

PRISCILA DORNELAS VALOTE

**PREDIÇÃO DE ALTURA E CONCENTRAÇÃO DE PROTEÍNA BRUTA DE
CAPIM-BRAQUIÁRIA A PARTIR DE DADOS DE SENSORIAMENTO REMOTO**

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

Orientadora: Fernanda Helena Martins Chizzotti

Coorientadores: Domingos Sárvio Magalhães Valente
Érica Beatriz Schultz

**VIÇOSA - MINAS GERAIS
2023**

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

T

V199p
2023

Valote, Priscila Dornelas, 1993-
Predição de altura e concentração de proteína bruta de capim-
braquiária a partir de dados de sensoriamento remoto: / Priscila
Dornelas Valote. - Viçosa, MG, 2023.
1 tese eletrônica (95 f.): il. (algumas color.).
Orientador: Fernanda Helena Martins Chizzotti
Tese (doutorado) - Universidade Federal de Viçosa, Departamento
de Zootecnia, 2023.
Inclui bibliografia.
DOI: <https://doi.org/10.47328/ufvbbt.2023.770>
Modo de acesso: World Wide Web.

1. Braquiária decumbens; 2. Pastagens - Manejo; 3. Inteligência
artificial; I. Chizzotti, Fernanda Helena Martins II. Universidade
Federal de Viçosa.. Departamento de Zootecnia. Programa de Pós-
Graduação em Zootecnia III. Título

CDD 22. ed. 633.202


PRISCILA DORNELAS VALOTE

**PREDIÇÃO DE ALTURA E CONCENTRAÇÃO DE PROTEÍNA BRUTA DE
CAPIM-BRAQUIÁRIA A PARTIR DE DADOS DE SENSORIAMENTO REMOTO**


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

APROVADA: 22 de setembro de 2023.

Assentimento:

Documento assinado digitalmente
 PRISCILA DORNELAS VALOTE
Data: 19/12/2023 18:15:20-0300
Verifique em <https://validar.iti.gov.br>

Priscila Dornelas Valote
(Autora)

Documento assinado digitalmente
 FERNANDA HELENA MARTINS CHIZZOTTI
Data: 20/12/2023 09:56:57-0300
Verifique em <https://validar.iti.gov.br>

Fernanda Helena Martins Chizzotti
(Orientadora)

À minha amada avó, Maria da Glória Henaut (in memoriam).

AGRADECIMENTOS

Acredito que tudo na vida deve ser feito com amor. E esse trabalho é a extensão da minha vida. Até aqui, tudo foi possível graças a Deus e sua infinita bondade comigo. Por isso, eu agradeço primeiramente a Ele.

Sigo com a consciência que fiz o meu melhor. E não foi fácil. Durante esse caminho, eu enfrentei duras batalhas, que jamais serão esquecidas. A mais sofrida delas com certeza foi perder a minha amada avó, Maria da Glória Henaut. Quando eu comecei a escrever esses agradecimentos, ela ainda estava entre nós. Mas, a Covid-19 passou como um “furacão” nas nossas vidas. E, infelizmente, ela foi morar com Deus.

Minha avó foi a pessoa que tornou tudo na minha vida possível. E eu sequer me despedi dela. Nesse momento, cheguei a pensar em desistir de tudo, inclusive deste trabalho e até de mim. Busquei forças onde nem sabia que existia, e continuei pela memória dela. Eu sei o quanto ela se orgulhava de mim. Então, depois de Deus, eu agradeço a ela: minha vó. Que sempre foi meu anjo na Terra e agora é meu anjo no Céu.

Em terceiro lugar, e não menos importante, fica minha eterna gratidão a todos que serviram de alicerce para mim e para minha pesquisa na UFV. Durante meu doutorado, conheci pessoas que tornaram a jornada mais leve. Agradeço aos meus amigos, estagiários, funcionários e professores. Cada um deles ocupa um pedacinho do meu coração.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG).

Que essa tese não seja o fim, e sim o começo de muitas jornadas em minha vida.

“Tem gente que muda o coração da gente”.

RESUMO

VALOTE, Priscila Dornelas, D.Sc., Universidade Federal de Viçosa, agosto de 2023. **Predição de altura e concentração de proteína bruta de capim-braquiária a partir de dados de Sensoriamento Remoto.** Orientadora: Fernanda Helena Martins Chizzotti. Coorientadores: Domingos Sárvio Magalhães Valente e Érica Beatriz Schultz.

Para a composição da tese foram preparados dois capítulos que consistiram na avaliação de modelo de predição automatizada de classes de altura e da concentração de proteína bruta (PB) dos pastos de *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Basilisk. Tais modelos foram criados a partir de dados mensurados a campo, análises de imagens aéreas multiespectrais processadas para extração dos valores médios e desvio padrão da média dos Índices de Vegetação e do algoritmo *Random Forest*. As imagens foram filtradas a partir da média dos valores de *Normalized Difference Vegetation Index* (NDVI) com objetivo de remover *pixels* irrelevantes. **Capítulo 1** – Foram obtidas imagens multiespectrais por Veículo Aéreo Não Tripulado (VANT) semanalmente entre os anos de 2019 e 2021 em 30 canteiros de 3 m² de *U. decumbens* com diferentes idades de rebrotação, totalizando 40 voos. As alturas aferidas ao longo do período experimental foram agrupadas em três classes: alturas inferiores a 12 cm (Classe 0); entre 12 cm e 20 cm (Classe 1) e alturas superiores a 20 cm (Classe 2). Foi observada acurácia global dos dados de 58.66% e valores de precisão de 39.19%, 60.20% e 46.15%, respectivamente para as Classes 0, 1 e 2 de altura. Os melhores IVs ranqueados de acordo com a importância (%) na participação do modelo foram o desvio padrão do *Chlorophyll Vegetation Index* (CVI) na máscara de filtragem NDVI > 0.40 (14.93% de importância), seguido pelo desvio padrão do *Transformed Vegetation Index* (TVI) e *Structure Insensitive Pigment Index* (SIPI) nas máscaras de filtragem NDVI > 0.40 e NDVI > 0.20, com 11.97% e 11.95% de importância, respectivamente. No entanto, o desbalanço entre as classes de altura inferiu em maiores probabilidades de acerto de predição para a Classe 1. Em análise individual de voo testado pelo modelo, mais de 93% das classificações das alturas foram preditas corretamente. O modelo representa o estágio inicial de desenvolvimento de uma importante ferramenta para o manejo de pastagens baseado na classificação da altura que precisa ser aprofundado. **Capítulo 2** – Foram obtidas

imagens multiespectrais a partir de VANT entre os anos de 2019 e 2021 em 30 canteiros de 3 m² de capim-braquiária com diferentes idades de rebrotação, totalizando 20 voos. As imagens foram processadas para extração dos valores médios e desvio padrão da média dos Índices de Vegetação (IVs). Utilizou-se o algoritmo *Random Forest* para desenvolver o modelo de predição da concentração de PB em % da matéria seca (MS) com base em dados de referência coletados a campo e estimados em laboratório. Os resultados demonstraram que 40.52% (R²) dos dados se ajustam ao modelo de regressão através dos IVs selecionados com erros de 2.13% de PB na matéria seca (MS) dos pastos de *U. decumbens* (Sin. *B. decumbens*) cv. Basilisk. Afirmamos o desafio de estimar a concentração de PB dos pastos de forma remota e esforços devem ser direcionados a fim de aumentar o ajuste no modelo e reduzir os erros na predição desta variável. Sugere-se o estudo aprofundado do *Enhanced Vegetation Index* (EVI), *Leaf Chlorophyll Index* (LCI), *Photochemical Reflectance Index* (PRI) e *Ratio Vegetation Index* (RVI) que participaram efetivamente do modelo e foram bem correlacionados de forma a atingir os objetivos propostos num futuro próximo. Por fim, outras técnicas de análises de dados para predição de PB devem ser avaliadas, assim como outras variáveis no modelo como dados meteorológicos e bandas espectrais, o que pode auxiliar no desenvolvimento de modelos capazes de prever esta variável com maior precisão e acurácia.

Palavras-chaves: Inteligência Artificial. Manejo dos pastos. *Random Forest*. VANTS. Zootecnia de Precisão.

ABSTRACT

VALOTE, Priscila Dornelas, D.Sc., Universidade Federal de Viçosa, september, 2023. **Prediction of canopy height and crude protein concentration of signalgrass from remote sensing imagery.** Adviser: Fernanda Helena Martins Chizzotti. Co-advisers: Domingos Sárvio Magalhães Valente and Érica Beatriz Schultz.

The thesis consists of two chapters devoted to the evaluation of an automated prediction model of canopy height classes and crude protein (CP) concentration of *Urochloa decumbens* (Syn. *Brachiaria decumbens*) cv. Basilisk. Such models were created from data measured in the field and analysis of multispectral aerial images to extract the average values and standard deviation of the vegetation indices (VI) to classify the canopy height and predict the CP concentration using the Random Forest algorithm. The images were filtered from the average Normalized Difference Vegetation Index (NDVI) values to remove irrelevant pixels. **Chapter 1** – Multispectral images were obtained by Unmanned Aerial Vehicle (UAV) weekly between 2019 and 2021 in 30 plots (3 m²) of *U. decumbens* with different regrowth ages, totaling 40 flights. Canopy heights were measured over the experimental period and grouped into three classes: heights less than 12 cm (Class 0); between 12 cm and 20 cm (Class 1) and heights greater than 20 cm (Class 2). Overall data accuracy of 58.66% and precision values of 39.19%, 60.20%, and 46.15% were observed for canopy height classes 0, 1, and 2, respectively. The best-ranked IV according to importance (%) to the model were the Chlorophyll Vegetation Index (CVI) standard deviation in the NDVI filter mask > 0.40 (14.93% importance), followed by the Transformed Vegetation Index standard deviation (TVI) and Structure Insensitive Pigment Index (SIPI) in the filtering masks NDVI > 0.40 and NDVI > 0.20, with 11.97% and 11.95% of importance, respectively, which demonstrates their potential for pasture canopy height predictions. However, the mismatch between the canopy height classes resulted in higher probabilities of correct prediction for Class 1. In an individual analysis of the flight tested by the model, more than 93% of the canopy height classifications were correctly predicted. The model represents the initial stage of development of an important tool for pasture management based on canopy height classification that needs to be improved. **Chapter 2** – Multispectral images were obtained from UAV between 2019 and 2021 in 30 plots (3 m²) with different regrowth ages, totaling 20 flights. The images were

processed to extract the average and standard deviation of the average VI. The Random Forest algorithm was used to develop the prediction model for CP concentration in % of dry matter (DM) based on reference data collected in the field and estimated in the laboratory. The results demonstrated that 40.52% (R^2) of the data fitted the regression model through the selected VI with errors of 2.13% of CP in the DM of pastures of *U. decumbens* (Syn. *B. decumbens*) cv. Basilisk. We state the challenge of estimating the CP concentration of pastures remotely and efforts must be made to increase the model performance. It is suggested further studies of the Enhanced Vegetation Index (EVI), Leaf Chlorophyll Index (LCI), Photochemical Reflectance Index (PRI), and Ratio Vegetation Index (RVI) that effectively participated in the model and were well correlated to CP concentration to achieve the proposed objectives shortly. Finally, other data analysis techniques for PB prediction must be evaluated, as well as other features in the model such as meteorological data and spectral bands, which can assist in the development of models capable of predicting this variable with greater precision and accuracy.

Keywords: Artificial Intelligence. Pasture management. Random Forest. UAV. Precision livestock farming.

SUMÁRIO

INTRODUÇÃO GERAL	12
REFERÊNCIAS.....	15
CAPÍTULO I - CLASSIFICAÇÃO AUTOMATIZADA DA ALTURA DE PASTOS DE CAPIM-BRAQUIÁRIA A PARTIR DE TÉCNICAS DE SENSORIAMENTO REMOTO E APRENDIZADO DE MÁQUINAS.	20
RESUMO.....	20
1. INTRODUÇÃO	21
2. MATERIAL E MÉTODOS	24
2.1. Localização e descrição da área de estudo	24
2.2. Dados de campo	26
2.3. Pré-processamento e construção dos ortomosaicos.....	29
2.4. Índices de Vegetação	29
2.5. Modelagem.....	32
3. RESULTADOS	36
3.1. Classificação das alturas e seleção do número de <i>features</i>	36
3.2. Matriz de confusão dos dados de teste	38
3.3. Probabilidades.....	39
4. DISCUSSÃO	41
5. CONCLUSÃO.....	47
REFERÊNCIAS.....	48
CAPÍTULO II - DETERMINAÇÃO AUTOMATIZADA DA CONCENTRAÇÃO DE PROTEÍNA BRUTA DE CAPIM-BRAQUIÁRIA VIA SENSORIAMENTO REMOTO E MODELO DE APRENDIZADO DE MÁQUINAS.....	61
RESUMO.....	61
1. INTRODUÇÃO	62
2. MATERIAL E MÉTODOS	65
2.1. Localização e descrição da área de estudo	65
2.2. Dados de campo	67
2.3. Pré - processamento e construção dos ortomosaicos.....	70
2.4. Índices de Vegetação	70
2.5. Modelagem.....	73
3. RESULTADOS	75
3.1. Seleção do número de <i>features</i> e correlações	75
3.2. Predições	77
4. DISCUSSÃO	78
5. CONCLUSÃO.....	82

REFERÊNCIAS.....	83
------------------	----

INTRODUÇÃO GERAL

As áreas de pastagens ocupam cerca de 160 milhões de hectares (IBGE, 2017) e desempenham papel essencial nos sistemas de produção pecuária em todo mundo através do provimento de diversos serviços ecossistêmicos (Z. Li et al., 2015). Estas plantas contribuem para a manutenção da biodiversidade, complexidade das interações bióticas, conservação da água e do solo entre outros (*Millennium Ecosystem Assessment*, 2005). Ainda, são responsáveis pela alimentação de cerca de 1.5 bilhões de bovinos, 1.2 bilhões de ovinos, 1 bilhão de cabras e 0.2 bilhões de búfalos em todo o mundo (FAOSTAT, 2016).

