainda permanecem no manejo dos ecossistemas de pastagens em larga escala, como a cobertura espacial limitada (Bareth e Schellberg, 2018).

Algumas plataformas de satélite oferecem livre acesso a dados visíveis e multiespectrais, auxiliando na determinação da produtividade nas pastagens, como o Landsat 7 e 8, com sensores como o Enhanced Thematic Mapper Plus (ETM) e Operational Land Imager (OLI), além de outros, como o Moderate Resolution Imaging Spectroradiometer (MODIS) das plataformas Terra e Aqua (Veloso et al., 2022). Nos últimos anos, houve uma melhoria na resolução óptica das imagens de satélite, fornecendo resoluções de 10 a 30 m de pixels em um ciclo de repetição de cinco dias (Serrano et al., 2020). Contudo, essa tecnologia não é eficiente para a mensuração de áreas muito pequenas (Xue e Su, 2017).

Outras desvantagens do uso das imagens de satélite são a presença de nuvens, que impede a captura fiel da área, e o tempo de revisita, que muitas das vezes não permite o acompanhamento diário da área de interesse (Bretas et al., 2021). Além disso, a maioria dos sistemas de satélite com alta resolução espacial, menor que cinco metros, são operados comercialmente (Manfreda et al., 2018). Uma alternativa é o uso de ARP aliada a câmaras multiespectrais, permitindo determinar várias características das plantas, como altura, produção de massa, densidade e valor nutricional por meio dos cálculos dos índices de vegetação (IV's), em função da alta resolução, normalmente menor que 1 m (Moeckel et al., 2018; Xue e Su, et al., 2017).

As ARP são plataformas adaptadas que, devido à diversidade de sensores que podem ser acopladas, auxiliam na coleta de imagens aéreas com alta resolução temporal e espacial (Salamí et al., 2014). Com os avanços na agricultura de precisão, miniaturização de tecnologias como processadores de computador e uso do Sistema Global de Navegação por Satélite (GNSS), as ARP se tornaram uma plataforma versátil, resultando em uma ferramenta capaz de ter bom desempenho em uma ampla gama de aplicações (López e Mulero-Pázmány, 2019). Elas são plataformas flexíveis que detectam as condições de crescimento das lavouras (Xiang e Tian., 2011) e

juntamente com as torres de monitoramento de culturas no campo (Ahamed et al., 2012), fornecem dados de maior densidade para o sensoriamento remoto.

Com o rápido desenvolvimento da tecnologia de sensores e plataformas no campo de ARP e pequenos sistemas de câmeras de alta resolução (RGB, multiespectral e hiperespectral) tornou-se possível aplicar essas tecnologias em campos experimentais e grandes áreas agrícolas (Maes e Steppe, 2019; Wachendorf et al., 2017). As aplicações flexíveis das ARP vêm beneficiando a agricultura, com abordagens de monitoramento com alta resolução espacial e temporal e vários sensores (Colomina e Molina, 2014). As ARP podem operar em baixa altitude para capturar imagens com resolução espacial de até 1 cm por pixel, resolução suficiente para medir parcelas individuais em campo (Turner et al., 2012).

O imageamento por ARP não é afetado pela oclusão de nuvens, mas durante o imageamento das áreas há necessidade de calibrar a câmera de antemão, para que as imagens sejam obtidas sob a mesma condição de luminosidade. Já as imagens provenientes dos satélites são corrigidas automaticamente (Bretas et al., 2021). As ARP apresentam outras limitações, como o período estreito das onze horas ao meio-dia, em que a incidência solar é satisfatória para o mapeamento. A autonomia de voo, o custo das plataformas e os problemas técnicos que podem ser enfrentados no ar, como perda de potência ou uma avaria do motor (Zhang e Kovacs, 2012; Hardin e Jensen, 2011), são as principais desvantagens do uso de ARP.

Insua et al., (2019), demonstraram que é possível obter medições precisas de massa de forragem, em alta resolução espacial, com o uso de câmaras multiespectrais leves montadas em ARP. As câmaras multiespectrais ou RGB (Von Bueren et al., 2015) e satélites (Punalekar et al., 2018) provaram ser uma solução eficaz para monitorar sistemas agrícolas (Rosa et al, 2021). Segundo Bazzo et al., (2023), sensores multiespectrais como a MicaSense fornecem mais bandas espectrais, incluindo a REDEEDGE, promovendo a obtenção de mais informações espectrais para aplicações em vegetação.

Além disso, a presença do sensor de luz descendente e alvo de calibração radiométrica são vantagens importantes das imagens multiespectrais (Bazzo et al., 2023), permitindo medições exatas, repetíveis e menos afetadas por fatores ambientais (Pranga et al., 2021). Atualmente, recursos computacionais estão sendo cada vez mais utilizados para extrair informações de imagens (Liu et al., 2021; Nandhini e Bhavani, 2020). As abordagens baseadas em computação podem ser

usadas como uma alternativa para substituir métodos destrutivos convencionais (Gée et al., 2021).

### 2.3. Índices de vegetação

Os IV's são combinações matemáticas da resposta espectral de diferentes bandas do espectro eletromagnético e são indicadores da atividade fotossintética e vigor da vegetação (Hill, 2013; Brantley et al., 2011). Esses índices reduzem o volume de dados a serem analisados e facilitam estimativas de variáveis biofísicas estruturais e fisiológicas da vegetação (Pan et al., 2015). São derivados de dados de reflectância adquiridos de sensores ópticos que têm sido usados em uma ampla gama de cenários para avaliar variações nos estados fisiológicos e nas propriedades biofísicas da vegetação (Sonobe et al., 2018; Villa et al., 2014).

Geralmente eles são associados com as avaliações diretas de interesse, como massa da forragem, altura do pasto, clorofila, entre outros (Xue e Su, 2017). Entre os índices, o mais comumente utilizado é o Índice de Vegetação por Diferença Normalizada (NDVI), calculado utilizando as bandas do vermelho visível (RED) e do NIR (Quemada et al., 2014). Ele está relacionado a altos níveis de clorofila, correlacionados com vigor vegetativo e conseqüentemente, com altas concentrações de proteína (Serrano et al., 2018). A seguir a equação do NDVI:

$$\text{NDVI} = (\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED})$$

Os índices associados a indicadores mais tradicionais fornecem aos agricultores as informações necessárias para a formulação da estratégia mais adequada de manejo e alimentação do gado (Serrano et al., 2017). No entanto, alguns índices como o NDVI podem apresentar problemas de saturação quando medidos em áreas de vegetação vigorosa (Schuster et al., 2015; Li et al., 2014; Hill, 2013). Isso pode ocorrer devido às folhas superiores que impedem a penetração da luz no dossel (Legg e Bradley, 2020). Alguns trabalhos relatam a perda de sensibilidade em condições de elevada massa e alta concentração de clorofila, o que pode superestimar as predições (Xue e Su, 2017).

Diante disso, outros índices têm sido propostos para minimizar esses problemas, como o Índice de Vegetação Aprimorado (EVI), Índice de Vegetação

Ajustado ao Solo (SAVI) e Índice de Vegetação Ajustado ao Solo Otimizado (OSAVI) (Fern et al., 2018; Jiang et al., 2008). Mas, devido à sua natureza empírica, esses modelos de regressão são específicos do local e do sensor, logo seu desempenho pode ser limitado por fatores como diferenças nas propriedades da superfície e geometria de visualização (Otgobayar et al., 2018). As equações dos índices, EVI, SAVI e OSAVI, são respectivamente as seguintes:

$$\text{EVI} = [(2.5 * (\text{NIR} - \text{RED})) / (\text{NIR} + 6 * \text{RED} - 7.5 * \text{BLUE} + 1)]$$

$$\text{SAVI} = [(1.5 * (\text{NIR} - \text{RED})) / (\text{NIR} + \text{RED} + 0.50)]$$

$$\text{OSAVI} = (\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED} + 0.16)$$

Outra desvantagem dos IV's é que eles geralmente usam duas ou três bandas espectrais, ignorando informações potencialmente importantes existentes em outras bandas (Atzberger, 2013). Mesmo com alguns problemas, os IV's são precisos na previsão de BAS e podem ser utilizados no monitoramento de pastagens (Filho et al., 2019; Michez et al., 2019; Otgobayar et al., 2018; Hill et al., 2017). A MicaSense REDEGE M (MicaSense, Inc., Seattle, WA, EUA) por exemplo, é um sensor multiespectral passivo acoplado a ARP, que permite a coleta da reflectância do dossel em cinco bandas espectrais (azul, verde, vermelho, borda do vermelho e infravermelho próximo), o que permite obter informações multivariadas do pasto (Esposito et al., 2021).

Estudos indicam que o RED está relacionado a absorção da clorofila, o GREEN com a sanidade da vegetação, o BLUE com a diferenciação entre vegetação e solo e o NIR ao valor nutricional da planta (Lugassi et al., 2015). Essas bandas espectrais obtidas por ARP têm demonstrado potencial para estimar a massa de culturas agrícolas, como cevada (Brocks e Bareth, 2018; Bendig, et al., 2014) e características biofísicas e bioquímicas das pastagens na Alemanha (Capolupo, et al., 2015), pastagens temperadas na China (Jin et al., 2014) e a classificação de espécies em pastagens mistas no Canadá (Lu e He, 2017).

Outros estudos revelam que os VI's são precisos na previsão de BAS em pastagens e podem ser usados no seu monitoramento (Michez et al., 2019; Otgobayar et al., 2018). Alguns índices também podem ser obtidos por sensores proximais, como o GreenSeeker, que é um sensor de dossel ativo. Ele mede a

refletância do dossel em bandas específicas nas regiões espectrais do RED e NIR e exibe o NDVI, uma medida útil da produtividade da planta (Huang et al., 2021; Tucker, 1979). No entanto, os sensores passivos conferem uma vantagem importante sobre os sensores proximais, pois permitem o cálculo de uma gama de índices, incluindo os baseados em REDEEDGE, como o Índice de Diferença Normalizada do REDEEDGE (NDRE) (Dunn et al., 2016).

O NDRE incorpora uma faixa REDEEDGE no lugar do RED, tornando-o mais resistente ao problema de saturação inerente ao NDVI (Dunn et al., 2016; Li et al., 2014). A seguir a equação do NDRE:

$$\text{NDRE} = (\text{NIR} - \text{REDEEDGE}) / (\text{NIR} + \text{REDEEDGE})$$

### **3. MATERIAL E MÉTODOS**

#### **3.1. Localização e caracterização do experimento**

O experimento foi conduzido no município de Viçosa, MG, no Departamento de Zootecnia da Universidade Federal de Viçosa (Figura 1). O solo da área experimental é um Latossolo Vermelho-Amarelo de textura argilosa. Previamente ao experimento, foram coletadas 20 amostras de solo na camada de 0 a 20 cm utilizando um trado holandês, para verificar a necessidade de calagem e adubação. O clima da região é classificado como Cwa, segundo o sistema Köppen, com precipitação anual média de 1.340 mm e umidade relativa do ar média de 80% (Martins et al., 2018).

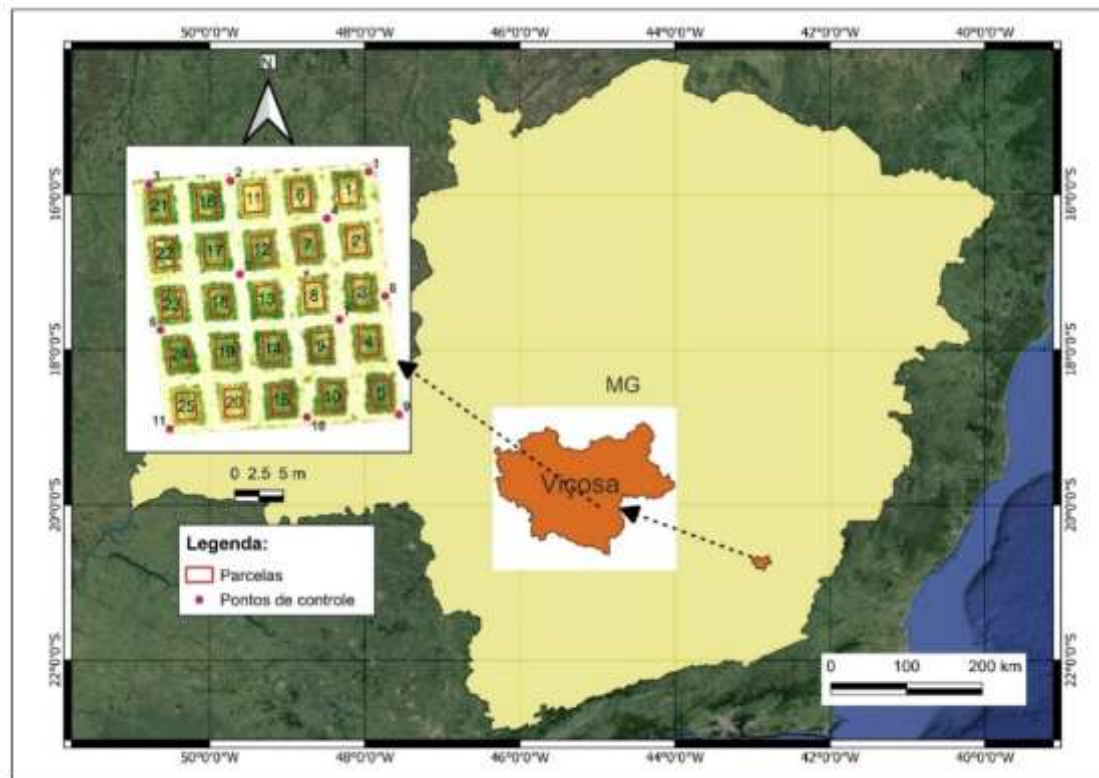


Figura 1 - Área experimental de 0,7 ha de *Urochloa decumbens* localizada em Viçosa, MG.