Considerando-se a importância da pastagem no cenário mundial, a manutenção da estrutura do pasto e o conhecimento da qualidade nutricional da planta forrageira são ações que podem garantir melhores resultados em desempenho animal (da Silva et al., 2015). Além disso, estas ações influenciam positivamente na sustentabilidade desses sistemas e são indispensáveis para otimização do gerenciamento dos pastos (Bendig et al., 2014).

Entretanto, as ferramentas e os métodos utilizados para monitoramento de pastagens baseiam-se principalmente em levantamentos de campo caracterizados por serem além de destrutivos, onerosos e demorados (Borra-Serrano et al., 2019; Castro et al., 2020; Delevatti et al., 2019; Ma et al., 2019). Somado a isso, a variabilidade de espécies, relevo e solo, comprometem a estimativa para toda área e implicam na redução da precisão dos dados coletados (Bretas et al., 2021). Nesses casos, o uso de métodos indiretos e modernos podem ser mais rápidos e eficazes para obter as informações acerca das pastagens.

Devido ao avanço da tecnologia e a partir de estudos que envolvem zootecnia e agricultura de precisão, muitas atividades dentro das fazendas foram otimizadas (Leiva et al., 2017). O Sensoriamento Remoto (SR) compreende um desses avanços, que, somado ao uso de técnicas de inteligência artificial (IA), trouxeram grandes contribuições para a produção no campo de forma rápida, dinâmica, indireta e precisa (Wachendorf et al., 2018).

A partir de sensores remotos é possível coletar informações em larga escala do alvo em estudo. Os dados baseados em sensores são gerados em alta velocidade e em diferentes formatos, criando um “*big data*” que excede a capacidade de análise pelas ferramentas tradicionais (Morota et. al 2018). E, é por isso então, que a IA tem

sido cada vez mais utilizada nos últimos anos para enfrentar o desafio da complexidade dos dados e ainda, a não linearidade dos mesmos (Ali et al. 2015; Morota et al. 2018). Entre as principais ferramentas utilizadas em IA, as técnicas de Aprendizado de Máquinas (AM) têm ganhado destaque devido à capacidade de automatizar a análise de “*big data*”. Algoritmos de AM podem reconhecer padrões em conjuntos de dados complexos e resolver problemas de classificação de forma rápida e automática ou diversas regressões. Assim, configura-se uma alternativa rápida, dinâmica e precisa em relação às avaliações a nível de campo tradicionalmente estabelecidas (Leiva et al., 2017).

Dentre as tecnologias de SR, destacam-se o uso de imagens obtidas via satélite e a utilização de Veículos Aéreos Não Tripulados (VANTS), como instrumentos de coleta de dados. O SR por satélite oferece grande possibilidade de monitoramento de culturas em larga escala (Yan et al., 2021). No entanto, vários estudos destacaram condições climáticas adversas (por exemplo, cobertura de nuvens) e a baixa resolução temporal resultante como as principais limitações do uso de satélites para monitoramento das pastagens (Barrett et al., 2014; Wang et al., 2019; Murphy et al., 2021).

Já os VANTS, surgem como uma promissora plataforma de SR devido à sua flexibilidade (Yao et al., 2019) e foram amplamente investigados para monitoramento de culturas com sensores de imagem (S. Li et al., 2021; Maresma et al., 2016; Wang et al., 2021). A partir de sensores a bordo de VANTS é possível rastrear pequenas áreas com alta resolução espaço-temporal e acompanhar uma estação inteira de crescimento com versatilidade em termos de planejamento de voo, excluindo as limitações inerentes ao uso das imagens obtidas via satélite (Maes et al., 2017).

A possibilidade do acompanhamento das áreas agrícolas via sensores deve-se à capacidade dos mesmos em capturar as diferentes ondas do espectro eletromagnético emitidas pela vegetação. Segundo Jensen (2009), a partir de combinações entre essas ondas, são gerados os chamados Índices de Vegetação (IVs). Os IVs se correlacionam com diferentes parâmetros biofísicos das culturas (Viña et al., 2011) e com isso, podem auxiliar no ajuste de uma gama de atividades agropecuárias. Juntamente com novas abordagens de técnicas de AM, é possível potencializar a precisão da predição de dados coletados via SR (Stojanova et al., 2010).

Nesse sentido, alguns estudos têm demonstrado que é possível monitorar e manejar as áreas de pastagens e o pastejo a partir de dados espectrais obtidos via SR a partir de VANTS (Batistoti et al., 2019; Castro et al., 2020; De Swaef et al., 2021; Wijesingha et al., 2020). A tecnologia foi empregada na estimativa da biomassa acima do solo (AGB) em diferentes genótipos do gênero *Megathyrsus* (Castro et al., 2020) e da altura do dossel forrageiro de plantas desse mesmo gênero (Batistoti et al., 2019). Já Caturegli et al. (2016), avaliaram parâmetros nutricionais de *Cynodon dactylon* x *transvaalensis*, *Zoysia matrella* e *Paspalum vaginatum*. Wijesingha et al. (2020), avaliaram esses parâmetros em pastos de clima temperado.

Porém, a altura do dossel e o valor nutritivo dos pastos dentro de um ambiente de pastagem são parâmetros muito variáveis, o que dificulta a predição dos mesmos. Logo, torna-se necessário o aprimoramento dos estudos que envolvam essa temática, utilizando-se métodos indiretos e modernos como SR e técnicas de AM, sobretudo relacionados às forrageiras tropicais do gênero *Urochloa*, devido à escassez de estudos acerca dessa temática. Assim, objetivou-se avaliar a predição de altura e concentração de proteína bruta de *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Basilisk a partir de dados coletados via SR e analisados por técnica de AM sob a hipótese de que é possível predizer estas variáveis utilizando-se tais ferramentas. O trabalho é composto por dois capítulos, com os seguintes objetivos específicos:

- I – Desenvolver e avaliar um modelo automatizado de predição de classes de altura do dossel de *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Basilisk via VANT e técnica de Aprendizado de Máquinas.
- II - Desenvolver e avaliar um modelo automatizado para predizer a concentração de proteína de *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Basilisk via VANT e técnica de Aprendizado de Máquinas.

Considerada uma área recente da pesquisa, as informações geradas contribuirão para estudos aprofundados acerca desse assunto e auxiliarão nos ajustes no manejo do pastejo e da pastagem de forma acessível e aplicável.

REFERÊNCIAS

- Ali, I., Greifeneder, F., Stamenkovic, J., Neumann, M., & Notarnicola, C. (2015). Review of Machine Learning Approaches for Biomass and Soil Moisture Retrievals from Remote Sensing Data. *Remote Sensing*, 7(12), 16398–16421. <https://doi.org/10.3390/rs71215841>
- Barrett, B., Nitze, I., Green, S., & Cawkwell, F. (2014). Avaliação de radares multitemporais e multissensores e dados espaciais auxiliares para monitoramento de pastagens na Irlanda usando abordagens de aprendizado de máquina. *Sensoriamento remoto do ambiente*, 152, 109–124. <https://doi.org/10.1016/j.rse.2014.05.018>
- Batistoti, J., Marcato Junior, J., Ítavo, L., Matsubara, E., Gomes, E., Oliveira, B., Souza, M., Siqueira, H., Salgado Filho, G., Akiyama, T., Gonçalves, W., Liesenberg, V., Li, J., & Dias, A. (2019). Estimating Pasture Biomass and Canopy Height in Brazilian Savanna Using UAV Photogrammetry. *Remote Sensing*, 11(20), 2447. <https://doi.org/10.3390/rs11202447>
- Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S., & Bareth, G. (2014). Estimating Biomass of Barley Using Crop Surface Models (CSMs) Derived from UAV-Based RGB Imaging. *Remote Sensing*, 6(11), 10395–10412. <https://doi.org/10.3390/rs61110395>
- Borra-Serrano, I., De Swaef, T., Muylle, H., Nuyttens, D., Vangeyte, J., Mertens, K., Saeys, W., Somers, B., Roldán-Ruiz, I., & Lootens, P. (2019). Canopy height measurements and non-destructive biomass estimation of *Lolium perenne* swards using UAV imagery. *Grass and Forage Science*, gfs.12439. <https://doi.org/10.1111/gfs.12439>

- Bretas, I. L., Valente, D. S. M., Silva, F. F., Chizzotti, M. L., Paulino, M. F., D'Áurea, A. P., Paciullo, D. S. C., Pedreira, B. C., & Chizzotti, F. H. M. (2021). Prediction of aboveground biomass and dry-matter content in *Brachiaria* pastures by combining meteorological data and satellite imagery. *Grass and Forage Science*, *76*(3), 340–352. <https://doi.org/10.1111/gfs.12517>
- Castro, W., Marcato Junior, J., Polidoro, C., Osco, L. P., Gonçalves, W., Rodrigues, L., Santos, M., Jank, L., Barrios, S., Valle, C., Simeão, R., Carromeu, C., Silveira, E., Jorge, L. A. de C., & Matsubara, E. (2020). Deep Learning Applied to Phenotyping of Biomass in Forages with UAV-Based RGB Imagery. *Sensors*, *20*(17), 4802. <https://doi.org/10.3390/s20174802>
- Caturegli, L., Corniglia, M., Gaetani, M., Grossi, N., Magni, S., Migliazzi, M., Angelini, L., Mazzoncini, M., Silvestri, N., Fontanelli, M., Raffaelli, M., Peruzzi, A., & Volterrani, M. (2016). Unmanned Aerial Vehicle to Estimate Nitrogen Status of Turfgrasses. *PLOS ONE*, *11*(6), e0158268. <https://doi.org/10.1371/journal.pone.0158268>
- da Silva, S., Sbrissia, A., & Pereira, L. (2015). Ecophysiology of C4 Forage Grasses—Understanding Plant Growth for Optimising Their Use and Management. *Agriculture*, *5*(3), 598–625. <https://doi.org/10.3390/agriculture5030598>
- De Swaef, T., Maes, W. H., Aper, J., Baert, J., Cougnon, M., Reheul, D., Steppe, K., Roldán-Ruiz, I., & Lootens, P. (2021). Applying RGB- and Thermal-Based Vegetation Indices from UAVs for High-Throughput Field Phenotyping of Drought Tolerance in Forage Grasses. *Remote Sensing*, *13*(1), 147. <https://doi.org/10.3390/rs13010147>

- Delevatti, L. M., Cardoso, A. S., Barbero, R. P., Leite, R. G., Romanzini, E. P., Ruggieri, A. C., & Reis, R. A. (2019). Effect of nitrogen application rate on yield, forage quality, and animal performance in a tropical pasture. *Scientific Reports*, 9(1), 7596. <https://doi.org/10.1038/s41598-019-44138-x>
- Instituto Brasileiro de Geografia e Estatística (IBGE). (2017). Censo Agropecuário (Agricultural census). Available online at: <https://biblioteca.ibge.gov.br/>
- FAOSTAT (2016) Banco de dados de emissões FAOSTAT. <http://faostat3.fao.org>. Acessado em 5 de abril de 2022
- Jensen J.R. (2009) - Remote Sensing of the Environment: An Earth Resource Perspective. 2nd Eds. Pearson Education.
- Leiva, J. N., Robbins, J., Saraswat, D., She, Y., & Ehsani, R. (2017). Evaluating remotely sensed plant count accuracy with differing unmanned aircraft system altitudes, physical canopy separations, and ground covers. *Journal of Applied Remote Sensing*, 11(3), 036003. <https://doi.org/10.1117/1.JRS.11.036003>
- Li, S., Jiao, J., & Wang, C. (2021). Research on Polarized Multi-Spectral System and Fusion Algorithm for Remote Sensing of Vegetation Status at Night. *Remote Sensing*, 13(17), 3510. <https://doi.org/10.3390/rs13173510>
- Li, Z., Han, G., Zhao, M., Wang, J., Wang, Z., Kemp, D. R., Michalk, D. L., Wilkes, A., Behrendt, K., Wang, H., & Langford, C. (2015). Identifying management strategies to improve sustainability and household income for herders on the desert steppe in Inner Mongolia, China. *Agricultural Systems*, 132, 62–72. <https://doi.org/10.1016/j.agsy.2014.08.011>

- Ma, Q., Chai, L., Hou, F., Chang, S., Ma, Y., Tsunekawa, A., & Cheng, Y. (2019). Quantifying Grazing Intensity Using Remote Sensing in Alpine Meadows on Qinghai-Tibetan Plateau. *Sustainability*, 11(2), 417. <https://doi.org/10.3390/su11020417>
- Maes, W., Huete, A., & Steppe, K. (2017). Optimizing the Processing of UAV-Based Thermal Imagery. *Remote Sensing*, 9(5), 476. <https://doi.org/10.3390/rs9050476>
- Maresma, Á., Ariza, M., Martínez, E., Lloveras, J., & Martínez-Casasnovas, J. (2016). Analysis of Vegetation Indices to Determine Nitrogen Application and Yield Prediction in Maize (*Zea mays* L.) from a Standard UAV Service. *Remote Sensing*, 8(12), 973. <https://doi.org/10.3390/rs8120973>
- Millennium Ecosystem Assessment, 2005. Acessado em: <https://www.millenniumassessment.org/en/index.html>
- Morota, G., Ventura, R. V., Silva, F. F., Koyama, M., & Fernando, S. C. (2018). BIG DATA ANALYTICS AND PRECISION ANIMAL AGRICULTURE SYMPOSIUM: Machine learning and data mining advance predictive big data analysis in precision animal agriculture1. *Journal of Animal Science*, 96(4), 1540–1550. <https://doi.org/10.1093/jas/sky014>
- Murphy, D. J., Murphy, M. D., O'Brien, B., & O'Donovan, M. (2021). A Review of Precision Technologies for Optimising Pasture Measurement on Irish Grassland. *Agriculture*, 11(7), 600. <https://doi.org/10.3390/agriculture11070600>
- Stojanova, D., Panov, P., Gjorgjioski, V., Kobler, A., & Džeroski, S. (2010). Estimating vegetation height and canopy cover from remotely sensed data with machine learning. *Ecological Informatics*, 5(4), 256–266. <https://doi.org/10.1016/j.ecoinf.2010.03.004>

- Viña, A., Gitelson, A. A., Nguy-Robertson, A. L., & Peng, Y. (2011). Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. *Remote Sensing of Environment*, 115(12), 3468–3478. <https://doi.org/10.1016/j.rse.2011.08.010>
- Wachendorf, M., Fricke, T., & Möckel, T. (2018). Remote sensing as a tool to assess botanical composition, structure, quantity and quality of temperate grasslands. *Grass and Forage Science*, 73(1), 1–14. <https://doi.org/10.1111/gfs.12312>
- Wang, F., Yi, Q., Hu, J., Xie, L., Yao, X., Xu, T., & Zheng, J. (2021). Combining spectral and textural information in UAV hyperspectral images to estimate rice grain yield. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102397. <https://doi.org/10.1016/j.jag.2021.102397>
- Wijesingha, J., Astor, T., Schulze-Brüninghoff, D., Wengert, M., & Wachendorf, M. (2020). Predicting Forage Quality of Grasslands Using UAV-Borne Imaging Spectroscopy. *Remote Sensing*, 12(1), 126. <https://doi.org/10.3390/rs12010126>
- Yan, S., Yao, X., Zhu, D., Liu, D., Zhang, L., Yu, G., Gao, B., Yang, J., & Yun, W. (2021). Large-scale crop mapping from multi-source optical satellite imageries using machine learning with discrete grids. *International Journal of Applied Earth Observation and Geoinformation*, 103, 102485. <https://doi.org/10.1016/j.jag.2021.102485>
- Yao, H., Qin, R., & Chen, X. (2019). Unmanned Aerial Vehicle for Remote Sensing Applications—A Review. *Remote Sensing*, 11(12), 1443. <https://doi.org/10.3390/rs11121443>

CAPÍTULO I - CLASSIFICAÇÃO AUTOMATIZADA DA ALTURA DE PASTOS DE CAPIM-BRAQUIÁRIA A PARTIR DE TÉCNICAS DE SENSORIAMENTO REMOTO E APRENDIZADO DE MÁQUINAS.

RESUMO

O manejo do pastejo com base na altura ideal para cada espécie compreende um método prático para garantir a qualidade nutricional e perenidade do pasto. Embora seja uma ferramenta de manejo simples, a aferição da altura a campo se torna trabalhosa devido às extensas áreas e grande variabilidade espacial e temporal das pastagens. Assim, o uso de Sensoriamento Remoto (SR) tem potencial para aprimorar a mensuração da altura de forma rápida. Objetivou-se desenvolver e avaliar um modelo automatizado de predição de classes de altura do dossel de *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Basilisk via SR e o algoritmo *Random Forest* como ferramenta auxiliar no manejo da pastagem e do pastejo. A partir de câmera multiespectral a bordo do Veículo Aéreo Não Tripulado (VANT) foram obtidas 40 imagens aéreas entre 2019 e 2021 sobre 30 canteiros experimentais de 3 m² cada, com diferentes idades de rebrotação. As imagens foram processadas para extração dos valores médios e desvio padrão da média dos Índices de Vegetação (IVs). As alturas foram agrupadas em três classes: alturas inferiores a 12 cm (Classe 0); entre 12 cm e 20 cm (Classe 1) e alturas superiores a 20 cm (Classe 2). Foi observada acurácia global dos dados de 58.66% e valores de precisão de 39.19%, 60.20% e 46.15% respectivamente para as Classes 0, 1 e 2 de altura. Os melhores IVs ranqueados de acordo com a importância de participação no modelo foram o desvio padrão do *Chlorophyll Vegetation Index* (CVI) na máscara de filtragem NDVI > 0.40 (14.93%), seguido pelo desvio padrão do *Transformed Vegetation Index* (TVI) e *Structure Insensitive Pigment Index* (SIPI) nas máscaras de filtragem NDVI > 0.40 e NDVI > 0.20, com 11.97% e 11.95% de importância, respectivamente. O desbalanço entre as classes de altura inferiu em maiores probabilidades de acerto de predição para a Classe 1. Sugerimos um maior banco de dados e com maior variabilidade, para que as classes apresentem número de dados balanceados e melhores métricas de avaliação.

Palavras-chave: Inteligência Artificial. Manejo dos pastos. *Random Forest*. VANTS. Zootecnia de Precisão.

1. INTRODUÇÃO

A aferição da altura do dossel forrageiro é importante no manejo do pastejo devido à alta relação com o Índice de Área Foliar (IAF), Interceptação Luminosa (IL) e massa de forragem (Echeverria et al., 2016; Jáuregui et al., 2017; Yu et al., 2018). O controle da altura com base na meta ideal de cada espécie forrageira proporciona qualidade nutricional e aumento na produtividade do pasto (Gomide et al., 2015; Paciullo et al., 2017). No manejo do pastejo sob lotação intermitente, a prática de aferição da altura do dossel forrageiro apoia a decisão de iniciar (altura pré-pastejo) ou findar (altura pós-pastejo) um evento de pastejo (Parsons & Penning, 1988).

As aferições da altura em ambientes de pastagens são tradicionalmente realizadas em pontos aleatórios no piquete com uso de régua ou bastões graduados (Andriamandroso* et al., 2016). Apesar de ser um método de fácil realização pelo manejador, a tomada dessa medida em áreas extensas e heterogêneas torna-se demorada e, em alguns casos, não representativa (Da Trindade et al., 2012; Legg & Bradley, 2019). Com isso, o desenvolvimento de métodos eficientes, confiáveis e práticos para monitorar as áreas de pastagem se fazem necessários. Tais métodos suprem a falta de mão de obra no setor agropecuário (Lessire et al., 2019) e ainda colaboram para o aumento da eficiência e sustentabilidade da produção animal em ambientes de pastagem (Tullo et al., 2019).

Graças ao avanço da tecnologia e a utilização de sensores remotos é possível a coleta de dados em grande escala, que auxiliam na tomada de decisão no manejo das pastagens e do pastejo (Andriamandroso* et al., 2016; Bretas et al., 2021). Os dados baseados em sensores são gerados em alta velocidade e em diferentes formatos, criando um “*big data*” que excede a capacidade de análise pelas ferramentas tradicionais (Morota et al. 2018). Assim, ferramentas de Inteligência Artificial (IA) têm sido cada vez mais utilizadas nos últimos anos para enfrentar o desafio da complexidade dessas informações coletadas (Ali et al. 2015; Morota et al. 2018). Entre as principais ferramentas utilizadas em IA, as técnicas de Aprendizado de Máquinas (AM) têm ganhado destaque devido à capacidade de automatizar a análise de *big data*. Algoritmos de AM podem reconhecer padrões em conjuntos de dados complexos e resolver problemas de classificação de forma rápida e automática. Assim, configura-se uma alternativa rápida, dinâmica e precisa em

relação às avaliações a nível de campo tradicionalmente estabelecidas (Leiva et al., 2017).

O uso de imagens obtidas via satélite e a utilização de Veículos Aéreos Não Tripulados (VANTS) tem se destacado como plataformas de aquisição de dados e discutido em vários estudos (S. Li et al., 2018; Shorten & Khoshgoftaar, 2019; Wijesingha et al., 2020). O Sensoriamento Remoto (SR) por satélite oferece grande possibilidade de monitoramento de culturas em larga escala (Yan et al., 2021). No entanto, a baixa resolução temporal das imagens obtidas por esse meio e condições climáticas adversas, como nuvens e neblina, pode levar à falta de conjuntos de dados de sensoriamento aplicáveis para o monitoramento das culturas (Maes et al., 2017).

Já o VANTS, surgem como uma promissora plataforma de SR devido à sua flexibilidade (Yao et al., 2019) e foram amplamente investigados para monitoramento de culturas com sensores de imagem (S. Li et al., 2021; Maresma et al., 2016; Wang et al., 2021). A partir de sensores a bordo de VANTS é possível rastrear pequenas áreas com alta resolução espaço-temporal e acompanhar uma estação inteira de crescimento com versatilidade em termos de planejamento de voo, excluindo as limitações inerentes ao uso das imagens obtidas via satélite (Maes et al., 2017).

A possibilidade do acompanhamento das áreas agrícolas via sensores remotos deve-se à capacidade dos mesmos em capturar as diferentes ondas do espectro eletromagnético emitidas pela vegetação. Segundo Jensen (2009), a partir da combinações entre essas ondas, são gerados os chamados Índices de Vegetação (IVs) que se correlacionam com diferentes parâmetros biofísicos das culturas (Viña et al., 2011).

Os IVs consistem em umas das ferramentas do SR que somado ao uso de técnicas de AM trouxeram grandes contribuições para a produção no campo de forma indireta e precisa (Wachendorf et al., 2018). Estudos como de Batistoti et al. (2019), Castro et al. (2020) e Wijesingha et al. (2020), demonstraram a aplicabilidade do imageamento por VANTS e dos IVs para predição e monitoramento da biomassa, altura e valor nutritivo do pasto para auxílio no manejo de pastagens.

Porém, estudos envolvendo a predição automatizada da altura do dossel de espécies forrageiras tropicais ainda são escassos, sobretudo em virtude da grande variabilidade da mesma dentro de um mesmo ambiente de pastejo (Bretas et al., 2023; Murphy et al., 2021). Sendo assim, valores de alturas agrupados em classes (ou seja,

intervalos de alturas), preditos a partir de dados de refletância espectral detectados por câmera acoplada em VANT e analisados por técnicas de AM, auxiliariam no gerenciamento de áreas de pastagem ocupadas por um rebanho de forma rápida.

O objetivo do estudo foi desenvolver um modelo de predição automatizada para classes de altura do capim-braquiária via técnicas de Sensoriamento Remoto e Aprendizado de Máquinas baseados em dados coletados a campo e uma seleção de IV, sob a hipótese de que é possível prever classes de altura a partir de tais técnicas.

2. MATERIAL E MÉTODOS

2.1. Localização e descrição da área de estudo

O experimento foi realizado na Unidade de Ensino, Pesquisa e Extensão em Forragicultura (UEPE Forragicultura) (Figura 1), situada na Universidade Federal de Viçosa (UFV), Viçosa, Minas Gerais, Brasil (lat. 20° 45'S, long. 42° 51'W e alt. 651 m).