A área experimental consistiu em 0,7 ha de capim-braquiária [*Urochloa decumbens* (Stapf) R.D. Webster], introduzida em 2011. Esta área foi dividida em 25 parcelas de 12 m<sup>2</sup> cada (3 x 4 m) distribuídas em cinco blocos homogêneos, com espaçamento de 2 x 1,5 m entre as parcelas (Figura 1). Os dados meteorológicos durante o experimento foram obtidos da estação meteorológica de Viçosa, disponível no Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) do Instituto Nacional de Meteorologia (INMET). As precipitações acumuladas mensalmente e as temperaturas médias mensais (Figura 2) foram calculadas para avaliar a relação das condições climáticas com as características estruturais e nutricional do capim.




Figura 2 - Dados de precipitação acumulada e temperaturas médias em Viçosa, MG, entre 2019/2020.

### 3.2. Aquisição das imagens multiespectrais e avaliações na forragem

Para a aquisição das imagens, foram realizados sete voos utilizando uma ARP do tipo Matrice 100 DJI, equipada com uma câmera multiespectral Micasense REDEGE (Figuras 3 e 4). Essa câmera é capaz de capturar cinco bandas espectrais simultaneamente: RED (668 nm com a largura de 10 nm), GREEN (560 nm com a largura de 20 nm), BLUE (475 nm com a largura de 20 nm), NIR (840 nm com a largura de 40 nm) e REDEGE (717 nm com a largura de 10 nm) (IATEC, 2024). Os voos ocorreram a uma altura de 40 m, resultando em resolução espacial de 9 cm<sup>2</sup>/pixel. Foi utilizado intervalo entre disparos de dois segundos, com sobreposição longitudinal de 75% e lateral de 80% para gerar mosaicos da área.



Figuras 3 e 4 - Drone Matrice 100 DJI e câmera multiespectral Micasense REDEEDGE. Fonte: LISBOA, 2020.

A área experimental foi previamente georreferenciada com um GPS Trimble Pro XR, que determinou as coordenadas (latitude, longitude e altitude) dos 11 pontos de controle na área (Figura 1). Antes de cada voo, uma imagem do painel de calibração da câmera foi capturada para posterior ajuste radiométrico das imagens. Os voos ocorreram entre 11 e 12 horas, aproveitando o ângulo solar mais adequado para capturar a reflectância da vegetação.

A altura das plantas nas parcelas foi aferida imediatamente antes de cada voo e da colheita da forragem, utilizando-se uma régua graduada, com medições em dez pontos aleatórios por unidade experimental, excluindo as bordaduras. As amostras de forragem foram colhidas a cada 21 dias, totalizando sete cortes. Para isso utilizou-se dois gabaritos de um metro quadrado alocados em pontos representativos da altura média do dossel em cada parcela (Figura 5). As amostragens foram colhidas com aparador de cerca viva (Husqvarna, modelo 325 HE 4, Cajamar, SP, Brasil). Após a aquisição das imagens os canteiros eram rebaixados a uma altura residual de 10 cm.



Figura 5 - Amostragem da forragem de *Urochloa decumbens* com dois quadros amostrais de um metro quadrado cada. Fonte: LISBOA, 2020.

Cinco doses de ureia (0, 50, 100, 150 e 200 kg ha<sup>-1</sup>) foram aplicadas após os cortes, visando gerar variação nas características estruturais e proteicas da planta (Figura 6). A aplicação foi dividida em doses de 50 kg, com intervalos de três dias, sendo finalizada uma semana antes do próximo corte. Cada parcela recebeu irrigação de 12 mm após a adubação. Mais detalhes sobre a condução do experimento e aquisição de imagens estão descritos em Lisboa (2020) e Carvalho (2020).

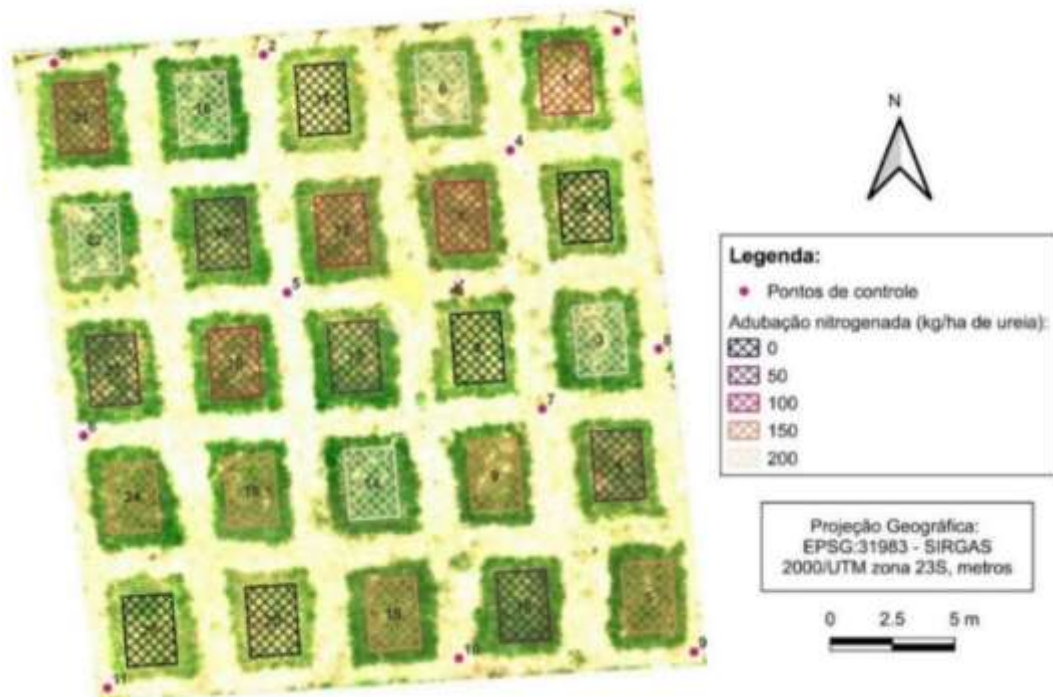


Figura 6 - Adubação com diferentes doses de ureia na área experimental de *Urochloa decumbens*.

Após a colheita, as amostras foram separadas e pesadas, e uma subamostra de 100 gramas foi seca em estufa a 55 °C por 72 horas para determinação da matéria seca ao ar (ASA). Posteriormente, as amostras foram moídas (peneira de 1 mm) para análise de MS definitiva (INCT-CA G-003/1) e PB (INCT-CA N-001/1), conforme Detmann et al., (2012). A densidade foi calculada pela razão entre a massa seca e a altura das plantas no ponto de amostragem. As estatísticas descritivas das variáveis estão apresentadas na Tabela 1.

Tabela 1 - Estatísticas descritivas das variáveis de massa verde e seca, altura, densidade, concentração de matéria seca e proteína bruta do pasto

<b>Estatística</b>	<b>MVF (Kg ha<sup>-1</sup>)</b>	<b>MSF (Kg ha<sup>-1</sup>)</b>	<b>ALT (cm)</b>	<b>DEN (Kg MS cm<sup>-1</sup>)</b>	<b>MS (%)</b>	<b>PB(%)</b>
N	175	175	175	175	175	175
Mínimo	165	58.15	11	4.47	11.52	7
Máximo	30974.35	5720.47	70.80	136.20	40.30	25.35
Média	7652.89	1491.79	28.59	46.58	22.48	17.38
Mediana	5338.75	1025.94	24.00	42.09	23.03	18.72
Desvio padrão	6751.56	1231.86	13.53	28.37	6.30	4.25
CV (%)	88.22	82.58	47.33	60.91	28.01	24.45

MVF - Massa verde de forragem, MSF - Massa seca de forragem, ALT - Altura, DEN - Densidade, MS - matéria seca, PB - Proteína bruta, N - Número de observações, CV - Coeficiente de variação.

### 3.3. Pré-processamento das imagens

As imagens capturadas a campo foram processadas no software Agisoft Metashape Professional®, incluindo etapas como calibração de refletância, alinhamento das fotos, construção de uma nuvem tridimensional de pontos, construção do modelo e textura, densificação da nuvem tridimensional, construção de um modelo digital de superfície e obtenção do ortomosaico (Figura 7). Os ortomosaicos dos sete voos (Figura 8) foram exportados em formato .tiff para o software QGIS® versão 3.28.4.

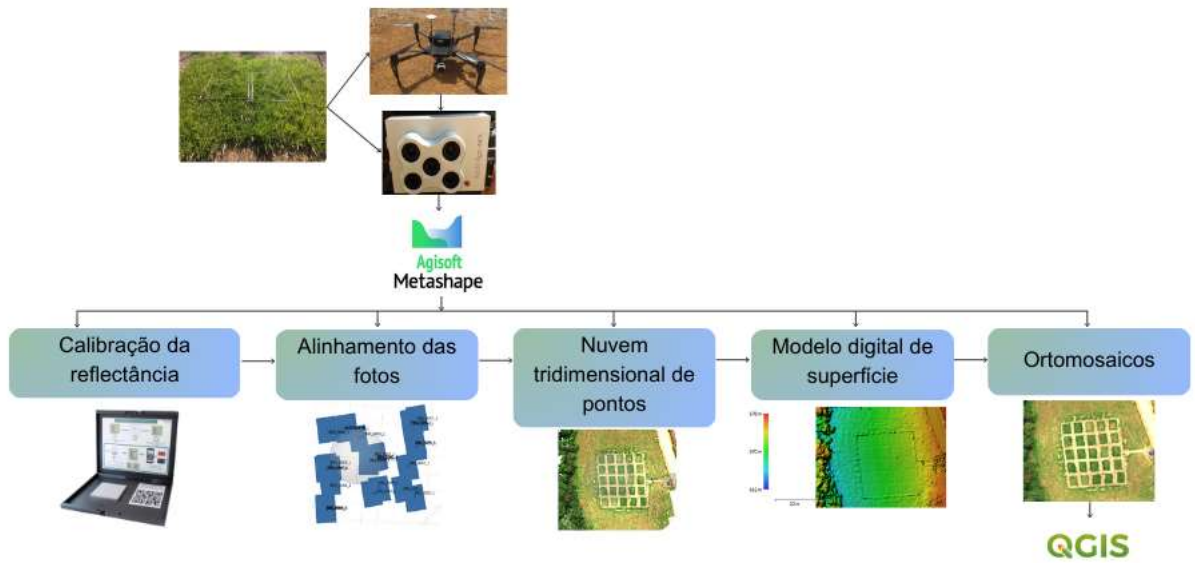


Figura 7 - Início do fluxograma de trabalho: coleta das imagens em campo, pré-processamento das imagens no software Agisoft até a obtenção dos ortomosaicos.




Figura 8 - Ortomosaicos gerados no software Agisoft a partir das imagens capturadas em cada voo com drone.