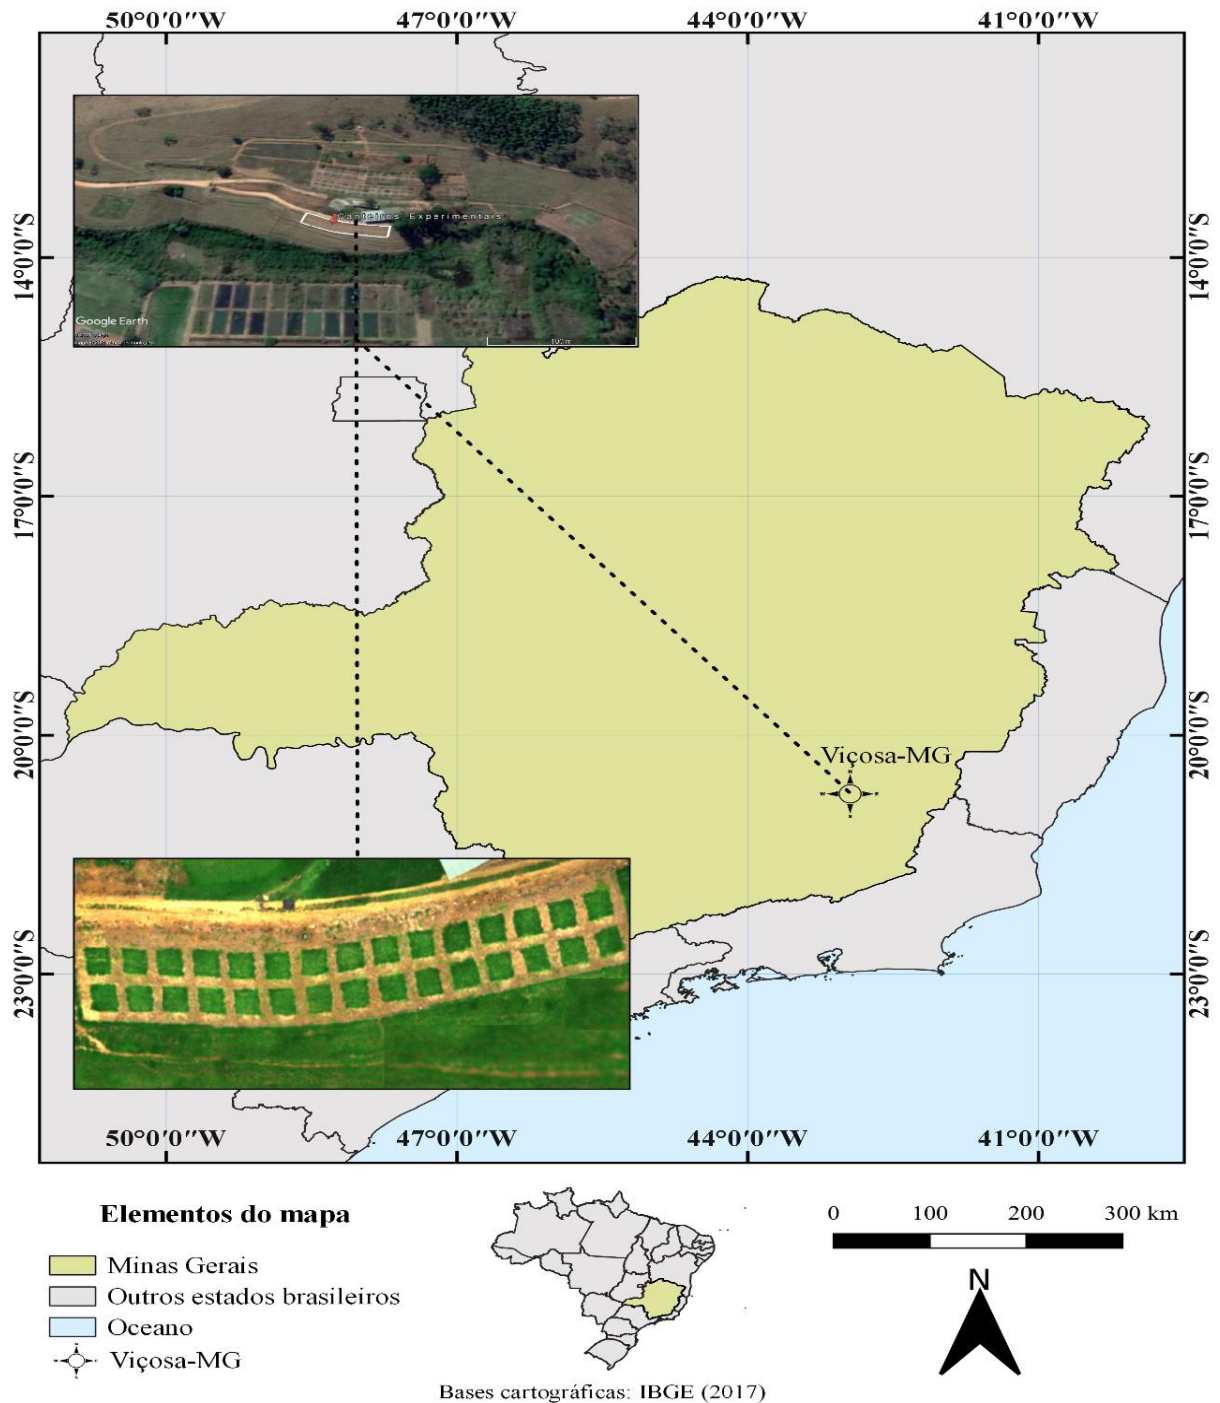


Figura 1. Localização da área de estudo.

Em um piquete previamente formado de *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Basilisk, vedado desde agosto de 2019, uma área de 500 m² foi selecionada, de acordo com a uniformidade do terreno, para alocar 30 parcelas de 3 m² cada, que foram dispostas em duas linhas horizontais, distantes 1.5 m entre si (Figura 1).

Na Figura 2, estão apresentados os dados meteorológicos referentes ao período de avaliação experimental (setembro de 2019 a março de 2021), obtidos de uma estação localizada a 550 m da área de estudo. O município de Viçosa possui clima Cwa, subtropical úmido, segundo a classificação de Köppen (Alvares et al., 2013). As estações secas e chuvosas da região são bem definidas.

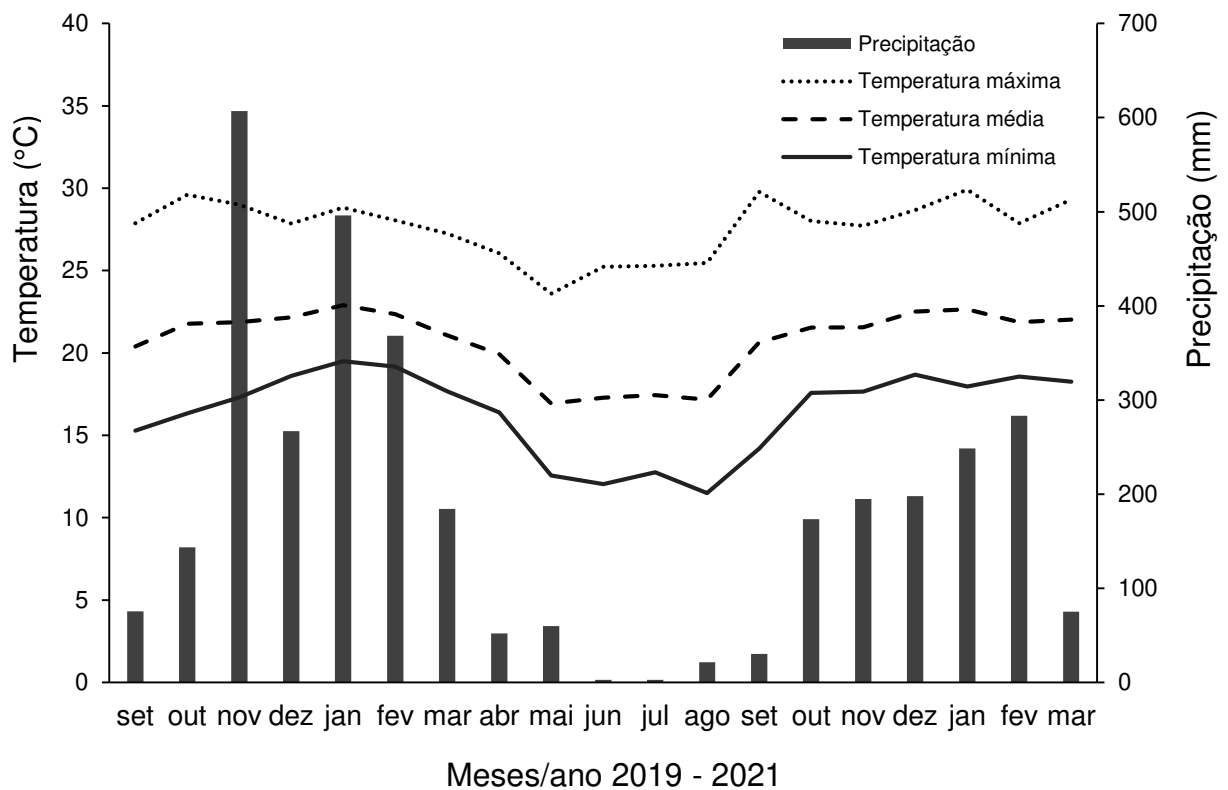


Figura 2. Precipitação pluvial (mm) e temperaturas (°C) máximas, médias e mínimas coletados durante o período experimental.

O solo da área de estudo é caracterizado como Latossolo Vermelho-Amarelo, de textura argilosa (Santos, 2018). Até o período pré-estudo, nenhum fertilizante havia sido utilizado. Uma amostra composta de solo da área experimental foi encaminhada para análise e o solo foi corrigido de acordo com o resultado da análise química na Tabela 1.

Tabela 1. Resultado da análise química do solo coletado na área experimental.

pH	P	K	V	m	P-rem	
H ₂ O	----- mg dm ⁻³ -----		----- % -----		mg L ⁻¹	
5.6	1.2	77.0	58.0	0.0	24.0	
Ca ²⁺	Mg ²⁺	Al ³⁺	H+Al	SB	t	T
----- cmol _c dm ⁻³ -----						
3.4	0.7	0.0	3.1	4.3	4.3	7.4

Abreviações: pH, potencial hidrogeniônico; P, Fósforo; K: Potássio; V, Índice de Saturação por Bases; m, Índice de Saturação por Alumínio; P-rem, Fósforo Remanescente; Ca²⁺, Cálcio; Mg²⁺, Magnésio; Al³⁺, Alumínio; H + Al, Acidez Potencial; SB, Soma de Bases Trocáveis; t, Capacidade de Troca Catiônica Efetiva; T, Capacidade de Troca Catiônica a pH 7.0.

Foram realizadas duas adubações de manutenção ao longo do período experimental com 30 kg ha⁻¹ de P₂O₅ e 150 kg ha⁻¹ de N de acordo com Ribeiro et al. (1999), considerando-se médio nível tecnológico. A primeira adubação foi parcelada em três datas (12/11/2019, 27/02/2020 e 10/03/2020) e a segunda em duas datas (22/09/2020 e 17/12/2020) de aplicações. A quantidade de adubo foi igualmente fracionada e distribuída para os 30 canteiros.

2.2. Dados de campo

Semanalmente, entre setembro de 2019 a março de 2021, foram aferidas a altura (ALT) do dossel forrageiro dos 30 canteiros experimentais totalizando-se 40 avaliações de campo (1200 valores médios de altura). As aferições ocorreram durante o inverno e a primavera de 2019, verão e primavera de 2020 e verão de 2021 no Brasil. Com o objetivo de gerar variação nas alturas do capim-braquiária, os 30 canteiros foram cortados em idades distintas de rebrotação, sendo que 10 eram cortados em intervalos que variavam de 10-15 dias, outros 10 a cada 21-28 dias e 10 entre 35-42 dias.

A ALT do dossel forrageiro foi estimada em cada um dos canteiros experimentais momento antes da aquisição das imagens aéreas. Para tanto, foi utilizada régua graduada em centímetros, em quatro pontos por canteiro (Figura 3).



Figura 3. Aferição da altura do dossel forrageiro nos canteiros experimentais.

Na Figura 4 estão apresentados os valores de ALT (cm) do dossel forrageiro aferidas ao longo de cada voo durante o período experimental.




Figura 4. Valores de altura do dossel forrageiro aferidas ao longo de cada voo.

Os valores de altura mínimo e máximo aferidos ao longo das avaliações experimentais foram respectivamente 5 cm e 50 cm (Figura 4). A média das alturas foi de 14.25 cm, com coeficiente de variação 34% e 4.87 de desvio padrão.

Imediatamente após a aferição da ALT foi obtida uma foto do painel de calibração da refletância incluída no *kit* da câmera MicaSense RedEdge - MX[®] com objetivo de ajustar o conjunto de imagens de acordo com as condições de iluminação do dia (calibração radiométrica). As imagens multiespectrais foram capturadas a partir da câmera MicaSense RedEdge - MX[®] a bordo da plataforma de voo Matrice 100 (Figura 5). A câmera possui cinco sensores semicondutores de óxido metálicos complementares que fornecem informações sobre as bandas espectrais Azul (~475 nm), Verde (~560 nm), Vermelho (~668 nm), *Red Edge* (~717 nm) e Infravermelho Próximo (~840 nm), evidenciados na Figura 5.




Figura 5. Da esquerda para direita: plataforma de voo Matrice 100 e câmera MicaSense RedEdge - MX[®] a bordo.

O plano de voo foi programado para garantir: (1) sobreposição frontal e lateral de 75%, (2) altura fixa de 50 metros e (3) tempo de voo fixo. A resolução espacial foi de quatro cm por *pixel*. Totalizaram-se 40 voos que aconteceram sob clima estável e condição de céu limpo, sempre no mesmo horário, às 12 h 00 min (horário local), para limitar as variações no ângulo do sol e as condições de iluminação.

2.3. Pré-processamento e construção dos ortomosaicos

Após a aquisição das ortofotos, as mesmas foram pré-processadas a partir do *software* Agisoft Metashape Professional® versão 1.7 (Agisoft, 2019) para construção do ortomosaico em seis etapas: (1) calibração automática a partir da foto do painel calibração de refletância, (2) alinhamento das imagens, (3) construção de uma nuvem tridimensional de pontos, (4) densificação da nuvem tridimensional, (5) construção de um modelo digital de superfície e (6) construção do ortomosaico. Após a construção do ortomosaico, o mesmo foi exportado em formato *Tiff* e, em ambiente de Sistemas de Informação Geográfica (SIG), para o *software* QGIS®, versão 3.2 (QGIS Development Team, 2019).

Foram criados polígonos de contorno manualmente para cada canteiro experimental. Logo, um total de 30 polígonos (imagens cortadas) foram criados por imagem (ortofoto), excluindo as bordas.

2.4. Índices de Vegetação

Para cada *pixel* que formaram a imagem recortada de cada canteiro, foram obtidos os valores das cinco diferentes bandas espectrais, Azul (~475 nm), Verde (~560 nm), Vermelho (~668 nm), *Red Edge* (~717 nm) e Infravermelho Próximo (~840 nm). Com base nos valores obtidos das bandas do Vermelho (VERM) e Infravermelho Próximo (NIR), foi calculado o valor médio do *Normalized Difference Vegetation Index* (NDVI) de cada uma das imagens recortadas. O NDVI é um dos Índices de Vegetação (IVs) mais explorados, proposto por Rouse et al. (1974), calculado segundo a Equação 1.

$$NDVI = \frac{NIR - VERM}{NIR + VERM} \quad (1)$$

Como as imagens recortadas também traziam informações do solo, as mesmas foram filtradas a partir da média dos valores de NDVI para cada voo em cada canteiro. Essa estratégia foi utilizada com objetivo de remover *pixels* irrelevantes, isto é, para eliminar detalhes que não são de interesse para as etapas subsequentes do processamento. Totalizaram-se quatro máscaras de filtragem: $NDVI > 0$, $NDVI > 0.20$, $NDVI > 0.40$, $NDVI > 0.60$. Os valores médios de todos os IVs utilizados no estudo, incluindo o NDVI e o desvio padrão da média de cada um deles foram calculados com base nas máscaras de filtragem. Para o cálculo dos índices médios de vegetação, foi considerado apenas os *pixels* com valor um na referida máscara.

Ao todo, nesse estudo, foram calculados 23 IVs (Tabela 2) a partir da linguagem de programação Python 3.7 e a biblioteca *Scikit-Learn* (Pedregosa et al., 2011).

Tabela 2. Índices de Vegetação (IVs) utilizados no estudo.

IVs	Autor	Operação Aritmética
ARVI	(Kaufman & Tanre, 1992)	$\frac{\text{NIR} - \text{VERM} - (\text{A} - \text{VERM})}{\text{NIR} + \text{VERM} - (\text{A} - \text{VERM})}$
CI_{Green}	(Gitelson et al., 2003)	$\text{NIR} \div (\text{V} - 1)$
$\text{CI}_{\text{Red Edge}}$		$\text{NIR} \div (\text{RE} - 1)$
CVI	(Vincini et al., 2008)	$\text{NIR} \times (\text{VERM} \div \text{V}^2)$
DVI	(Richardson & Wiegand, 1977)	$\text{NIR} - \text{VERM} / 32767.5$
EVI	(Huete, 1997)	$\frac{2.5 \times ((\text{NIR} - \text{VERM}) \div (\text{NIR} + 6 \times \text{VERM} - 7.5 \times \text{A} + 1))}{1}$
GNDVI	(Gitelson et al., 1996)	$(\text{NIR} - \text{V}) \div (\text{NIR} + \text{V})$
GRVI	(Sripada et al., 2006)	$\text{V} - \text{VERM} / \text{V} + \text{VERM}$
IRG	(Gamon & Surfus, 1999)	$\text{VERM} - \text{V} / 32767.5$
LCI	(Datt, 1999)	$(\text{NIR} - \text{RE}) \div (\text{NIR} - \text{VERM})$
MSR	(Chen, 1996)	$\frac{(\text{NIR} \div \text{VERM} - 1) \div ((\text{NIR} \div \text{VERM})^{0.5} + 1)}{1}$
NDVI	(Rouse et al., 1974)	$(\text{NIR} - \text{VERM}) \div (\text{NIR} + \text{VERM})$
$\text{NDVI}_{\text{Red Edge}}$	(Gitelson et al., 2003)	$(\text{NIR} - \text{RE}) \div (\text{NIR} + \text{RE})$
NGRDI	(Tucker, 1979)	$(\text{V} - \text{VERM}) \div (\text{V} + \text{VERM})$
PRI	(Gamon et al., 1992)	$\text{A} - \text{V} / \text{VERM} + \text{V}$
RDVI	(Roujean & Breon, 1995)	$(\text{NIR} - \text{VERM}) \div (\text{NIR} + \text{VERM})^{0.5}$
RVI	(Jordan, 1969)	VERM / NIR
SIPI	(Peñuelas et al., 1995)	$\text{NIR} - \text{A} / \text{NIR} + \text{A}$
SR	(Birth & McVey, 1968)	NIR / VERM
$\text{SR}_{\text{Red Edge}}$	(Gitelson, 2005)	NIR / RE
TVI	(Deering et al., 1975)	$\frac{((\text{NIR} - \text{VERM}) \div (\text{NIR} + \text{VERM}))^{0.5} + 0.5}{1}$
$\text{VARI}_{\text{Green}}$	(Gitelson et al., 2002)	$(\text{V} - \text{VERM}) \div (\text{V} + \text{VERM} + \text{A})$
$\text{VARI}_{\text{Red Edge}}$		$\frac{(\text{RE} - (1.7 \times \text{VERM}) + (0.7 \times \text{A})) \div (\text{RE} + (2.3 \times \text{VERM}) + (1.3 \times \text{A}))}{1}$

Abreviações: A, Azul; V, Verde; VERM, Vermelho; RE, *Red Edge*; NIR, Infravermelho Próximo; ARVI, *Atmospherically Resistant Vegetation Index*; CI_{Green} , *Chlorophyll Index*; $\text{CI}_{\text{Red Edge}}$, *Chlorophyll Index Red Edge*; CVI, *Chlorophyll Vegetation Index*; DVI, *Difference Vegetation Index*; EVI, *Enhanced Vegetation Index*; GNDVI, *Green Normalized Difference Vegetation Index*; GRVI, *Green-Red Vegetation Index*; IRG, *Red-Green Ratio Index*; LCI, *Leaf Chlorophyll Index*; MSR, *Modified Simple Ratio*; NDVI, *Normalized Difference Vegetation Index*; $\text{NDVI}_{\text{Red Edge}}$, *Normalized Difference Red Edge*; NGRDI, *Normalized Red-Green Difference Index*; PRI, *Photochemical Reflectance Index*; RDVI, *Red Green Ratio Index*; RVI, *Ratio Vegetation Index*; SIPI, *Structure Insensitive Pigment Index*; SR, *Simple Ratio*; $\text{SR}_{\text{Red Edge}}$, *Red-Edge Simple Ratio*; TVI, *Transformed Vegetation Index*; $\text{VARI}_{\text{Green}}$, *Vegetation Atmospherically Resistant Index* e $\text{VARI}_{\text{Red Edge}}$, *Visible Atmospherically Resistant Indices Red Edge*.

2.5. Modelagem

O *Random Forest* (RF) foi escolhido para construção do modelo de classificação das ALT, pois o algoritmo apresenta desempenho superior quando comparado a outras técnicas para pesquisa relacionada a ambientes de pastagens, comprovados em diversos estudos (Bretas et al., 2021; Mutanga et al., 2012; Wang et al., 2017).

A etapa de modelagem dos dados compreendeu quatro passos. Com base nos dados coletados e baseados nas metas de ALT recomendada para manejo da *U. decumbens* (*Sin. B. decumbens*) cv. Basilisk sob lotação intermitente, foram definidas, no passo 1, três diferentes classes de ALT. Sabe-se que o manejo do pastejo sob o método de lotação intermitente deve ser baseado nas alturas pré e pós-pastejo do dossel forrageiro (Hodgson, 1990; Carnevalli et al., 2006; Da Silva et al., 2015). Tais metas são estabelecidas para cada espécie com base no Índice de Área Foliar crítico, que corresponde a altura referente a interceptação de 95% de luz (IL95) pelo dossel.

Dessa forma, as classes de ALT (Classe 0, Classe 1 e Classe 2) foram agrupadas de maneira supervisionada, em função da recomendação de metas de manejo para o capim-braquiária (Pedreira et al., 2017). A Classe 0 compreendeu ALT menores e iguais a 12 cm. Já na Classe 1, foram agrupadas as ALT entre 12 cm e 20 cm. As ALT iguais ou maiores a 20 cm foram agrupadas na Classe 2 (Figura 6).



Classe 0: alturas menores ou iguais a 12 cm; Classe 1: alturas maiores que 12 cm e menores que 20 cm; Classe 2: alturas iguais ou superiores a 20 cm. Abreviação: ALT, alturas.

Figura 6. Classes de altura do dossel definidas conforme recomendações de manejo do pastejo para capim-braquiária sob lotação intermitente.

De forma prática, a Classe 0 representa a altura pós-pastejo, ou seja, o momento de retirar os animais do piquete sob pastejo e trocá-los de piquete; enquanto a Classe 1 indica que não há necessidade de alterações no manejo (ex. manter os animais pastejando ou manter o piquete em rebrotação). Por fim, a Classe 2 representa altura pré-pastejo, ou seja, o momento de iniciar o pastejo em um novo piquete (Figura 6).

Para construção do modelo de classificação da ALT utilizou-se o algoritmo de *Random Forest* (RF), a partir da linguagem de programação Python 3.7 e a biblioteca *Scikit-Learn* (Pedregosa et al., 2011).

No 2º passo, para cada semana distinta, foi realizado um voo para obtenção da imagem dos 30 canteiros. Com isso foram geradas 40 imagens diferentes, denominadas aqui como voos. Dos 40 voos, 75% (total de 30 voos), foram selecionados aleatoriamente para treinamento do algoritmo de AM de classificação da altura da pastagem nos piquetes. Os 25% restantes dos voos (10 voos) foram utilizados para testar o modelo treinado e assim determinar as métricas de avaliação do mesmo.

No 3º passo, a partir do *Random Forest* (RF), selecionou-se o número de *features* ideais a partir da validação cruzada (VC) nos dados de treinamento (75% dos voos) com 5-*Kfolds*. Em cada rodada de treinamento e VC, definiu-se um modelo de RF. Baseado neste modelo, uma *feature* foi selecionada para compor o mesmo. Foram usadas como *features*, os valores médios e o desvio padrão da média de todos os IVs utilizados no estudo, nas referidas máscaras de filtragem a partir do NDVI.

O processo foi repetido com uma até 50 *features*. Após realizar esse processo nos 5-*Kfolds* utilizou-se a estabilidade do Coeficiente *Kappa* (Cohen, 1960) como métrica para definição do número ideal de *features*. As mesmas foram ranqueadas de maneira automatizada pelo algoritmo de acordo com a influência no modelo.

Com as *features* selecionadas e o modelo treinado, no 4º passo, aplicou-se os dados de teste. A etapa final da modelagem culminou em uma matriz de confusão dos dados de teste e seis métricas foram utilizadas para avaliação do modelo. Assim, a partir do modelo final foi definido o ROC AUC (*Receiver Operating Characteristics e Area Under The Curve*), Coeficiente *Kappa* dos dados de teste. As métricas Precisão, *Recall*, *F1 Score* também foram calculadas, segundo as Equações 2, 3 e 4.

$$\text{Precisão} = \frac{TP}{TP + FP} \times 100 \quad (2)$$

$$\text{Recall} = \frac{TP}{TP + FN} \times 100 \quad (3)$$

$$\text{F1 Score} = \frac{2 \times \text{precisão} \times \text{recall}}{\text{precisão} + \text{recall}} \times 100 \quad (4)$$

Em que TP são os valores de ALT verdadeiros e positivos, FP os valores falsos positivos e FN os valores de ALT falsos negativos. Com base nos valores de predições corretas, calculou-se a acurácia global dos dados de teste de acordo com a Equação 5, representado pelo percentual de acertos em relação ao total de observações.

$$\text{Acurácia Global} = \frac{\sum TP}{\text{TOTAL}} \times 100 \quad (5)$$

As probabilidades de acerto e erro em cada classificação de ALT também foram calculadas pelo modelo. O fluxograma de aquisição dos dados de campo até a etapa de modelagem está apresentado na Figura 7.

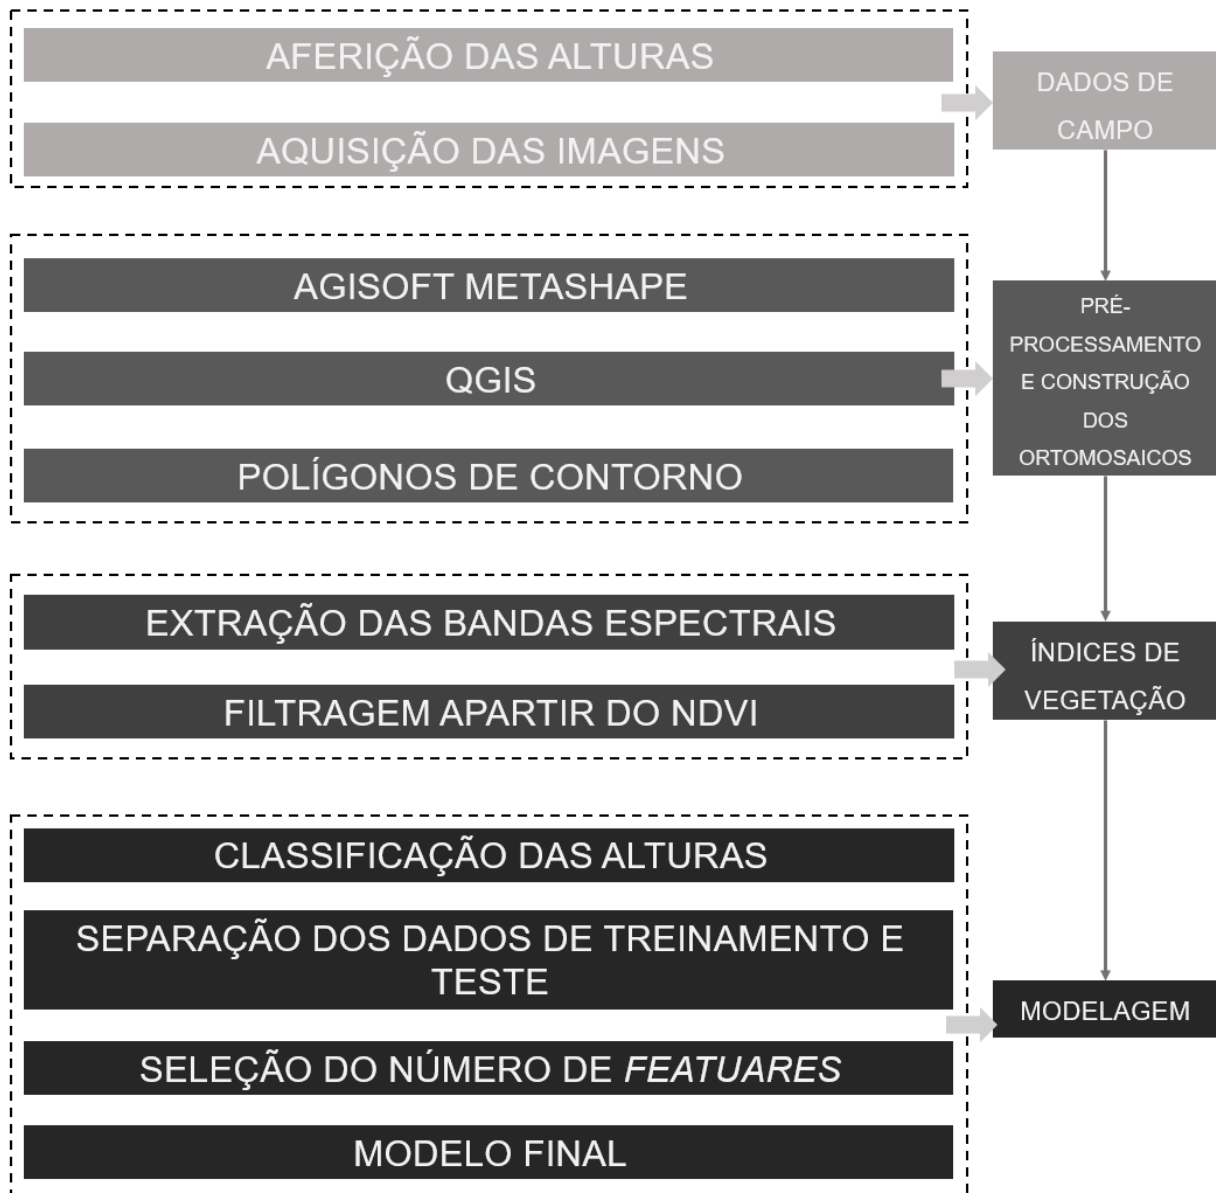


Figura 7. Fluxograma de aquisição dos dados e modelagem.