Em seguida, recortes de 6 m<sup>2</sup> foram realizados em cada parcela para extração dos valores das cinco bandas espectrais, utilizando a ferramenta de estatísticas zonal do QGIS. Esses dados digitais foram normalizados conforme orientação técnica do Agisoft Portal de Suporte Técnico (2024), no qual os valores foram divididos por 32.768, o que promoveu o ajuste da reflectância para uma faixa de zero a um. A partir dessas bandas, foram determinados os 12 IV's utilizados neste trabalho (Tabela 2), como NDVI, NDRE, Índice de Vegetação por Diferença Normalizada do Verde (GNDVI), entre outros.

Os dados meteorológicos (precipitação acumulada, temperaturas mínima, média e máxima) nos 21 dias anteriores ao primeiro voo e entre os voos também foram utilizados como variáveis preditoras. Esses dados, junto com as bandas espectrais e IV's (Figura 9), alimentaram os modelos de RLS, RLM e RFR, capturando tanto a variabilidade espectral quanto os efeitos ambientais nas estimativas das variáveis de interesse (massa verde e seca, altura, densidade, concentração de matéria seca e proteína bruta).




Figura 9 - Continuação do fluxograma de trabalho: pré-processamento das imagens no software QGIS até a obtenção das variáveis preditoras.

Tabela 2 - Índices de vegetação

Índices de Vegetação	Equações	Referências
CIRE (REDEGE Chlorophyll Index)	$(\text{NIR}/\text{REDEGE}) - 1$	Gitelson et al., (2005)
EVI (Enhanced Vegetation Index)	$[(2.5 * (\text{NIR} - \text{RED})) / (\text{NIR} + 6 * \text{RED} - 7.5 * \text{BLUE} + 1)]$	Jiang et al., (2008)
EVI2 (Enhanced Vegetation Index 2)	$[2.5 * (\text{NIR} - \text{RED}) / (\text{NIR} + 2.4 * \text{RED} + 1)]$	Jiang et al., (2008)
GCVI (GREEN Chlorophyll Vegetation Index)	$(\text{NIR}/\text{GREEN}) - 1$	Gitelson et al., (2005)
GNDVI (GREEN Normalized Difference Vegetation Index)	$[(\text{NIR} - \text{GREEN}) / (\text{NIR} + \text{GREEN})]$	Gitelson et al., (1996)
NDRE (Normalized Difference REDEGE)	$[(\text{NIR} - \text{REDEGE}) / (\text{NIR} + \text{REDEGE})]$	Fitzgerald et al., (2006)
NDVI (Normalized Difference Vegetation Index)	$[(\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED})]$	Rondeaux et al., (1996)
MTCI (MERIS Terrestrial Chlorophyll Index)	$[(\text{NIR} - \text{REDEGE}) / (\text{REDEGE} - \text{RED})]$	Dash et al., (2007)
OSAVI (Optimized Soil Adjusted Vegetation Index)	$[(\text{NIR} - \text{RED}) / (\text{NIR} + \text{RED} + 0.16)]$	Rondeaux et al., (1996)
SAVI (Soil Adjusted Vegetation Index)	$[(1.5 * (\text{NIR} - \text{RED})) / (\text{NIR} + \text{RED} + 0.50)]$	Rondeaux et al., (1996)
SR (Simple Ratio)	$\text{NIR} / \text{RED}$	Huete, (1988)
SREDEGE (Simple Ratio REDEGE)	$\text{NIR} / \text{REDEGE}$	Fraser, (2005)

CIRE - Índice de Clorofila REDEGE, EVI - Índice de Vegetação Aprimorado, EVI2 - Índice de Vegetação Aprimorado 2, GCVI - Índice de Clorofila Verde, GNDVI - Índice de Vegetação de Diferença Normalizada Verde, NDRE - Índice de Diferença Normalizada REDEGE, NDVI - Índice de Vegetação por Diferença Normalizada, MTCI - Índice de Clorofila Terrestre MERIS, OSAVI - Índice de Vegetação Ajustado ao Solo Otimizado, SAVI - Índice de Vegetação Ajustado ao Solo, SR - Razão Simples e SREDEGE - Razão Simples REDEGE.

### 3.4. Modelagem

Foram desenvolvidos três modelos preditivos utilizando técnicas de machine learning: RLS, RLM e RFR. Os algoritmos foram implementados na linguagem Python 3.11 (Python Software Foundation, 2024). A partir das bandas espectrais (RGB, REDEGE e NIR) foram criados 12 IV's, apresentados na Tabela 2, que foram utilizados como variáveis preditoras. Além disso, foram consideradas as bandas espectrais e os dados meteorológicos (precipitação acumulada, temperatura mínima média, temperatura média e temperatura máxima média), coletados 21 dias antes do primeiro voo e entre os voos subsequentes, totalizando 21 variáveis preditoras.

Para selecionar as melhores variáveis preditoras, foi realizada uma análise de correlação, que permitiu investigar as relações entre as variáveis preditoras e as variáveis de interesse, com o objetivo de identificar possíveis colinearidades. Uma matriz de correlação foi gerada utilizando o coeficiente de Pearson, que avalia a força e direção da relação linear entre duas variáveis contínuas, variando entre -1 e 1. Valores próximos de 1 indicam forte correlação positiva, próximos de -1 indicam forte correlação negativa e próximos a zero indicam uma correlação fraca ou inexistente. Adicionalmente, foi utilizado o teste t-Student para avaliar a significância das correlações ( $P < 0,05$ ), destacando as relações estatisticamente relevantes.

A validação cruzada do tipo "Leave-one-out" foi utilizada durante a etapa de treinamento e validação dos modelos para seleção do melhor modelo e minimização do sobreajuste. Ao final de sete voos realizados em 25 parcelas, totalizaram-se 175 observações. Assim, 150 observações foram destinadas ao treinamento e 25 ao teste em cada iteração (Figura 10). Em cada rodada, um voo foi reservado para teste, enquanto os demais compuseram o conjunto de treinamento. O processo foi repetido sete vezes, garantido que cada voo fosse utilizado como conjunto de teste ao menos uma vez. Essa abordagem foi escolhida devido ao pequeno número de observações, permitindo uma avaliação consistente e estimativas confiáveis de erro.

Para seleção das variáveis preditoras incluídas no modelo RFR utilizou-se a função "SelectFromModel", que avalia a importância das variáveis preditoras com base na sua contribuição para a performance do modelo. O parâmetro "max\_features" foi configurado para iterar entre diferentes combinações de variáveis, selecionando desde uma variável até o conjunto completo. O número de variáveis selecionadas de acordo com o grau de importância foi então determinado com base na estabilização

do menor erro quadrático médio (RMSE). Para os modelos de RLS e RLM, a seleção do número das variáveis foi realizada com base exclusivamente na estabilização do menor RMSE.

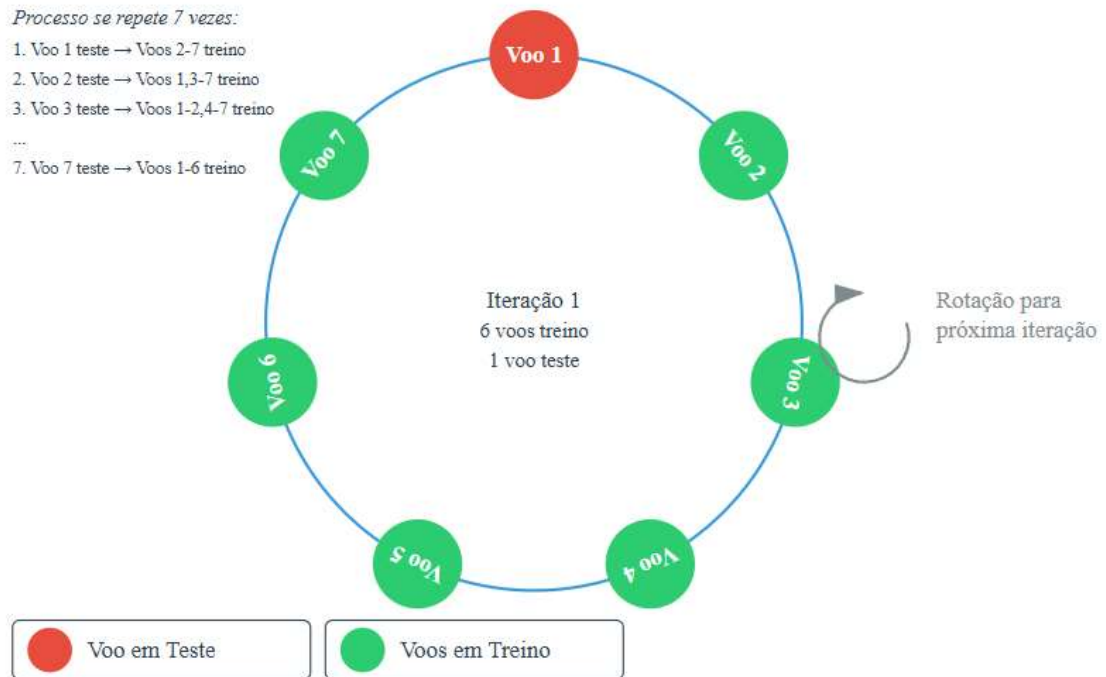


Figura 10 - Esquema de validação cruzada Leave-one-out.

Além disso, os dados foram padronizados para os modelos de RLS e RLM pela função “StandardScaler”, o que garantiu uma média igual a zero e desvio padrão igual a um, uma prática importante em algoritmos de machine learning sensíveis à escala dos dados. Para o RFR, foi realizada a otimização dos hiperparâmetros, utilizando o método “gp\_minimize”, uma técnica de otimização bayesiana que busca de forma eficiente a combinação ideal de parâmetros para minimizar o erro. Esse método iterou sobre parâmetros como o número de árvores (n\_estimators), profundidade máxima (max\_depth), número mínimo de amostras por nó (min\_samples\_split) e número mínimo de amostras por folha (min\_samples\_leaf), selecionando a combinação que resultou no melhor desempenho do modelo, medido pelo RMSE.

Durante o treinamento dos modelos, diferentes subconjuntos de variáveis foram avaliados a cada iteração, utilizando as métricas RMSE e erro absoluto médio (MAE). Como abordado anteriormente, a seleção do número ideal de variáveis preditoras foi realizada com base no menor RMSE, buscando o equilíbrio entre a quantidade de

variáveis e a acurácia das previsões. Também foi utilizado nessa etapa a validação cruzada “Leave-one-out” para evitar ajuste excessivo.

Para os modelos de RLM e RFR, as variáveis mais frequentemente selecionadas ao longo das iterações foram mantidas no modelo final, garantindo que as variáveis mais robustas fossem utilizadas. Para o modelo de RLS, foi escolhida uma única variável preditora com base no menor RMSE, assegurando a simplicidade do modelo sem comprometer a acurácia. As equações utilizadas para calcular o RMSE e o MAE são as seguintes:

Erro Quadrático Médio (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{V}_{pred} - V_{obs}^i)^2}$$

Erro Absoluto Médio (MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |V_{obs}^i - \hat{V}_{pred}|$$

A técnica de validação cruzada do tipo “K-folds” com 7 divisões foi utilizada para teste final dos modelos selecionados após as etapas de treinamento e validação, permitindo avaliar o poder de generalização do modelo em diferentes partições dos dados. Portanto, foi aplicada uma combinação de diferentes técnicas de validação cruzada durante o processo de modelagem para garantir a robustez dos modelos obtidos. Primeiramente, adotou-se a técnica “Leave-one-out”, no qual, a cada iteração, um voo foi deixado de fora para ser utilizado como conjunto de teste, enquanto os demais foram usados para o treino do modelo. Posteriormente, foi utilizada a técnica de validação cruzada do tipo “K-folds” com 7 divisões dentro de cada conjunto de treinamento, de forma a evitar problemas de sobreajuste dos modelos mesmo com banco de dados restrito.