3. RESULTADOS

3.1. Classificação das alturas e seleção do número de *features*

Na tabela a seguir (Tabela 3), estão representadas as observações de altura para cada classificação, separadas em dados de treinamento e teste.

Tabela 3. Classificação das alturas do dossel forrageiro aferidas ao longo do período experimental.

Conjunto de dados	Classificação das alturas			Total
	Classe 0 (ALT ≤ 12 cm)	Classe 1 (12 cm < ALT < 20 cm)	Classe 2 (ALT ≥ 20 cm)	
Treinamento	396	398	106	900
Teste	73	192	35	300
Total	469	590	141	1200

Classe 0: alturas menores ou iguais a 12 cm; Classe 1: alturas maiores que 12 cm e menores que 20 cm; Classe 2: alturas iguais ou superiores a 20 cm. Abreviação: ALT, alturas.

Do total de 300 observações de valores médios de altura (25% do conjunto de aferições a campo) para teste, 73 pertenciam a Classe 0, 192 a Classe 1 e 35 a Classe 2, sendo esta última a classe com o menor número de observações, tanto para os dados de treinamento, quanto para os dados de teste do modelo.

Quanto às *features*, 10 foram selecionadas como classificatórias para o modelo em função da estabilidade do Coeficiente de *Kappa* com 36.28% de média (Figura 8).

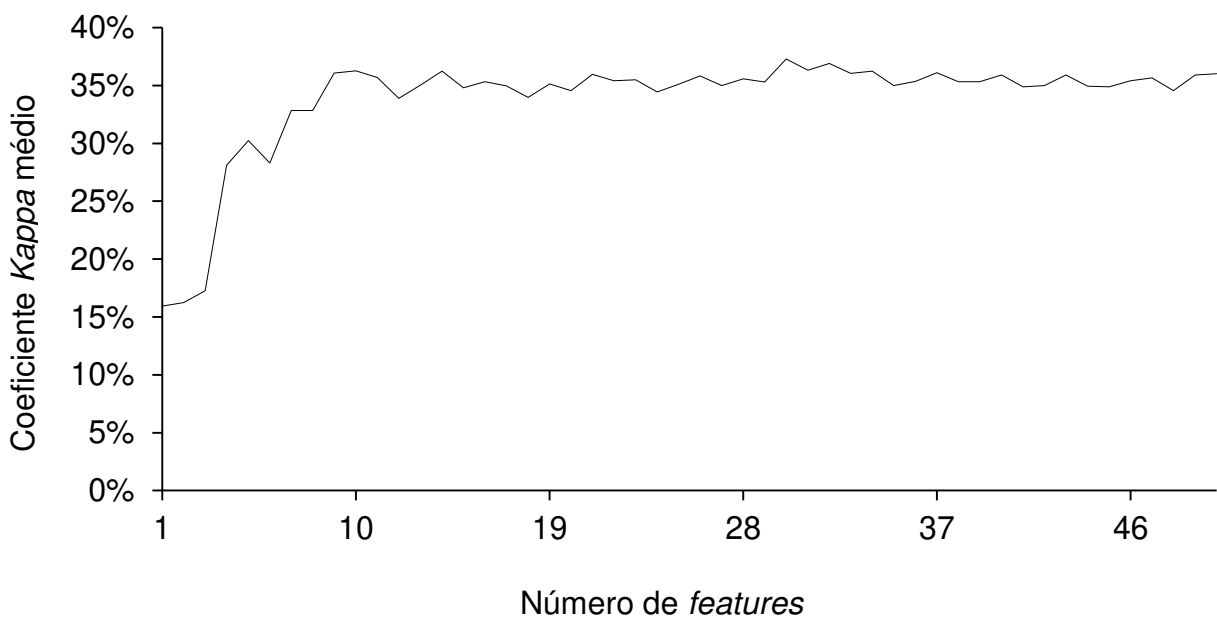



Figura 8. Seleção do número de *features*.

O desvio padrão foi selecionado como *feature* para todos os IVs que contribuíram para o modelo, exceto para o *Ratio Vegetation Index* (RVI), em que a média dos valores encontrados para o IV foi selecionada (Figura 8).

A *feature* de maior influência no modelo foi o desvio padrão do *Chlorophyll Vegetation Index* (CVI) na máscara de filtragem NDVI > 0.40 (14.93% de importância), seguido pelo desvio padrão do *Transformed Vegetation Index* (TVI) e *Structure Insensitive Pigment Index* (SIPI) nas máscaras de filtragem NDVI > 0.40 e NDVI > 0.20, com 11.97% e 11.95% de importância na participação do modelo, respectivamente (Figura 9).



Abreviações: RVI_std_0, desvio padrão dos valores do *Ratio Vegetation Index* na máscara de filtragem de NDVI > 0; ARVI_std_2, desvio padrão dos valores do *Atmospherically Resistant Vegetation Index* na máscara de filtragem de NDVI > 0.20; CVI_std_2, desvio padrão dos valores do *Chlorophyll Vegetation Index* na máscara de filtragem de NDVI > 0.20; RVI_mean_6, média dos valores *Ratio Vegetation Index* na máscara de filtragem de NDVI > 0; NDVI_std_0, desvio padrão dos valores do *Normalized Difference Vegetation Index* na máscara de filtragem de NDVI > 0; CVI_std_0, desvio padrão dos valores do *Chlorophyll Vegetation Index* na máscara de filtragem de NDVI > 0; NDVI_std_2, desvio padrão dos valores do *Normalized Difference Vegetation Index* na máscara de filtragem de NDVI > 0.20; SIPI_std_2, desvio padrão dos valores do *Structure Insensitive Pigment Index* na máscara de filtragem de NDVI > 0.20; TVI_std_4, desvio padrão dos valores do *Transformed Vegetation Index* na máscara de filtragem de NDVI > 0.40; CVI_std_4, desvio padrão dos valores do *Chlorophyll Vegetation Index* na máscara de filtragem de NDVI > 0.40; NDVI, *Normalized Difference Vegetation Index*; Mean, média.

Figura 9. Ranking das features (%) determinado pelo *Random Forest*.

O desvio padrão do *Normalized Difference Vegetation Index* (NDVI) na máscara de filtragem NDVI > 0.2 e NDVI > 0 participaram com 9.78% e 9.11% de importância, respectivamente. O desvio padrão do CVI na máscara de filtragem NDVI > 0 apresentou 9.39% de importância para o modelo. Este mesmo IV também foi

selecionado com 8.82% de importância, no entanto na máscara de filtragem $NDVI > 0.2$. A média do *Ratio Vegetation Index* (RVI) na máscara de filtragem $NDVI > 0.6$ foi selecionada com 9.11% de importância. Os últimos IVs ranqueados foram o desvio padrão dos valores de ARVI (ARVI_std_2) e RVI (RVI_sdt_0) respectivamente com 7.54% e 7.40% (Figura 9).

3.2. Matriz de confusão dos dados de teste

Os resultados apresentados na Figura 10 mostram que o modelo foi capaz de prever corretamente (verdadeiros positivos) 29 valores de $ALT \leq 12$ cm, pertencentes a Classe 0 (Figura 10). No entanto, classificou erroneamente (falsos negativos) 44 valores, sendo 43 deles classificados como Classe 1. Em apenas um canteiro de um voo (ou seja, entre 300 avaliações de altura), um canteiro Classe 0 foi classificado como Classe 2.

		PREDITO			FN
		CLASSE 0	CLASSE 1	CLASSE 2	
OBSERVADO	CLASSE 0	29	43	1	44
	CLASSE 1	45	141	6	51
	CLASSE 2	0	29	6	29
	FP	45	72	7	124

CLASSE 0		CLASSE 1		CLASSE 2	
(TP) 29	(FN) 44	(TP) 141	(FN) 51	(TP) 6	(FN) 29
(FP) 45	(TN) 174	(FP) 72	(TN) 35	(FP) 7	(TN) 170

MÉTRICAS	CLASSE 0	CLASSE 1	CLASSE 2
PRECISÃO	39.19%	66.20%	46.15%
RECALL	39.72%	73.43%	17.14%
F1 SCORE	39.45%	69.63%	25.00%
ACURÁCIA GLOBAL	58.66%		
KAPPA	13.98%		
ROC AUC	70.85%		

Classe 0: alturas menores ou iguais a 12 cm; Classe 1: alturas maiores que 12 cm e menores que 20 cm; Classe 2: alturas iguais ou superiores a 20 cm. Abreviações: FN, valores de altura falso negativos; FP, valores falsos positivos; TP, valores de altura verdadeiros e positivos; TN, valores verdadeiros negativos; ROC AUC, *Receiver Operating Characteristics e Area Under The Curve*.

Figura 10. Matriz de confusão dos dados de teste e as métricas de avaliação do modelo.

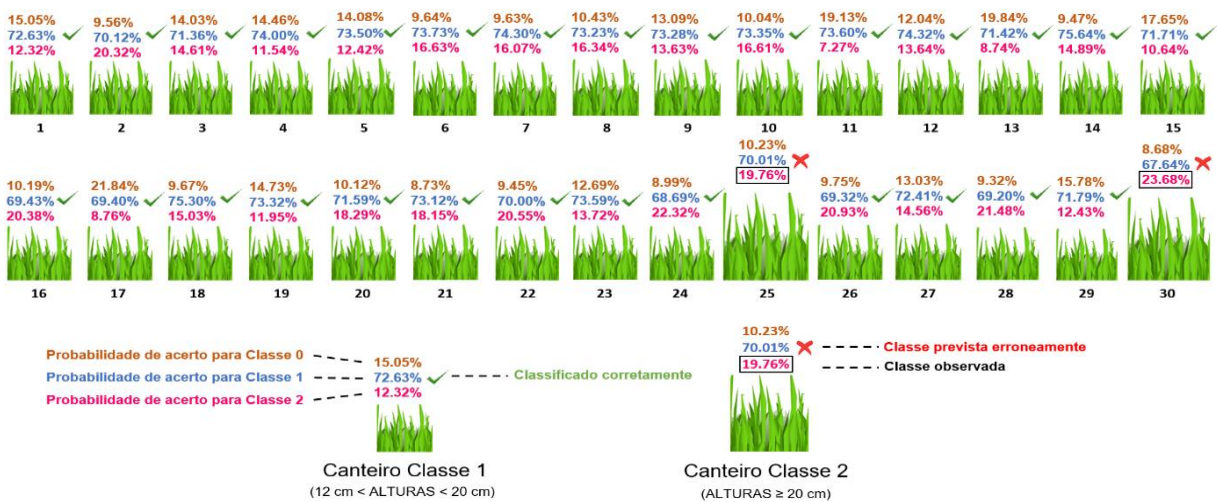
O maior número de predições corretas foi referente a Classe 1 (12 cm < ALT < 20 cm). O modelo acertou na predição de 141 valores, de um total de 192 observações. O modelo errou na predição de 45 valores de ALT que foram classificados como Classe 0 e seis valores de ALT que foram classificados como Classe 2 (Figura 10).

Somente seis valores de ALT foram preditos corretamente pelo modelo como Classe 2 (ALT ≥ 20 cm). O modelo errou na predição de 29 valores, que foram classificados como Classe 1. E, em nenhuma das predições, um canteiro Classe 2 foi previsto como Classe 0 (Figura 10).

As métricas de avaliação do modelo, *Precisão*, *Recall* e *F1 Score* (Equações 3, 4 e 5, respectivamente) foram maiores para Classe 1. O menor valor de *Recall* observado foi para a Classe 2. E, a menor *Precisão* foi obtida para Classe 0 (Figura 10). *Precisão* e *Recall* são importantes para caracterizar o impacto de falsos positivos (FP) e falsos negativos (FN), respectivamente. A acurácia global dos dados de teste foi de 58.66%.

3.3. Probabilidades

Para representar os valores das probabilidades de acerto das predições dos dados de teste, dois voos foram utilizados. A Figura 11, ilustra as probabilidades de acerto inerentes a cada classificação de altura (ALT) no voo de número 5.

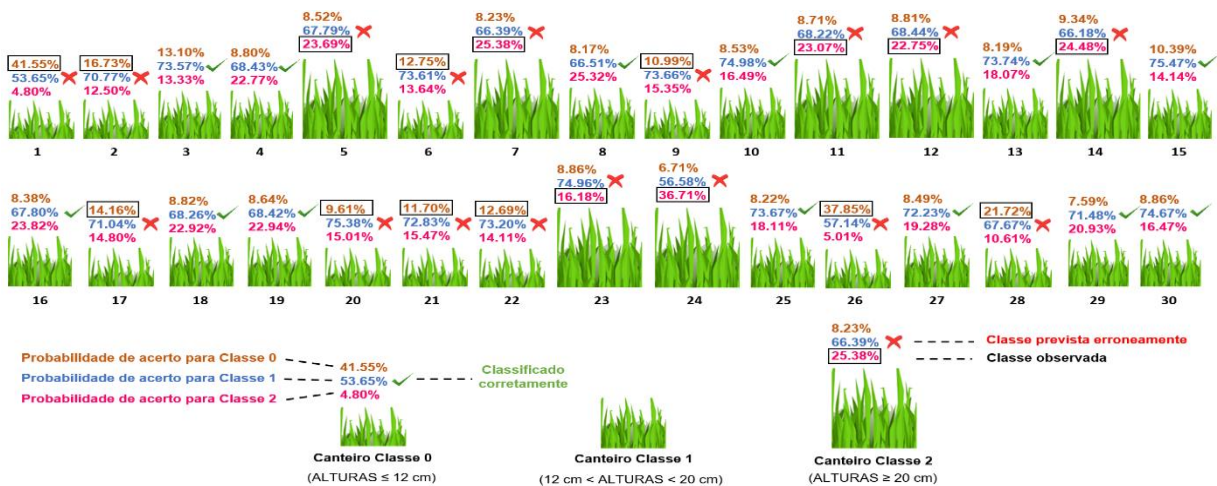


Classe 0: alturas menores ou iguais a 12 cm; Classe 1: alturas maiores que 12 cm e menores que 20 cm; Classe 2: alturas iguais ou superiores a 20 cm.

Figura 11. Probabilidades de acerto (em %) das predições de classes de altura dos dados de teste no voo número 5.

Foram observadas apenas duas classes de altura durante o voo de número 5: Classe 1 e Classe 2, ou seja, não havia canteiros pertencentes a Classe 0 durante as aferições a campo para esse voo (Figura 11). O modelo classificou corretamente 28 canteiros, o que confere mais de 93% de acerto das predições para esse voo específico. Os dois erros de predições aconteceram com os canteiros observados como Classe 2 (canteiro número 25 e número 30), que foram preditos como Classe 1.

Já para o voo de número 26, representado na Figura 12, foram observados canteiros pertencentes às três classes de alturas: Classe 0, Classe 1 e Classe 2. Dos 30 canteiros avaliados, o modelo classificou corretamente 13 canteiros (Figura 12).



Classe 0: alturas menores ou iguais a 12 cm; Classe 1: alturas maiores que 12 cm e menores que 20 cm; Classe 2: alturas iguais ou superiores a 20 cm.

Figura 12. Probabilidades de acerto (em %) das predições de classes de altura para os dados de teste no voo de número 26.

Todos os canteiros preditos corretamente pertenciam a Classe 1 nesta representação. Entre os demais canteiros, dez que foram observados como Classe 0, foram preditos como Classe 1 e sete canteiros pertencentes a Classe 2, foram preditos também como Classe 1 (Figura 12). Mesmo que com altas probabilidades de acerto para a classe observada, a predição da classe não foi correta.

4. DISCUSSÃO

O estudo de Théau et al. (2021), corroboram com o nosso propósito de classificação de alturas. Estes autores mencionaram o potencial da classificação das ALT para planejar ciclos de pastejo como uma ferramenta prática e generalizável para o manejo de pastagens. Bretas et al. (2023), a partir de imagens de satélites e técnicas de AM, também agruparam os valores de ALT dos pastos de *Megathyrus maximus* cv. Mombaça em três classes como suporte a tomada de decisão para o manejo do pastejo.

Apesar da definição de classes de altura, as métricas de avaliação do modelo não foram bem-sucedidas. Da mesma forma, alguns autores avaliaram a correlação entre os dados de refletância obtidos por satélites e a ALT do pasto medidas a campo para estimar a altura, mas falharam (Tiscornia et al., 2019). Os mesmos autores justificaram a baixa correlação encontrada devido à grande variabilidade de ALT dentro de um mesmo piquete. Em uma revisão de tecnologias para otimizar o monitoramento de pastagens, Murphy et al. (2021) concluíram que a principal limitação do SR de pastagens é sua alta heterogeneidade, normalmente maior do que nas lavouras, onde a agricultura de precisão está consolidada.

Todas as *features* selecionadas, exceto a média do *Ratio Vegetation Index* (RVI), envolveram o desvio padrão (Figura 9). O modelo pode ter identificado o desvio padrão dos dados de ALT como parâmetro de aprendizado. De acordo com Murphy et al. (2021) e Tiscornia et al. (2019) em ambientes de pastagem, essa discrepância entre as alturas em um mesmo ambiente de pastagem é comum. Essa diferença é ainda maior em pastos tropicais, em função da heterogeneidade das espécies, do relevo, da correção e adubação do solo (Bretas et al., 2021). O mesmo foi observado no estudo (Figura 4).

O IV mais influente para predição do modelo foi o *Chlorophyll Vegetation Index* (CVI) na máscara de filtragem de NDVI > 0.4 (Figura 9). Esse índice apresenta correlação com a quantificação de clorofila presente na forrageira avaliada, quando calculado e representado no ortomosaico, identificando zonas com maior concentração de clorofila (Vincini et al., 2008).

Com base nas fórmulas utilizadas para os cálculos dos IVs (Tabela 2), todas as bandas espectrais utilizadas pela câmera no presente estudo foram importantes para classificação automatizada da ALT de *U. decumbens*. Apesar da destacada

importância atribuída à banda do Infravermelho Próximo (NIR) e *Red Edge* (RE), entre os IVs tradicionais descritos na literatura e comumente usados para monitorar aspectos morfológicos e quantitativos da vegetação (por exemplo, o NDVI, EVI, GNDVI e NDRE), apenas o NDVI foi selecionado.

Dessa forma, o *ranking* das principais variáveis selecionadas no modelo (Figura 9) infere que outros IVs podem ser mais adequados para classificar a altura do pasto em relação aos IVs tradicionalmente explorados no monitoramento da vegetação. Esse estudo aponta que o CVI, *Structure Insensitive Pigment Index* (SIPI) e *Transformed Vegetation Index* (TVI) também podem ser utilizados para esse propósito. Tais IVs consideram também a região do Vermelho, Verde, Azul (Tabela 2). Bretas et al. (2023), também estudaram um modelo de predição para classificação da ALT com espécie forrageira tropical *Megathyrus maximus* (Sin. *Panicum maximum*) cv. Mombaça. A partir do SR via satélite os autores também sugeriram o aprofundamento em estudos utilizando outros IVs em detrimento aos tradicionais (Bretas et al., 2023).

A matriz de confusão (Figura 10) mostra que os maiores erros de classificação estão entre as Classes 0 e 1 e Classes 1 e 2, ou seja, classes sequenciais. Esses erros aconteceriam até mesmo utilizando-se os métodos tradicionais em virtude da proximidade entre as classes de ALT. Houve apenas uma predição errada entre as Classes 0 e 2 (Figura 10).

A determinação da classe de ALT pode comprometer todo o manejo dos pastos, do pastejo e a qualidade da dieta. Por isso, deve-se considerar a precisão dos dados encontrados, sobretudo onde é preciso minimizar os valores falsos positivos (FP). Já o *Recall* do modelo, considera os valores falsos negativos (FN). No entanto, essas são medidas consideradas contraditórias, sendo que o aumento de uma das métricas leva à diminuição da outra. Por isso, é importante representar o *F1 Score* como uma métrica que considera a média harmônica entre Precisão e *Recall* (Equações 3, 4 e 5).

Os valores de *Recall* observados para as Classe 0 e 1 (Figura 10) foram baixos, em função da grande variabilidade dos dados trabalhados e somado ao extenso período de coleta de dados de ALT, que incluíram diferentes estações climáticas. Esta métrica foi mais expressiva para Classe 1, sobretudo por ser a classe com maior número de observações coletadas (Tabela 3). O menor *Recall* foi referente a Classe 2. Tal classe apresentou menor número de observações nos dados de teste. Os

menores registros de ALT pertencentes a esta classe (Tabela 3) se devem à morfologia das plantas forrageiras do gênero *Urochloa* (Sin. *Brachiaria*), caracterizadas pelo crescimento decumbente dos colmos e porte mais baixo em relação a outras espécies forrageiras, como por exemplo cultivares do gênero *Panicum* (Sin. *Megathyrsus*) (Omote et al., 2021).

Além disso, o menor incremento na ALT pode ser atribuído principalmente ao manejo constante de rebaixamento do dossel forrageiro e ao fato de que os canteiros foram adubados apenas três vezes de forma parcelada nos meses de novembro e fevereiro de 2019 e março de 2020 e duas vezes em setembro e dezembro de 2020. Os canteiros não foram irrigados. Outros estudos utilizaram estratégias de adubação e irrigação para gerar variação nos dados coletados (Bretas et al., 2023; Bretas et al., 2021; Castro et al., 2023; Batistoti et al., 2019).

Deve-se considerar também que, a rebrotação das pastagens após a desfolha, durante os meses de março até setembro, é mais lenta (Parsons & Chapman, 2000). Assim, o tempo entre avaliações pode não ter sido suficiente para promover diferença espectral entre estas classes em alguns voos.

O desbalanço entre as classes de alturas no presente estudo, implicou no maior número de predições corretas para a Classe 1, bem como para as observações de Classe 0 e 2 que foram preditas também como Classe 1 (Tabela 3). Isso aconteceu em função das maiores probabilidades de acerto observadas para essa classe. Sendo assim, mediante probabilidades mais baixas de acertos obtidas para Classe 0 e 2, o modelo sugeria a Classe 1 como forma de tentar prever corretamente (Figura 11 e 12). Assim, um maior número e a mesma quantidade de observações para cada classe poderiam melhorar os valores das métricas exploradas neste estudo.

Encontrou-se valor de ROC AUC de 70.85%. Tal métrica é muito utilizada para avaliar o desempenho de modelos de classificação. O ROC AUC indica o quão bom o modelo é em ranquear exemplos positivos acima dos exemplos negativos. Observou-se também uma acurácia global dos dados superior a 58% (Figura 10). A acurácia determina a proporção de classes de canteiros que foram corretamente classificados. Tais resultados confirmam a dificuldade de prever ALT dos pastos, considerando-se a mesma uma variável dinâmica e muito heterogênea, que tornam a aplicação do SR em pastagens (cultura perene) mais complexa em relação às culturas anuais (por exemplo arroz, trigo e milho), onde a aplicação desta técnica está melhor estabelecida (Murphy et al., 2021).

Para as classes de ALT exploradas no estudo é possível realizar uma implementação baseada no método de lotação intermitente, tradicionalmente utilizado nos sistemas de produção intensivos a pasto (Difante et al., 2010; Schons et al., 2021). Para implementar nosso modelo de classificação de ALT e simular a tomada de decisão no manejo do pastejo e da pastagem, utilizamos as probabilidades dos dois voos utilizados nos dados teste selecionados aleatoriamente (Figuras 11 e 12). Os canteiros experimentais agora também serão mencionados como piquetes.

A Classe 0 ($ALT \leq 12$ cm), de acordo com o método de lotação intermitente, representa o momento em que o pastejo deve ser finalizado (Figura 6). Nesse momento, conhecido como pós-pastejo, o dossel forrageiro deve estar com cerca de 40% a 50% do valor da ALT inicial recomendada. Assim, os piquetes previstos como pertencentes a Classe 0, deverão ser vedados do pastejo até que, a partir do processo de rebrotação, o dossel forrageiro alcance ALT de pastejo ideal novamente. Para tanto, esse monitoramento deve ser constante e por isso são justificados métodos práticos para determinação dos valores de ALT.

As ALT representadas pela Classe 1, entre 12 cm e 20 cm (Figura 6), simbolizam um piquete sob pastejo. Na ausência de animais, indica um piquete em processo de rebrotação, no qual o pecuarista deve aguardar o momento ideal baseados nas metas de ALT para entrada dos animais.

A Classe 2 (Figura 6), representa o momento de iniciar um pastejo de acordo com as metas de ALT propostas para *U. decumbens* (Sin. *B. decumbens*) cv. Basilisk. Esta classe agrupou valores de altura de 20 cm até 50 cm. Porém, vale lembrar que, sob condições de valores de ALT médios superiores a 30 cm, as plantas começam a perder o valor nutritivo e qualidade estrutural do dossel forrageiro. Conseqüentemente, alturas muito acima daquelas recomendadas para cada espécie forrageira, impacta negativamente o processo de pastejo, conforme descrito por alguns autores (Paciullo et al., 2017; Trindade et al., 2007; Valote et al., 2021).

De acordo com as observações das classes na Figura 11, os 28 canteiros poderiam estar em processo de rebrotação ou sob pastejo. Já os canteiros 25 e 30 deveriam estar aptos a receberem animais naquele momento (observados como Classe 2). No entanto, as predições desses canteiros foram feitas de maneira equivocada, haja visto que, o modelo os classificou como Classe 1. Tal predição implicaria na decisão de não iniciar o pastejo, em função da meta de altura ainda não atingida. Isto acarretaria em perda de qualidade nutricional da planta forrageira,

ocasionada pelo incremento na ALT das mesmas (participação de colmos) e material senescente (Da Silva et al., 2015; Euclides et al., 2014; Kill-Silveira, 2020), mediante ao atraso do início do pastejo.

Mas, para esse voo, apenas dois canteiros foram preditos erroneamente. Para corrigir esse erro de predição do modelo, o rebaixamento do dossel poderia ser feito utilizando-se um segundo lote de animais de menor exigência nutricional. E, a dinâmica do método seria facilmente recuperada para os demais ciclos, mediante detecção visual do erro pelo manejador.

Durante o voo número 26 (Figura 12), apenas 13 canteiros foram preditos corretamente. Predizer corretamente a classe de ALT do canteiro é muito importante para a manutenção do ciclo de pastejo nos métodos de lotação intermitente para garantir a qualidade nutricional da planta forrageira.

Atrasar ou adiantar o início do pastejo, compromete a dinâmica de todo método ao longo do período de duração do ciclo. Pois são alterados o período de ocupação (PO) e período de descanso (PD) dos piquetes, aumentando os esforços em mão de obra por parte do manejador para recuperação da sequência do método.

Ainda, a decisão errada de não interromper um processo de pastejo, atrasa o processo de rebrotação da forrageira e, conseqüentemente, o tempo de recuperação da planta (Martins et al., 2013; Paciullo et al., 2017). Da mesma forma que, não iniciar o pastejo no momento recomendado com base nas metas de ALT, haverá descontrole na ALT do dossel que afetará negativamente a estrutura do pasto (Paciullo et al., 2017) e, conseqüentemente, a qualidade nutricional da planta e o consumo animal.

Foram preditos como Classe 1, os canteiros 1, 2, 6, 9, 17, 20, 21, 26 e 28 (Figura 12). No entanto, os mesmos foram observados mediante as aferições de ALT a campo como Classe 0. Quando se classifica um piquete Classe 0 como Classe 1, a permanência dos animais resultará em maior rebaixamento do dossel e perdas significativas referentes à produção animal e reservas nutricionais das plantas dispensadas para rebrotação (Chapman, 2016).