O fluxograma (Figura 11) esquematiza todo o processo de modelagem, desde a coleta dos dados até o desenvolvimento dos modelos, passando pelo pré-processamento e processamento das imagens. As performances dos modelos foram avaliadas por meio do coeficiente de determinação ( $R^2$ ), do RMSE e do MAE,

assegurando uma análise precisa e robusta da capacidade preditiva e da generalização dos modelos. A equação utilizada para calcular o  $R^2$  é a seguinte:

Coeficiente de Determinação ( $R^2$ ):

$$R^2 = 1 - \frac{\sum_{i=1}^n (V_{obs}^i - V_{pred})^2}{\sum_{i=1}^n (V_{obs}^i - \bar{V}_{obs})^2}$$

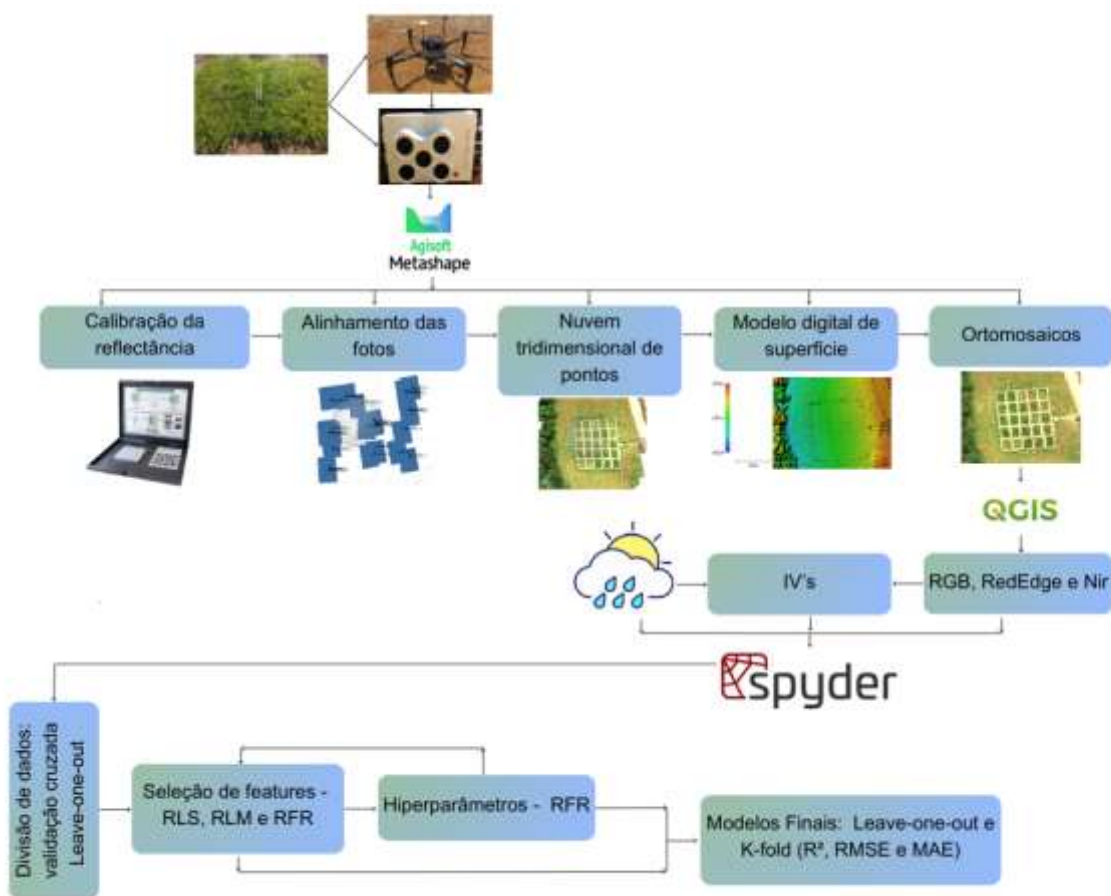


Figura 11 - Fluxograma de trabalho: desde a coleta das imagens em campo, passando pela fase de pré-processamento das imagens nos softwares Agisoft e QGIS, até o processamento dos dados no Spyder.

## 4. RESULTADOS

### 4.1. Correlação entre as variáveis e seleção das variáveis preditoras

A matriz de correlação (Figura 12) apresenta as correlações positivas e negativas entre as variáveis preditoras e entre essas e as variáveis de interesse

(massa de forragem verde e seca, altura, densidade, concentração de matéria seca e proteína bruta). Os IV's exibiram correlações positivas entre si, com a banda NIR e com os dados meteorológicos, enquanto suas correlações com as demais bandas foram predominantemente negativas. As variáveis de interesse, com exceção da concentração de matéria seca, mostraram correlações positivas entre si e com os IV's, mas correlações negativas com as bandas espectrais, exceto no caso da concentração de MS (Figura 12).

Os dados meteorológicos mostraram correlações positivas com as variáveis de interesse, exceto para a concentração de MS (com precipitação e temperaturas média e mínima) e para a PB (com temperaturas máxima e média). Ademais, nenhuma correlação significativa foi observada entre a PB e outras variáveis de interesse. Entre as variáveis de interesse, as maiores correlações foram entre massa verde e massa seca (0.91\*), densidade e massa seca (0.89\*), e altura e massa verde (0.85\*) (Figura 12). As maiores correlações entre as variáveis de interesse e os IV's foram: massa verde com MTCI (0.90\*), massa seca com GCVI (0.90\*), densidade com SR (0.85\*), altura com EVI2 (0.80\*), concentração de MS com OSAVI (-0.64\*) e PB com MTCI (0.44\*).

Em relação aos dados meteorológicos, destacaram-se as correlações entre massa seca e densidade com temperatura média (0.75\* e 0.69\*, respectivamente), altura com temperatura mínima (0.67\*), concentração de matéria seca com precipitação (-0.64\*) e massa verde com precipitação e temperatura mínima (0.62\*) (Figura 12). Já entre as bandas espectrais, as correlações mais relevantes foram altura e massa verde com NIR (0.79\* e 0.70\*, respectivamente), densidade e massa seca com GREEN (-0.76\* e -0.70\*, respectivamente), concentração de MS com RED (0.58\*) e PB com GREEN e REDEDGE (-0.39\*) (Figura 12).




Figura 12 - Matriz de correlao entre as variveis predictoras e as variveis de interesse, com correlao significativas indicadas por \* ( $P < 0,05$ , teste t-Student).

Para os modelos de regresso linear simples (RLS), as variveis predictoras selecionadas foram: MTCI para massa verde e PB; SR para massa seca e densidade; e NIR para altura e concentrao de MS, conforme mostrado na Tabela 3. Para os modelos de regresso linear mltipla (RLM), foram selecionadas 20 variveis predictoras para massa verde (Figura 13a), trs para massa seca (Figura 13b), 18 para altura (Figura 13c), oito para densidade (Figura 13d), 13 para concentrao de MS (Figura 13e) e seis para PB (Figura 13f).

J para os modelos de Random Forest Regressor (RFR), foram selecionadas 20 variveis predictoras para massa verde (Figura 14a), quatro para massa seca (Figura 14b), 11 para altura (Figura 14c), nove para densidade (Figura 14d), dez para concentrao de MS (Figura 14e) e 19 para protena (Figura 14f). As variveis predictoras selecionadas para os modelos RLM e RFR, considerando a maior frequncia observada em todos os voos, tm so descritas na Tabela 3. Por

fim, os hiperparâmetros médios selecionados para os modelos de RFR, de acordo com as variáveis de interesse, encontram-se na Tabela 4.




Figura 13 - Números ideais de variáveis preditoras para estimar as variáveis de interesse por Regressão Linear Múltipla. RMSE - Erro quadrático médio e MS - Matéria seca.

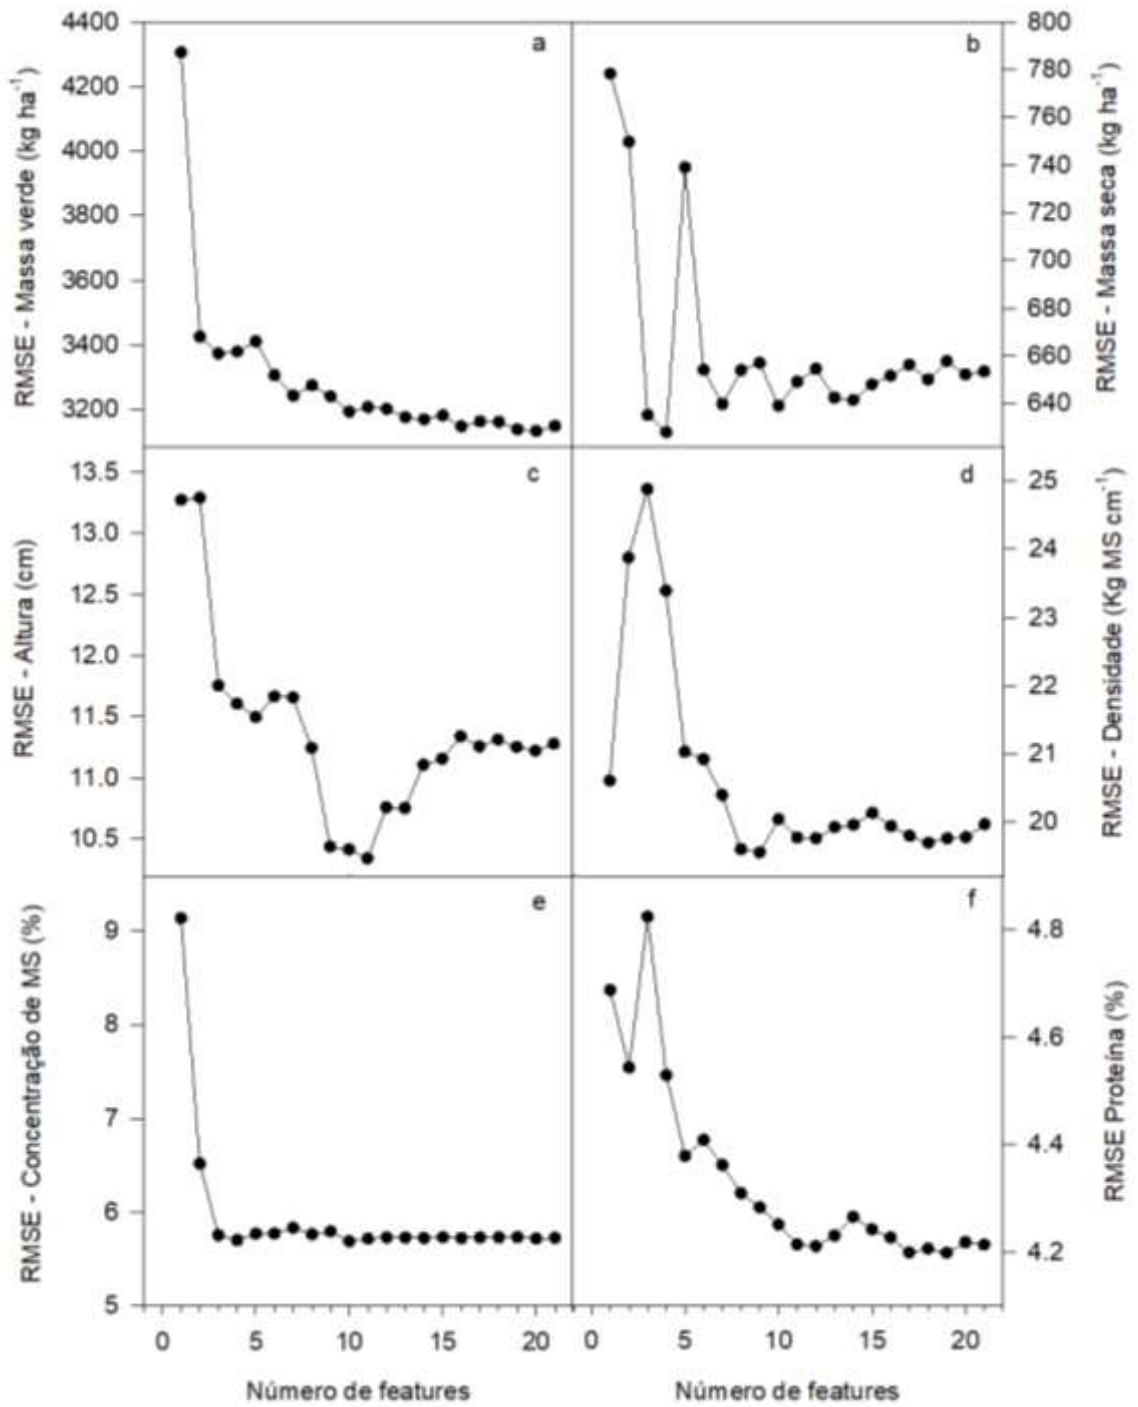


Figura 14 - Números ideais de variáveis preditoras para estimar as variáveis de interesse por Random Forest Regressor. RMSE - Erro quadrático médio e MS - Matéria seca.

Tabela 3 - Variáveis predictoras selecionadas para os modelos

Variáveis de interesse	Variáveis predictoras		
	RLS	RLM	RFR
Massa verde (kg ha <sup>-1</sup> )	MTCI	MTCI, SREDEDGE, CIRE, GCVI, NDRE, SR, GNDVI, OSAVI, EVI2, SAVI, EVI, NIR, NDVI, Precipitação, Temperatura mínima, GREEN, RED, BLUE, Temperatura média e REDEDGE.	GCVI, MTCI, GNDVI, SREDEDGE, CIRE, NDRE, OSAVI, NDVI, SR, EVI2, GREEN, BLUE, SAVI, NIR, REDEDGE, EVI, RED, Temperatura mínima, Temperatura máxima e Precipitação.
Massa seca (kg ha <sup>-1</sup> )	SR	GCVI, SREDEDGE e SR.	GCVI, GNDVI, OSAVI e NDVI.
Altura (cm)	NIR	EVI2, EVI, MTCI, SAVI, OSAVI, CIRE, SREDEDGE, GCVI, NIR, NDRE, GNDVI, BLUE, SR, NDVI, RED, GREEN, Precipitação e Temperatura média.	OSAVI, Temperatura mínima, GNDVI, EVI, SAVI, EVI2, GCVI, NIR, NDVI, SR e GREEN,.
Densidade (Kg MS cm <sup>-1</sup> )	SR	SR, GCVI, NDRE, GNDVI, GREEN, SREDEDGE, CIRE e BLUE.	GREEN, BLUE, RED, GNDVI, Precipitação, NDVI, OSAVI, Temperatura média e Temperatura máxima.
Concentração de MS (%)	NIR	Precipitação, NDRE, OSAVI, NDVI, EVI, SAVI, GNDVI, RED, EVI2, CIRE, Temperatura mínima, MTCI e NIR.	NIR, MTCI, Temperatura máxima, RED, Precipitação, GREEN, CIRE, SR, NDVI e NDRE.
Proteína bruta (%)	MTCI	MTCI, NDRE, GNDVI, SREDEDGE, GREEN e REDEDGE.	MTCI, REDEDGE, BLUE, GREEN, NIR, RED, Temperatura média, OSAVI, Precipitação, Temperatura mínima, NDVI, SR, GNDVI, Temperatura máxima, GCVI, CIRE, SREDEDGE, NDRE e EVI.

RLS - Regressão Linear Simples, RLM - Regressão Linear Múltipla, RFR - Random Forest Regressor, MS - Matéria seca, CIRE - Índice de Clorofila REDEDGE, EVI - Índice de Vegetação Aprimorado, EVI2 - Índice de Vegetação Aprimorado 2, GCVI - Índice de Clorofila Verde, GNDVI - Índice de Vegetação de Diferença Normalizada Verde, NDRE - Índice de Diferença Normalizada REDEDGE, NDVI - Índice de Vegetação por Diferença Normalizada, MTCI - Índice de Clorofila Terrestre MERIS, OSAVI - Índice de Vegetação Ajustado ao Solo Otimizado, SAVI - Índice de Vegetação Ajustado ao Solo, SR - Razão Simples e SREDEDGE - Razão Simples REDEDGE. As features selecionadas estão dispostas na tabela de acordo com seu grau de importância, do maior para o menor, para os modelos de RLM e RFR.

Tabela 4 - Hiperparâmetros selecionados por RFR

Hiperparâmetros	Massa verde	Massa seca	Altura	Densidade	Concentração de MS	Proteína
<b>N estimators</b>	50	500	473	63	50	500
<b>Max depth</b>	8	16	11	20	11	12
<b>Min samples split</b>	3	2	2	7	2	2
<b>Min samples leaf</b>	8	2	1	2	4	5

N estimators - número de estimadores ou árvores, Max depth - profundidade máxima de cada árvore, Min samples split - número mínimo de amostras necessárias para dividir um nó e Min samples leaf - número mínimo de amostras em cada folha.

#### 4.2. Modelos Finais

Na Tabela 5 são apresentados os modelos de RLS utilizados para a predição das características estruturais e químicas da forragem, empregando como possíveis variáveis preditoras os índices de vegetação (IV's), bandas espectrais ou dados meteorológicos. As predições das massas de forragem verde e seca pelos modelos de RLS apresentaram resultados satisfatórios, com  $R^2$  de 0,75 e 0,64, respectivamente. A altura do dossel também demonstrou um desempenho considerável, com  $R^2$  de 0,59, enquanto a densidade e a %PB apresentaram capacidades preditivas mais baixas, com  $R^2$  de 0,40 e 0,13, respectivamente. Para a concentração de MS, os resultados não foram incluídos, pois o modelo não conseguiu generalizar adequadamente os dados disponíveis com a variável preditora (banda NIR), resultando na ausência de variações nas predições.

Tabela 5 - Modelos de Regressão Linear Simples para previsão das variáveis de interesse

Variáveis de interesse	Modelos	$R^2$	RMSE	MAE
Massa verde (Kg ha <sup>-1</sup> )	$y = 0.73\text{MTCI} + 2030.6$	0.75	3368.77	2358.38
Massa seca (Kg ha <sup>-1</sup> )	$y = 0.67\text{SR} + 471.7$	0.64	741.34	555.20
Altura (cm)	$y = 0.64\text{NIR} + 9.86$	0.59	8.72	7.26
Densidade (Kg MS cm <sup>-1</sup> )	$y = 0.50\text{SR} + 23.22$	0.40	22.31	15.29
Proteína bruta (%)	$y = 0.19\text{MTCI} + 13.90$	0.13	4.02	3.44

$R^2$  - Coeficiente de determinação, RMSE - Erro quadrático médio, MAE - Erro absoluto médio e MS - Massa seca.

As previsões dos modelos de RLM foram satisfatórias para as massas de forragem verde e seca, com  $R^2$  de 0,77 (Figura 15a) e 0,71 (Figura 16a), respectivamente. No entanto, os resultados foram insatisfatórios para as demais variáveis: altura com  $R^2$  de 0,25 (Figura 17a), densidade com  $R^2$  de 0,42 (Figura 18a), concentração de MS e PB com  $R^2$  de 0,04 (Figuras 19<sup>a</sup> e 20a). Para os modelos de RFR, as melhores previsões também foram observadas para as massas de forragem verde e seca, com  $R^2$  de 0,63 e 0,62, respectivamente (Figuras 15b e 16b). Contudo, as previsões para as demais variáveis não foram satisfatórias: altura com  $R^2$  de 0,35 (Figura 17b), densidade com  $R^2$  de 0,34 (Figura 18b), concentração de MS com  $R^2$  de 0,12 (Figura 19b) e PB com  $R^2$  de 0,09 (Figura 20b).




Figura 15 - Previsões da massa verde, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente.

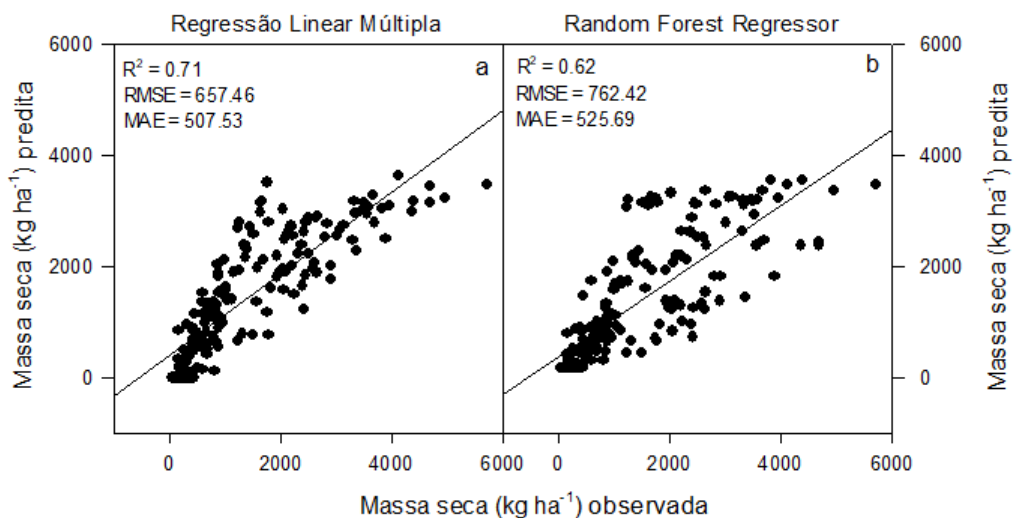


Figura 16 - Previsões da massa seca, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente.

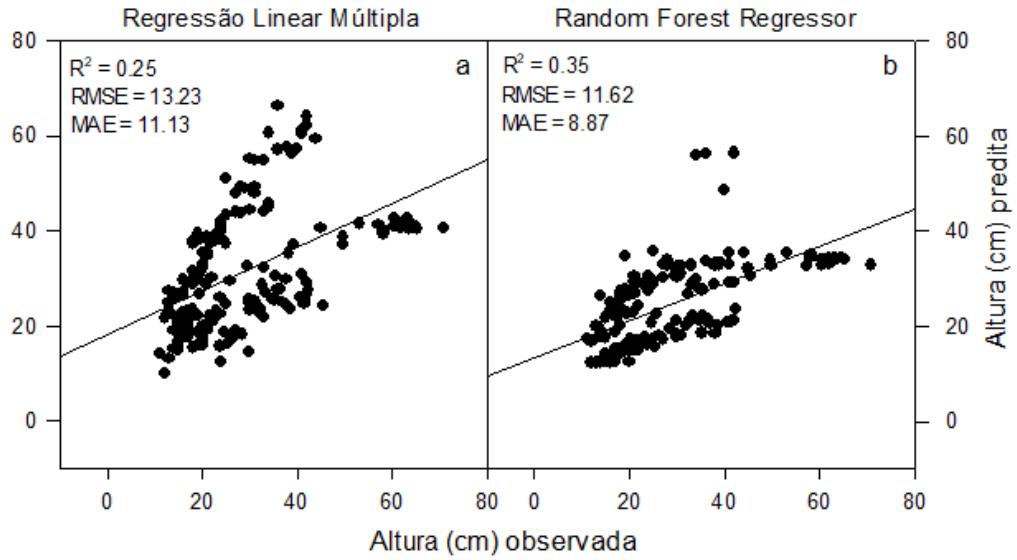


Figura 17 - Predições da altura, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente.




Figura 18 - Predições da densidade, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente. MS - Massa seca.




Figura 19 - Predições da concentração de matéria seca, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente. MS - Matéria seca.

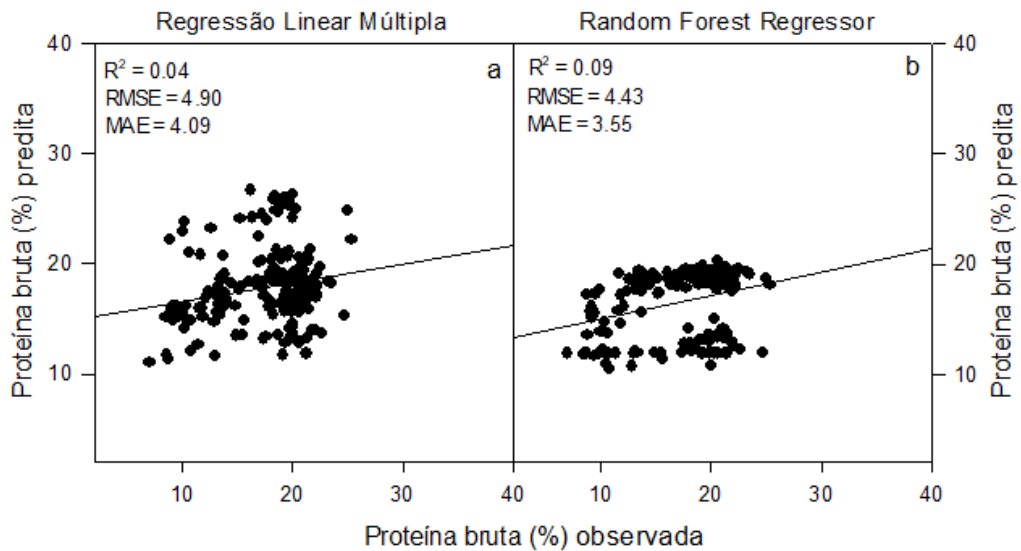


Figura 20 - Predições da proteína bruta, por Regressão Linear Múltipla e Random Forest Regressor, respectivamente.

## 5. DISCUSSÃO

As imagens obtidas com aeronaves remotamente pilotadas são eficazes na geração de índices de vegetação, sendo que diversos estudos destacam associações significativas entre esses índices e características importantes das culturas, como o rendimento de grãos e a biomassa aérea (Maimaitijiang et al., 2020; Duan et al., 2019). Neste trabalho, IV's foram utilizados para prever diferentes características do pasto,

entre elas as massas verde e seca da forragem, apresentando resultados satisfatórios, com  $R^2$  superiores a 0,60. Esses resultados reforçam a importância dos IV's para a predição da massa de forragem do pasto.

Entre os índices utilizados, o NDVI destaca-se por sua ampla aplicação no monitoramento agrícola e pela forte correlação com o crescimento das culturas (Shiratsuchi et al., 2014). Neste estudo, ele apresentou associações positivas com quase todas as variáveis de interesse (Figura 12). Contudo, sua sensibilidade é reduzida em áreas de alta biomassa ou solo exposto (Bretas et al., 2021). Diante disso, mesmo com a aplicação de outros índices para mitigar essas limitações (Dash e Curran, 2007; Fraser, 2005; Gitelson et al., 2005; Rondeaux et al., 1996; Huete, 1988), os modelos de predição para massa de forragem apresentaram maior dispersão dos dados à medida que a biomassa aumentava (Figuras 15a e 15b), evidenciando dificuldades na predição em cenários de alta massa de forragem.

Contudo, existem outras abordagens para prever a massa de forragem do pasto. Michez et al., (2019), por exemplo, ao utilizarem IV's obtidos por imagens multiespectrais com ARP, observaram que o modelo que incorporou refletância e altura apresentou o melhor desempenho, com  $R^2$  de 0,49 e RMSE de 900 kg ha<sup>-1</sup>. Enquanto, que o modelo baseado apenas em refletância obteve  $R^2$  de 0,35 e RMSE de 1000 kg ha<sup>-1</sup> para predição da massa de forragem.

Este estudo obteve resultados superiores para a predição da massa verde do pasto (Tabela 5 e Figura 15) utilizando dados de refletância juntamente com dados climáticos, superando os resultados de Michez et al., (2019), indicando, que o uso de dados climáticos agrega valor aos modelos de predição. No entanto, apesar da maior acurácia dos modelos, os erros de predição também foram maiores. Portanto, é fundamental avaliar tanto o  $R^2$  quanto o RMSE para uma análise mais completa e crítica dos modelos de predição.

De forma semelhante, Batistoti et al. (2019), ao estimar a massa do dossel de pastagens temperadas no Mato Grosso do Sul, observaram que a massa das pastagens apresentou alta relação com a altura ( $R^2 = 0,81$ ). Neste trabalho, a relação observada foi de  $R^2 = 0,72$  para a massa verde e  $R^2 = 0,62$  para a massa seca (dados não mostrados), corroborando a relevância da altura como variável preditora da massa de forragem. Isso é especialmente importante, pois a mensuração da altura no pasto é relativamente mais fácil, do que a coleta de forragem para análises subsequentes.

Schucknecht et al., (2022) avaliaram pastagens com ARP e sensores multiespectrais, obtendo um  $R^2$  de 0,67 para a massa seca e RMSE de 419 kg ha<sup>-1</sup>. Esse resultado foi similar ao encontrado neste estudo para o modelo RLM, com  $R^2$  de 0.71 e RMSE de 657,46 kg ha<sup>-1</sup> (Figura 16a). O maior erro encontrado neste estudo, pode ser atribuído à menor variabilidade dos dados, já que o estudo abrangeu apenas primavera e verão, com características mais homogêneas. Além disso, a alta correlação entre variáveis preditoras pode ter prejudicado o modelo, mascarando efeitos individuais. Logo, melhorias no conjunto de dados, com maior variação temporal e espacial, podem ajudar a aprimorar as predições.

Com relação às bandas espectrais, destaca-se o infravermelho próximo, amplamente utilizado na composição de diversos índices descritos na literatura. Neste trabalho, essa banda esteve presente em todos os 12 índices avaliados. Estudos apontam que o NIR apresenta melhor desempenho na estimativa da massa de culturas quando comparado às bandas espectrais RED, GREEN e BLUE (Viljanen et al., 2018; Bendig et al., 2015; Tilly et al., 2015). Essa banda além de contribuir para a melhor predição observada neste trabalho (Figura 15a), também se destacou na predição da altura (Tabela 5).

Quanto à altura, o uso do NIR como única variável preditora, demonstrou que um modelo simples pode superar modelos mais complexos, que utilizam múltiplas variáveis preditoras para prever a variável de interesse. Esses achados reforçam a importância de identificar variáveis-chave para otimizar tanto a eficiência quanto a acurácia das predições. Todavia, Abdullah et al., (2021) reportaram resultados superiores aos deste estudo, alcançando um  $R^2$  de 0,66 ao utilizarem modelos digitais de superfície e de terreno associados ao algoritmo Support Vector Machine, mas com uma ARP do tipo asa fixa e sensor multiespectral Parrot Sequoia.

Outros estudos encontraram valores mais baixos para altura ( $R^2 = 0.44$ ), como Barnetson et al., (2020), através do uso da relação linear de mínimos quadrados. Logo, todos esses resultados destacam a relevância do presente estudo, mostrando que, mesmo com abordagens distintas, as predições para altura podem ser aprimoradas pela escolha de modelos e equipamentos adequados ao contexto.

Neste contexto, algoritmos de Random Forest Regressor, apesar de sua maior complexidade, apresentaram desempenho inferior aos demais modelos. Isso pode ser atribuído ao ajuste excessivo (overfitting) do modelo aos dados de treinamento, aliado ao tamanho reduzido do conjunto de dados, o que limita sua capacidade de

generalização (Rosa et al., 2021; Chen et al., 2019). Além disso, Schucknecht et al., (2022) observaram uma redução significativa no desempenho de modelos RFR ao validar dados externos, destacando a importância de calibrações locais.

A concentração de MS e PB, foram as piores previsões deste estudo, isso provavelmente é devido à baixa variação ao longo do experimento, o que se reflete nos baixos coeficientes de variação (Tabela 1). Além disso, o estudo avaliou o pasto apenas em duas estações do ano, períodos em que o capim-braquiária apresentou altas concentrações de água, o que pode ter dificultado a previsão da concentração de matéria seca. Em contrapartida, estudos como o de Bretas et al., (2021), que incluíram períodos de seca, apresentaram maior variabilidade nos dados e, conseqüentemente, melhor desempenho preditivo para a concentração de MS. No entanto, tal estudo utilizou imagens obtidas por satélite.

Quanto à proteína bruta, essa é uma variável crucial no manejo de pastagens (Nishikawa et al., 2023). No entanto, o uso de câmeras multiespectrais neste estudo apresentou limitações na detecção de assinaturas espectrais sutis, necessárias para estimativas precisas de nitrogênio, como as informações localizadas na região do infravermelho de ondas curtas (Short Wave Infrared - SWIR) (Schucknecht et al., 2022). Dessa forma, o uso de câmeras hiperespectrais é mais adequado para essa finalidade, pois a maior parte da concentração de nitrogênio nas folhas está relacionada a pigmentos, como a clorofila, e a proteínas envolvidas na fotossíntese (Ollinger, 2011).

Alguns trabalhos, como o de Wijesingha et al., (2020), utilizaram ARP equipada com câmera hiperespectral para determinar a proteína bruta da forragem na Alemanha, obtendo  $R^2$  de 0.74 para o modelo de RFR. No referido estudo, foram avaliados 194 dados e a variação observada foi similar a deste estudo, com a proteína variando de 5 a 23%. Isso indica que o baixo coeficiente de variação observado (Tabela 1), não foi o fator responsável pela menor capacidade preditiva da proteína do pasto nos modelos propostos. Além disso, esse resultado demonstra que o sensoriamento remoto pode auxiliar no monitoramento do valor nutricional do pasto. Mas, os equipamentos e técnicas utilizados devem estar alinhados aos objetivos do estudo.

No estudo de Schucknecht et al., (2022), a previsão da concentração de nitrogênio das pastagens foi realizada com base no modelo RFR, com resultados de  $R^2$  de 0.47 e 0.43 para os sensores multiespectrais Parrot Sequoia e MicaSense

REDEDGE-M, respectivamente. Embora esses resultados não sejam excelentes, foram superiores aos encontrados neste estudo para proteína. Como a proteína está diretamente relacionada ao nitrogênio, esses resultados são pertinentes. No entanto, ao utilizar dados externos para validar o modelo, o  $R^2$  para a concentração de nitrogênio caiu drasticamente para 0.02 (Schucknecht et al., 2022). Isso reforça a necessidade de validação dos modelos a campo. Por isso, a importância e necessidade de considerar calibrações locais versus agregados no espaço e no tempo.

Para proteína pode-se explorar algoritmos de machine learning com base em modelos de transferência radiativa (Berger et al., 2020). Além de outras abordagens de modelagem, como colheita, crescimento das plantas, ou modelos biogeoquímicos assimilando dados de detecção (Berger et al., 2020). Porém, os equipamentos para essas e outras aquisições são muitas vezes inacessíveis e caros, dificultando a aquisição de informações das pastagens (Franco et al., 2023). Os resultados aqui encontrados juntamente com outros utilizando câmeras multiespectrais são condizentes, dado que é difícil imagens conseguirem estimar algo tão intrínseco das plantas.

Dessa forma, se faz necessário a continuação de outros estudos com a temática abordada, visando melhores resultados. Por exemplo, com o uso de diferentes câmeras, como a hiperespectral para predizer a qualidade do pasto, modelos digitais de superfície e terreno e sensor LiDAR para tentar predizer a altura. O LiDAR é um sensor ativo que não é afetado pelas condições de iluminação e permite capturar a estrutura tridimensional da vegetação (Bazzo et al., 2023). Além de diferentes modelos de predição, IV's não tão correlacionados entre si e principalmente ter um conjunto de dados maior. A abordagem empregada neste estudo também deve ser aprimorada e testada em diferentes ambientes, porque com variações no pasto, espaço e tempo se faz possível estruturar modelos de predição mais eficazes.

## 6. CONCLUSÕES

O uso de imagens multiespectrais obtidas por aeronaves remotamente pilotadas, associadas ao aprendizado de máquinas, mostrou-se uma ferramenta promissora para a predição de características estruturais do pasto, como massa de forragem verde e seca, ou altura do dossel em pastos de *Urochloa decumbens*. Este

trabalho obteve predições satisfatórias para essas variáveis, reforçando a aplicabilidade dessas tecnologias na gestão de pastagens. O acesso a essas informações pode auxiliar no ajuste da taxa de lotação animal e na identificação de manejos pontuais, como adubação.

Os modelos de regressão linear múltipla e simples apresentaram os melhores resultados, o que é positivo para a implementação prática, pois modelos mais simples e acessíveis podem ser utilizados no monitoramento de pastagens, inclusive em áreas de difícil acesso. Contudo, predições relacionadas ao valor nutricional, como proteína bruta, não foram satisfatórias, destacando as limitações das câmeras multiespectrais em capturar assinaturas espectrais específicas.

Além disso, a baixa variabilidade em alguns dados e a limitada dimensão do banco de dados foram fatores limitantes. Portanto, é essencial ampliar o conjunto de dados e explorar novas abordagens, como o uso de câmeras hiperespectrais, sensores LiDAR e modelos baseados em séries temporais e variações espaciais, para aprimorar o desempenho dos modelos. Portanto, estudos futuros devem priorizar essas estratégias, buscando otimizar a precisão das predições e ampliar a aplicabilidade das tecnologias na gestão sustentável de pastagens.

## **7. REFERÊNCIAS BIBLIOGRÁFICAS**

ABDULLAH, M. M. et al. The use of UAV-based remote sensing to estimate mass and carbon stock for native desert shrubs. *MethodsX*, v. 8, p. 2-8, 2021.

Agisoft portal de suporte técnico. Fluxo de trabalho de processamento do MicaSense Rededge MX (incluindo calibração de refletância) no Agisoft. Disponível em: <<https://agisoft.freshdesk.com/support/solutions/articles/31000148780-micasense-rededge-max-processing-workflow-reflectance-calibration-in-agisoft-metashape-pro>>. Acesso em: 20 de jul. 2024.

AHAMED, T. et al. Tower remote-sensing system for monitoring energy crops; image acquisition and geometric corrections. *Biosystems Engineering*, v. 112, n. 2, p. 93-107, 2012.

ALVAREZ-MENDOZA, C. I. et al. Predictive Modeling of Above-Ground Mass in Brachiaria Pastures from Satellite and UAV Imagery Using Machine Learning Approaches. *Remote Sensing*, v. 14, n. 22, p. 1-19, 2022.

- ATZBERGER, C. Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major information needs. *Remote Sens*, v. 5, p. 949-981, 2013.
- BAGHDADI, N. N. et al. Coupling SAR C-Band and Optical Data for Soil Moisture and Leaf Area Index Retrieval Over Irrigated Grasslands. *Ieee Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 9, n. 3, p. 1229-1243, 2016.
- BARETH, G.; SCHELLBERG, J. Replacing Manual Rising Plate Meter Measurements with Low-cost UAV-Derived Sward Height Data in Grasslands for Spatial Monitoring. *Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, p. 2-10, 2018.
- BARNETSON, J.; PHINN, S.; SCARTH, P. Estimating Plant Pasture Biomass and Quality from UAV Imaging across Queensland's Rangelands. *AgriEngineering*, v. 2, n. 4, p. 523-543, 2020.
- BATISTOTI, J. et al. Estimating pasture mass and canopy height in Brazilian Savanna using UAV photogrammetry. *Remote Sensing*, v. 11, n. 20, p. 1-12, 2019.
- BAZZO. C. O. G. et al. A Review of Estimation Methods for Aboveground Mass in Grasslands Using UAV. *Remote Sens*, v. 15, n. 639, p. 1-40, 2023.
- BENDIG, J. et al. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for mass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*, v. 39, p. 79-87, 2015
- BENDIG, J. et al. Estimating mass of barley using crop surface models (CSMs) derived from UAV-based RGB imaging. *Remote Sensing*, v. 6, n. 11, p. 10395-10412, 2014.
- BENGTSSON, J. et al. Grasslands - more important for ecosystem services than you might think. *Ecosphere*, v. 10, n. 2, p. 2-14, 2019.
- BERGER, K. et al. Retrieval of aboveground crop nitrogen content with a hybrid machine learning method. *International Journal of Applied Earth Observation and Geoinformation*, v. 92, p. 1-13, 2020.
- BRANTLEY, S. T. et al. Remote Sensing of Environment Application of hyperspectral vegetation indices to detect variations in high leaf area index temperate shrub thicket canopies. *Remote Sensing of Environment*, v. 115, n. 2, p. 514-523, 2011.
- BRETAS, I. L. et al. Prediction of aboveground biomass and dry-matter content in brachiaria pastures by combining meteorological data and satellite imagery. *Grass and Forage Science*, v. 76, n. 3, p. 340-352, 2021.

- BROCKS, S.; BARETH, G. Estimating barley biomass with crop surface models from oblique RGB imagery. *Remote Sensing*, v. 10, n. 2, p. 1-14, 2018.
- BROVELLI, M. A. et al. Accuracy assessment of high resolution satellite imagery orientation by leave-one-out method. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 63, n. 4, p. 427-440, 2008.
- CAPOLUPO, A. et al. Estimating plant traits of grasslands from UAV-acquired hyperspectral images: A comparison of statistical approaches. *ISPRS International Journal of Geo-Information*, v. 4, n. 4, p. 2792-2820, 2015.
- CARVALHO, F. B. P. Avaliação de pasto de capim-braquiária por sensoriamento aéreo e terrestre. Trabalho de Conclusão de Curso (Bacharelado em Agronomia) – Universidade Federal do Viçosa, Viçosa, 2020.
- CHEN, K.; O'LEARY, R. A.; EVANS, F. H. A simple and parsimonious generalised additive model for predicting wheat yield in a decision support tool. *Agricultural Systems*, v. 173, p. 140-150, 2019.
- COLOMINA, I; MOLINA, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 92, p. 79-97, 2014.
- CORRÊA, C. T. R. et al. GISH-based comparative genomic analysis in *Urochloa P. Beauv.* *Molecular Biology Reports*, v. 47, n. 2, p. 887-896, 2020.
- DASH, J.; CURRAN, P. J. Evaluation of the MERIS terrestrial chlorophyll index (MTCI). *Advances in Space Research*, v. 39, n. 1, p. 100-104, 2007.
- DAVID, E. et al. Global wheat head detection (GWHD) Dataset: A large and diverse dataset of high-resolution RGB-labelled images to develop and benchmark wheat head detection methods. *Plant Phenomics*, p. 2-11, 2020.
- DELEVATTI, L. M. et al. Effect of nitrogen application rate on yield, forage quality, and animal performance in a tropical pasture. *Scientific Reports*, v. 9, p. 1-9, 2019.
- DETMANN, E. et al. Métodos para análise de alimentos, INCT. Visconde do Rio Branco- MG. Universidade Federal de Viçosa, Departamento de Zootecnia, 214 p, 2012.
- D'OLIVEIRA, P. S. et al. Aplicações da agricultura de precisão em pastagens. *Embrapa*, n. 127, p. 2-23, 2023.
- DUAN, B. et al. Remote estimation of rice yield with unmanned aerial vehicle (UAV) data and spectral mixture analysis. *Frontiers in Plant Science*, v. 10, p. 2-12, 2019.

- DUNN, B. et al. Remote sensing PI nitrogen uptake in rice. REC Farmers' Newsletter, n. 195, p. 48-50, 2016.
- DUSSEUX, P. et al. Evaluation of SPOT imagery for the estimation of grassland mass. International Journal of Applied Earth Observations and Geoinformation, v. 38, p. 72-77, 2015.
- EISFELDER, C. et al. Net primary productivity in Kazakhstan, its spatio-temporal patterns and relation to meteorological variables. Journal of Arid Environments, v. 103, p. 17-30, 2014.
- ESPOSITO, M. et al. Drone and sensor technology for sustainable weed management: a review. Chemical and Biological Technologies in Agriculture, v. 8, n. 1, p. 1-11, 2021.
- FERN, R. R. et al. Suitability of NDVI and OSAVI as estimators of GREEN mass and coverage in a semi-arid rangeland. Ecological Indicators, v. 94, p. 16-21, 2018.
- FERNANDES, M. H. M. R. et al. Using Sentinel-2 satellite images and machine learning algorithms to predict tropical pasture forage mass, crude protein, and fiber concentration. Scientific Reports, v. 14, p. 1-12, 2024
- FERREIRA, G. C. V; FERREIRA NETO, J. A. Usos de geoprocessamento na avaliação de degradação de pastagens no assentamento Ilha do Coco, Nova Xavantina – Mato Grosso, Brasil. Revista Engenharia Na Agricultura - Reveng, v. 26, n. 2, p. 140-148, 2018.
- FILHO, M. G. et al. Estimating natural grassland mass by vegetation indices using Sentinel 2 remote sensing data. International Journal of Remote Sensing, v. 41, n. 8, p. 2861-2876, 2019.
- FRANCO, V. R. et al. Hybrid machine learning methods combined with computer vision approaches to estimate biophysical parameters of pastures. Evolutionary Intelligence, v. 16, n. 4, p. 1271-1284, 2023.
- FRASER, R. H.; LATIFOVIC, R. Mapping insect-induced tree defoliation and mortality using coarse spatial resolution satellite imagery. International Journal of Remote Sensing, v. 26, n. 1, p. 193-200, 2005.
- GAMON, J. A. et al. A Narrow-Waveband Spectral Index That Tracks Diurnal Changes in Photosynthetic Efficiency. Remote Sens. Environ., v. 41, p. 35-44, 1992.
- GÉE, C. et al. Evaluation of weed impact on wheat biomass by combining visible imagery with a plant growth model: towards new non-destructive indicators for weed competition. Precision Agriculture, v. 22, n. 2, p. 550-568, 2021.

- GITELSON, A. A. et al. Remote estimation of canopy chlorophyll content in crops. *Geophysical Research Letters*, v. 32, n. 8, p. 1-4, 2005.
- GITELSON, A. A. et al. Use of a GREEN channel in remote sensing of global vegetation from EOS- MODIS. *Remote Sensing of Environment*, v. 58, n. 3, p. 289-298, 1996.
- GU, Y. et al. Identifying grasslands suitable for cellulosic feedstock crops in the Greater Platte River Basin: dynamic modeling of ecosystem performance with 250 m e MODIS. *GCB Bioenergy*, v. 4, p. 96-106, 2012.
- GU, Y; WYLIE. B. K. Detecting Ecosystem Performance Anomalies for Land Management in the Upper Colorado River Basin Using Satellite Observations, Climate Data, and Ecosystem Models. *Remote Sens*, v. 2, p. 1880-1891, 2010.
- HARDIN, P.; JENSEN, R. Small-scale unmanned aerial vehicles in environmental remote sensing: Challenges and opportunities. *GIScience and Remote Sensing*, v. 48, n. 1, p. 99-111, 2011.
- HILL, M. J. et al. Relationships between vegetation indices, fractional cover retrievals and the structure and composition of Brazilian Cerrado natural vegetation. *International Journal of Remote Sensing*, v. 38, n. 3, p. 874-905, 2017.
- HILL, M. J. Remote Sensing of Environment Vegetation index suites as indicators of vegetation state in grassland and savanna: An analysis with simulated SENTINEL 2 data for a North American transect. *Remote Sensing of Environment*, v. 137, p. 94-111, 2013.
- HOPPING, K. A. et al. Linking people, pixels, and pastures: A multi-method, interdisciplinary investigation of how rangeland management affects vegetation on the Tibetan Plateau. *Applied Geography*, v. 94, p. 147-162, 2018.
- HUANG, S. et al. A commentary review on the use of normalized difference vegetation index (NDVI) in the era of popular remote sensing. *Journal of Forestry Research*, v. 32, n. 1, p. 1-6, 2021.
- HUETE, A. R. A Soil-Adjusted Vegetation Index (SAVI). Elsevier Science Publishing, v. 25, n. 52, p. 295-309, 1988.
- IATEC. Micasense Rededge-MX Multispectral 5-bandas (versão Nova). Disponível em: <<https://www.iatecps.com/product-page/micasense-rededge-mx-multispectral-5-bandas-vers%C3%A3o-nova>>. Acesso em: 20 de jun. 2024.

- IBGE. Rebanho de bovinos (bois e vacas). 2022. Disponível em: <<https://www.ibge.gov.br/explica/producao-agropecuaria/bovinos/br>>. Acesso em: 13 de jan. 2023.
- IMMITZER, M. et al. First Experience with Sentinel-2 Data for Crop and Tree Species Classifications in Central Europe. *Remote Sens*, v. 8, p. 1-23, 2016.
- INMET. Instituto Nacional de Meteorologia. Disponível em: <<https://bdmep.inmet.gov.br/#>>. Acesso em: 21 de fev. 2024.
- INSUA, J. R. et al. Estimation of spatial and temporal variability of pasture growth and digestibility in grazing rotations coupling unmanned aerial vehicle (UAV) with crop simulation models. *PLOS ONE*, p. 1-21, 2019.
- JANK, L. et al. The value of improved pastures to Brazilian beef production. *Crop & Pasture Science*, v. 65, p. 1132-1137, 2014.
- JIA, W. et al. Estimation and uncertainty analyses of grassland mass in Northern China: Comparison of multiple remote sensing data sources and modeling approaches. *Ecological Indicators*, v. 60, p. 1031-1040, 2016.
- JIANG, Z. et al. Development of a two-band enhanced vegetation index without a BLUE band. *Remote Sensing of Environment*, v. 112, n. 10, p. 3833-3845, 2008.
- JIN, Y. et al. Remote sensing-based biomass estimation and its spatio-temporal variations in temperate Grassland, Northern China. *Remote Sensing*, v. 6, n. 2, p. 1496-1513, 2014.
- JÚNIOR, R. F. V. Diagnosis of degraded pastures using an improved NDVI-based remote sensing approach: An application to the Environmental Protection Area of Uberaba River Basin (Minas Gerais, Brazil). *Remote Sensing Applications: Society and Environment*, v. 14, p. 20-33, 2019.
- KELLER, E. et al. Climatic factors influencing New Zealand pasture resilience under scenarios of future climate change. *NZGA: Research and Practice Series*, v. 17, p. 105-122, 2021.
- KLEMAS, V. Remote sensing of coastal wetland mass: An overview. *Journal of Coastal Research*, v. 29, n. 5, p. 1016-1028, 2013.
- LATI, R. N. et al. Estimating plant growth parameters using an energy minimization-based stereovision model. *Computers and Electronics in Agriculture*, v. 98, p. 260-271, 2013.
- LEGG, M.; BRADLEY, S. Ultrasonic arrays for remote sensing of pasture mass. *Remote Sensing*, v. 12, n. 1, p. 1-20, 2020.

- LI, F. et al. Improving estimates of grassland fractional vegetation cover based on a pixel dichotomy model: A case study in Inner Mongolia, China. *Remote Sensing*, v. 6, n. 6, p. 4705-4722, 2014.
- LI, F. et al. Improving estimation of summer maize nitrogen status with red edge-based spectral vegetation indices. *Field Crops Research*, v. 157, p. 111-123, 2014.
- LISBOA, A. M. Sensoriamento remoto na avaliação de pasto de *Brachiaria decumbens*. UFV, p. 1-45, 2020.
- LIU, Y. et al. Efficient extraction of deep image features using convolutional neural network (CNN) for applications in detecting and analysing complex food matrices. *Trends in Food Science and Technology*, v. 113, p. 193-204, 2021.
- LÓPEZ, J. J.; MULERO-PÁZMÁNY, M. Drones for conservation in protected areas: Present and future. *Drones*, v. 3, n. 1, p. 1-23, 2019.
- LU, B.; HE, Y. Species classification using Unmanned Aerial Vehicle (UAV)-acquired high spatial resolution imagery in a heterogeneous grassland. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 128, p. 73-85, 2017.
- LUGASSI, R. et al. Estimating pasture quality of fresh vegetation based on spectral slope of mixed data of dry and fresh vegetation-method development. *Remote Sensing*, v. 7, n. 6, p. 8045-8066, 2015.
- LUSSEM, U. et al. Estimating mass in temperate grassland with high resolution canopy surface models from UAV-based RGB images and vegetation indices. *Journal of Applied Remote Sensing*, v. 13, n. 03, p. 1-18, 2019.
- MACHADO, V. D. et al. Grazing management strategies for *Urochloa decumbens* (Stapf) R. Webster in a silvopastoral system under rotational stocking. *Grass and Forage Science*, p. 266-278, 2020.
- MAES, W. H.; STEPPE, K. Perspectives for Remote Sensing with Unmanned Aerial Vehicles in Precision Agriculture. *Trends in Plant Science*, v. 24, n. 2, p. 152-164, 2019.
- MAIMAITIJIANG, M. et al. Crop monitoring using satellite/UAV data fusion and machine learning. *Remote Sensing*, v. 12, n. 9, p. 1-17, 2020.
- MANFREDA, S. et al. On the use of unmanned aerial systems for environmental monitoring. *Remote Sensing*, v. 10, n. 4, p. 2-20, 2018.
- MARTINS, F. B., et al. Classificação Climática De Köppen E De Thornthwaite Para Minas Gerais: Cenário Atual E Projeções Futuras. *Revista Brasileira de Climatologia*, v. 1, p. 129-156, 2018.

- MERZLYAK, M. N. et al. Non-destructive optical detection of pigment changes during leaf senescence and fruit ripening. *Physiologia Plantarum*, v. 106, n. 1, p. 135-141, 1999.
- MICHEZ, A. et al. Mapping and monitoring of mass and grazing in pasture with an unmanned aerial system. *Remote Sensing*, v. 11, n. 5, p. 2-14, 2019.
- MOECKEL, T. et al. Estimation of vegetable crop parameter by multi-temporal UAV-borne images. *Remote Sensing*, v. 10, n. 5, p. 1-18, 2018.
- MOROTA, G. et al. Big data analytics and precision animal agriculture symposium: Machine learning and data mining advance predictive big data analysis in precision animal agriculture. *Journal of Animal Science*, v. 96, n. 4, p. 1540-1550, 2018.
- MULLA, D. J. Twenty-five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. *Biosystems Engineering*, v. 114, n. 4, p. 358-371, 2013.
- NANDHINI, N; BHAVANI, R. Feature Extraction for Diseased Leaf Image Classification using Machine Learning. *International Conference on Computer Communication and Informatics*, p. 1-4, 2020.
- NISHIKAWA, H. et al. Dry Matter Yield and Nitrogen Content Estimation in Grassland Using Hyperspectral Sensor. *Remote Sensing*, v. 15, n. 2, p. 1-15, 2023.
- OJIMA, D. S. et al. Social-Ecological Vulnerability of Grassland Ecosystems. *Climate Vulnerability: Understanding and Addressing Threats to Essential Resources*, v. 4, p. 151–162, 2013.
- OLLINGER, S. V. Sources of variability in canopy reflectance and the convergent properties of plants. *New Phytologist*, v. 189, n. 2, p. 375-394, 2011.
- OTGONBAYAR, M. et al. Mapping pasture mass in Mongolia using Partial Least Squares, Random Forest regression and Landsat 8 imagery. *International Journal of Remote Sensing*, p. 1-23, 2018.
- PAN, Z. et al. Mapping crop phenology using NDVI time-series derived from HJ-1 A/B data. *International Journal of Applied Earth Observation and Geoinformation*, v. 34, n. 1, p. 188-197, 2015.
- PEREIRA, O. J. R. et al. Assessing pasture degradation in the Brazilian Cerrado based on the analysis of MODIS NDVI time-series. *Remote Sensing*, v. 10, n. 11, p. 1-12, 2018.

- POLLEY, H. W. et al. Climate change and North American rangelands: Trends, projections, and implications. *Rangeland Ecology and Management*, v. 66, n. 5, p. 493-511, 2013.
- PRANGA, J. et al. Improving accuracy of herbage yield predictions in perennial ryegrass with UAV-based structural and spectral data fusion and machine learning. *Remote Sensing*, v. 13, n. 17, p. 1-23, 2021.
- Projeto MapBiomias. Mapeamento anual de cobertura e uso da terra no Brasil entre 1985 a 2022. Coleção 8, 2022. Disponível em: <[https://brasil.mapbiomas.org/wp-concentration/uploads/sites/4/2023/10/FACT\\_MapBiomias\\_Agropecuaria\\_04.10\\_v2.pdf](https://brasil.mapbiomas.org/wp-concentration/uploads/sites/4/2023/10/FACT_MapBiomias_Agropecuaria_04.10_v2.pdf)>. Acesso em: 9 de set. 2023.
- PUNALEKAR, S. M. et al. Application of Sentinel-2A data for pasture mass monitoring using a physically based radiative transfer model. *Remote Sensing of Environment*, v. 218, p. 207-220, 2018.
- Python Software Foundation. (2024). Python (Version 3.11). Disponível em: <<https://www.python.org>>.
- QUEMADA, M. et al. Airborne hyperspectral images and ground-level optical sensors as assessment tools for maize nitrogen fertilization. *Remote Sensing*, v. 6, n. 4, p. 2940-2962, 2014.
- RAHIM, H. R. B. A. et al. Applied light-side coupling with optimized spiral-patterned zinc oxide nanorod coatings for multiple optical channel alcohol vapor sensing. *Journal of Nanophotonics*, v. 10, n. 3, p. 1-16, 2016.
- RONDEAUX, G. et al. Optimization of Soil-Adjusted Vegetation Indices. *Remote Sens. Environ.*, v. 107, p. 95-107, 1996.
- ROSA, D. D. et al. Predicting pasture biomass using a statistical model and machine learning algorithm implemented with remotely sensed imagery. *Computers and Electronics in Agriculture*, v. 180, 2021.
- SAKAMOTO, T. et al. An alternative method using digital cameras for continuous monitoring of crop status. *Agricultural and Forest Meconcentraçãoology*, v. 154–155, p. 113–126, 2012.
- SALAMÍ, E. et al. UAV flight experiments applied to the remote sensing of vegetated areas. *Remote Sensing*, v. 6, n. 11, p. 11051-11081, 2014.
- SANGJAN, W. et al. Pasture Productivity Assessment under Mob Grazing and Fertility Management Using Satellite and UAS Imagery. *Drones*, v. 6, n. 9, p. 1-14, 2022.

- SCHUCKNECHT, A. et al. Estimating dry biomass and plant nitrogen concentration in pre-Alpine grasslands with low-cost UAS-borne multispectral data-a comparison of sensors, algorithms, and predictor sets. *Biogeosciences*, v. 19, n. 10, p. 2699-2727, 2022.
- SCHUSTER, C. et al. Grassland habitat mapping by intra-annual time series analysis -Comparison of RapidEye and TerraSAR-X satellite data. *International Journal of Applied Earth Observation and Geoinformation*, v. 34, n. 1, p. 25-34, 2015.
- SERRANO, J. et al. Evaluation of near infrared spectroscopy (NIRS) and remote sensing (RS) for estimating pasture quality in Mediterranean montado ecosystem. *Applied Sciences (Switzerland)*, v. 10, n. 13, 2020.
- SERRANO, J. et al. Monitoring seasonal Pasture Quality Degradation in the Mediterranean montado ecosystem: Proximal versus remote sensing. *Water (Switzerland)*, v. 10, n. 10, 2018.
- SERRANO, J. et al. Tree influence on soil and pasture: contribution of proximal sensing to pasture productivity and quality estimation in montado ecosystems. *International Journal of Remote Sensing*, v. 39, n. 14, p. 4801-4829, 2017.
- SHIRATSUCHI, L. S. et al. Sensoriamento Remoto: conceitos básicos e aplicações na Agricultura de Precisão. *Embrapa*, v. 4, p. 59-69, 2014.
- SONOBE, R. et al. Crop classification from Sentinel-2-derived vegetation indices using ensemble learning. *Journal of Applied Remote Sensing*, v. 12, n. 02, p. 1, 2018.
- SOUSA, M. F. F. Avaliação de degradação de pastagens com o uso de sensoriamento remoto e índices de vegetação. *Enciclopédia Biosfera, Centro Científico Conhecer*, v. 19, n. 39, p. 48-57, 2022.
- TILLY, N.; AASEN, H.; BARETH, G. Fusion of plant height and vegetation indices for the estimation of barley biomass. *Remote Sensing*, v. 7, n. 9, p. 11449-11480, 2015.
- TUCKER, C. J. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, v. 8, n. 2, p. 127-150, 1979.
- TURNER, D. et al. An automated technique for generating georectified mosaics from ultra-high resolution Unmanned Aerial Vehicle (UAV) imagery, based on Structure from Motion (SfM) point clouds. *Remote Sensing*, v. 4, n. 5, p. 1392-1410, 2012.
- VELOSO, G. A. et al. For a greater efficiency of the Brazilian pastures: analysis of gross primary productivity with CASA model and satellite data. *Caderno de Geografia*, v. 32, n. 71, p. 1150-1171, 2022.

- VILJANEN, N. et al. A novel machine learning method for estimating biomass of grass swards using a photogrammetric canopy height model, images and vegetation indices captured by a drone. *Agriculture (Switzerland)*, v. 8, n. 5, p. 2-21, 2018.
- VILLA, P. et al. Comparative assessment of broadband vegetation indices over aquatic vegetation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, v. 7, n. 7, p. 3117-3127, 2014.
- VON BUEREN, S. K. et al. Deploying four optical UAV-based sensors over grassland: Challenges and limitations. *Biogeosciences*, v. 12, n. 1, p. 163-175, 2015.
- WACHENDORF, M. Remote sensing as a tool to assess botanical composition, structure, quantity and quality of temperate grasslands. *Grass and Forage Science*, p. 1-14, 2017.
- WANG, Y. et al. Prediction of aboveground grassland mass on the Loess Plateau, China, using a random forest algorithm. *Scientific Reports*, v. 7, n. 1, p. 1-10, 2017.
- WIJESINGHA, J. et al. Predicting Forage Quality of Grasslands Using UAV-Borne Imaging Spectroscopy. *Remote Sens*, v. 12, p. 1-20, 2020.
- WYLIE, B. K. et al. Integrating modelling and remote sensing to identify ecosystem performance anomalies in the boreal forest, yukon river basin, Alaska. *International Journal of Digital Earth*, v. 1, n. 2, p. 196-220, 2008.
- XIANG, H.; TIAN, L. Development of a low-cost agricultural remote sensing system based on an autonomous unmanned aerial vehicle (UAV). *Biosystems Engineering*, v. 108, n. 2, p. 174-190, 2011.
- XUE, J.; SU, B. Significant remote sensing vegetation indices: A review of developments and applications. *Journal of Sensors*, p. 1-7, 2017.
- ZHANG, C.; KOVACS, J. M. The application of small unmanned aerial systems for precision agriculture: A review. *Precision Agriculture*, v. 13, n. 6, p. 693-712, 2012.
- ZHANG, L. et al. Upscaling carbon fluxes over the Great Plains grasslands: Sinks and sources. *Journal of Geophysical Research*, v. 116, n. 1, p. 1-11, 2011.