Já os canteiros 5, 7, 11, 12, 14, 23 e 24 foram previstos como Classe 1, mas pertenciam a Classe 2 (Figura 12). As implicações são as mesmas citadas anteriormente durante as predições no voo de número 5.

Em situações diferentes das ilustradas nas Figuras 11 e 12, quando se classifica um piquete Classe 1 como Classe 0 ou Classe 1 como Classe 2 as

consequências são possíveis de serem reparadas apenas com ajuste no PD e PO, respectivamente.

No primeiro caso (predizer como Classe 1 um piquete observado como Classe 0) o pastejo seria interrompido com pouco rebaixamento do dossel forrageiro, caracterizando um pastejo leniente e, nesse caso, o PD desse piquete em questão seria menor (Carvalho et al., 2015). No segundo caso, predizer como Classe 1 um piquete observado como Classe 2, na presença dos animais, os mesmos continuariam em pastejo e na ausência deles, haveria um incremento na altura do dossel e perda da qualidade da forrageira. Sugerimos então que, apenas nas situações em que os canteiros apresentam probabilidade de acerto para determinada classe inferior a 70%, sejam conferidos pontualmente pelo manejador.

Acreditamos que a classificação com base na faixa de ALT média de um piquete seja uma ferramenta prática e generalizável para o manejo de pastagens e suficiente para a tomada de decisão no manejo do pastejo em acordo com (Théau et al., 2021), mas necessita de ajustes.

Os resultados encontrados sugerem outros estudos mais aprofundados, de maneira a obter resultados mais precisos acerca das classes agrupadas. A predição com precisão das classes de ALT, auxiliaria na compreensão dos efeitos de curto e longo prazo de diferentes estratégias de pastejo e manejo do pasto, por exemplo, o PO, o PD dos pastos e o ajuste da TL animal como visto na implementação hipotética. Ainda, seria possível realizar o zoneamento das áreas de pastagens com base na altura da planta forrageira. Isso forneceria uma opção de explorar a heterogeneidade espacial e a qualidade nutritiva da pastagem poupando áreas que ainda não estiverem aptas ao pastejo.

Além disso, experimentos realizados preferencialmente dentro da mesma estação, em que os dias são bem similares em condições gerais de tempo, podem auxiliar em melhores resultados, favorecendo a calibração radiométrica. Assim, os modelos poderiam ser criados para cada uma das estações ou ainda, individualmente. Alguns autores sugerem que imagens oblíquas ou ainda 3D podem gerar resultados mais precisos (Aasen et al., 2015; Barbedo et al., 2020; Holman et al., 2016), pois considerariam melhor a refletância das bandas espectrais em função da estrutura do dossel forrageiro.

5. CONCLUSÃO

Algoritmos de classificação com base em faixas de altura média do dossel são ferramentas práticas com potencial para auxílio na tomada de decisão no manejo do pastejo a campo. Contudo, estudos mais aprofundados que utilizem o uso de imagens multiespectrais e técnicas de Aprendizado de Máquina para predição da altura do dossel de *U. decumbens*, devem ser realizados para melhorias no modelo proposto.

Sugerimos um maior banco de dados e com maior variabilidade, para que as classes apresentem número de dados balanceados, de forma alcançar melhores métricas de avaliação do modelo. O estudo representa o estágio inicial de desenvolvimento de uma importante ferramenta para o manejo de pastagens baseado na classificação da altura que precisa ser aprimorada.

REFERÊNCIAS

- Aasen, H., Burkart, A., Bolten, A., & Bareth, G. (2015). Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. *ISPRS Journal of Photogrammetry and Remote Sensing*, *108*, 245–259. <https://doi.org/10.1016/j.isprsjprs.2015.08.002>
- Agisoft (2019). Agisoft Metashape Professional. Retrieved from: www.agisoft.ru
- Alvares, C. A., Stape, J. L., Sentelhas, P. C., de Moraes Gonçalves, J. L., & Sparovek, G. (2013). Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, *22*(6), 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>
- Ali, I., Greifeneder, F., Stamenkovic, J., Neumann, M., & Notarnicola, C. (2015). Review of Machine Learning Approaches for Biomass and Soil Moisture Retrievals from Remote Sensing Data. *Remote Sensing*, *7*(12), 16398–16421. <https://doi.org/10.3390/rs71215841>
- Andriamandroso*, A. L. H., Bindelle*, J., Mercatoris, B., & Lebeau, F. (2016). A review on the use of sensors to monitor cattle jaw movements and behavior when grazing. *BASE*, 273–286. <https://doi.org/10.25518/1780-4507.13058>
- Barbedo, J. G. A., Koenigkan, L. V., & Santos, P. M. (2020). Cattle Detection Using Oblique UAV Images. *Drones*, *4*(4), 75. <https://doi.org/10.3390/drones4040075>
- Batistoti, J., Marcato Junior, J., Ítavo, L., Matsubara, E., Gomes, E., Oliveira, B., Souza, M., Siqueira, H., Salgado Filho, G., Akiyama, T., Gonçalves, W., Liesenberg, V., Li, J., & Dias, A. (2019). Estimating Pasture Biomass and Canopy Height in Brazilian Savanna Using UAV Photogrammetry. *Remote Sensing*, *11*(20), 2447. <https://doi.org/10.3390/rs11202447>

- Birth, G. S., & McVey, G. R. (1968). Measuring the Color of Growing Turf with a Reflectance Spectrophotometer¹. *Agronomy Journal*, 60(6), 640–643. <https://doi.org/10.2134/agronj1968.00021962006000060016x>
- Borra-Serrano, I., De Swaef, T., Muylle, H., Nuyttens, D., Vangeyte, J., Mertens, K., Saeys, W., Somers, B., Roldán-Ruiz, I., & Lootens, P. (2019). Canopy height measurements and non-destructive biomass estimation of *Lolium perenne* swards using UAV imagery. *Grass and Forage Science*, gfs.12439. <https://doi.org/10.1111/gfs.12439>
- Bretas, I. L., Valente, D. S. M., De Oliveira, T. F., Montagner, D. B., Euclides, V. P. B., & Chizzotti, F. H. M. (2023). Canopy height and biomass prediction in Mombaça guinea grass pastures using satellite imagery and machine learning. *Precision Agriculture*. <https://doi.org/10.1007/s11119-023-10013-z>
- Bretas, I. L., Valente, D. S. M., Silva, F. F., Chizzotti, M. L., Paulino, M. F., D'Áurea, A. P., Paciullo, D. S. C., Pedreira, B. C., & Chizzotti, F. H. M. (2021). Prediction of aboveground biomass and dry-matter content in *Brachiaria* pastures by combining meteorological data and satellite imagery. *Grass and Forage Science*, 76(3), 340–352. <https://doi.org/10.1111/gfs.12517>
- Carnevali, R., Silva, S. C., Bueno, A. A. O., Uebele, M. C., Bueno, F. O., Hodgson, J., Silva, G. N., & Morais, J. P. G. (2006). Herbage production and grazing losses in *Panicum maximum* cv. Mombaça under four grazing managements. *Tropical Grasslands*, 40, 165–176.
- Carvalho, P. C. F., Bremm, C., Mezzalira, J. C., Fonseca, L., Da Trindade, J. K., Bonnet, O. J. F., Tischler, M., Genro, C. T. M., Nabinger, C., Laca, E. A. (2015). Can animal performance be predicted from short-term grazing processes? *Animal Production Science (Print)*, 55,319–327.

- Castro, W., Marcato Junior, J., Polidoro, C., Osco, L. P., Gonçalves, W., Rodrigues, L., Santos, M., Jank, L., Barrios, S., Valle, C., Simeão, R., Carromeu, C., Silveira, E., Jorge, L. A. de C., & Matsubara, E. (2020). Deep Learning Applied to Phenotyping of Biomass in Forages with UAV-Based RGB Imagery. *Sensors*, *20*(17), 4802. <https://doi.org/10.3390/s20174802>
- Chapman, D. (2016). Using Ecophysiology to Improve Farm Efficiency: Application in Temperate Dairy Grazing Systems. *Agriculture*, *6*(2), 17. <https://doi.org/10.3390/agriculture6020017>
- Chen, J. M. (1996). Evaluation of Vegetation Indices and a Modified Simple Ratio for Boreal Applications. *Canadian Journal of Remote Sensing*, *22*(3), 229–242. <https://doi.org/10.1080/07038992.1996.10855178>
- Cohen, J. A. (1960). Coefficient of agreement for nominal scales. *Journal of Educational and Measurement*, *20*(1), 37-46. <https://doi.org/10.1177/001316446002000104>
- Da Silva, S., Sbrissia, A., & Pereira, L. (2015). Ecophysiology of C4 Forage Grasses—Understanding Plant Growth for Optimising Their Use and Management. *Agriculture*, *5*(3), 598–625. <https://doi.org/10.3390/agriculture5030598>
- Da Trindade, J. K., Pinto, C. E., Neves, F. P., Mezzalira, J. C., Bremm, C., Genro, T. C. M., Tischler, M. R., Nabinger, C., Gonda, H. L., & Carvalho, P. C. F. (2012). Forage Allowance as a Target of Grazing Management: Implications on Grazing Time and Forage Searching. *Rangeland Ecology & Management*, *65*(4), 382–393. <https://doi.org/10.2111/REM-D-11-00204.1>
- Datt, B. (1999). A New Reflectance Index for Remote Sensing of Chlorophyll Content in Higher Plants: Tests using Eucalyptus Leaves. *Journal of Plant Physiology*, *154*(1), 30–36. [https://doi.org/10.1016/S0176-1617\(99\)80314-9](https://doi.org/10.1016/S0176-1617(99)80314-9)

- Deering, D. W.; Rouse, J. W.; Haas, R. H.; Schell, J. A. Measuring “forage production” of grazing units from Landsat MSS data. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 10., Ann Arbor. **Proceedings...** Ann Arbor, MI: ERIM, 1975. v.2, p.1169-1178.
- Difante, G. D. S., Euclides, V. P. B., Nascimento Júnior, D. D., Silva, S. C. D., Barbosa, R. A., & Torres Júnior, R. A. D. A. (2010). Desempenho e conversão alimentar de novilhos de corte em capim-tanzânia submetido a duas intensidades de pastejo sob lotação rotativa. *Revista Brasileira de Zootecnia*, 39(1), 33–41. <https://doi.org/10.1590/S1516-35982010000100005>
- Echeverria, J. R., Euclides, V. P. B., Sbrissia, A. F., Montagner, D. B., Barbosa, R. A., & Nantes, N. N. (2016). Acúmulo de forragem e valor nutritivo do híbrido de *Urochloa* “BRS RB331 Ipyorã” sob pastejo intermitente. *Pesquisa Agropecuária Brasileira*, 51(7), 880–889. <https://doi.org/10.1590/S0100-204X2016000700011>
- Euclides, V. P. B., Montagner, D. B., Barbosa, R. A., & Nantes, N. N. (2014). Manejo do pastejo de cultivares de *Brachiaria brizantha* (Hochst) Stapf e de *Panicum maximum* Jacq. *Revista Ceres*, 61(suppl), 808–818. <https://doi.org/10.1590/0034-737x201461000006>
- Escarnecia, D. L., & Hodgson, J. (1992). Grazing Management. Science into Practice. *Journal of Range Management*, 45(5), 509. <https://doi.org/10.2307/4002914>
- Gamon, J. A., Peñuelas, J., & Field, C. B. (1992). A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. *Remote Sensing of Environment*, 41(1), 35–44. [https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/10.1016/0034-4257(92)90059-S)

- Gamon, J. A., & Surfus, J. S. (1999). Assessing leaf pigment content and activity with a reflectometer. *New Phytologist*, *143*(1), 105–117. <https://doi.org/10.1046/j.1469-8137.1999.00424.x>
- Gitelson, A. A. (2005). Remote estimation of canopy chlorophyll content in crops. *Geophysical Research Letters*, *32*(8), L08403. <https://doi.org/10.1029/2005GL022688>
- Gitelson, A. A., Gritz †, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, *160*(3), 271–282. <https://doi.org/10.1078/0176-1617-00887>
- Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, *58*(3), 289–298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Gitelson, A. A., Zur, Y., Chivkunova, O. B., & Merzlyak, M. N. (2002). Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy *Photochemistry and Photobiology*, *75*(3), 272. [https://doi.org/10.1562/0031-8655\(2002\)075<0272:ACCIPL>2.0.CO;2](https://doi.org/10.1562/0031-8655(2002)075<0272:ACCIPL>2.0.CO;2)
- Gomide, C. A., Chaves, C. S., Ribeiro, K. G., Sollenberger, L. E., Paciullo, D. S., Pereira, T. P., & Morenz, M. J. (2015a). Structural traits of elephant grass (*Pennisetum purpureum* Schum.) genotypes under rotational stocking strategies. *African Journal of Range & Forage Science*, *32*(1), 51–57. <https://doi.org/10.2989/10220119.2014.930929>

- Holman, F., Riche, A., Michalski, A., Castle, M., Wooster, M., & Hawkesford, M. (2016). High Throughput Field Phenotyping of Wheat Plant Height and Growth Rate in Field Plot Trials Using UAV Based Remote Sensing. *Remote Sensing*, 8(12), 1031. <https://doi.org/10.3390/rs8121031>
- Huete, A. (1997). A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment*, 59(3), 440–451. [https://doi.org/10.1016/S0034-4257\(96\)00112-5](https://doi.org/10.1016/S0034-4257(96)00112-5)
- Insua, J. R., Utsumi, S. A., & Basso, B. (2019). 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*, 14(3), e0212773. <https://doi.org/10.1371/journal.pone.0212773>
- Jáuregui, J. M., Michelini, D. F., Agnusdei, M. G., Baudracco, J., Sevilla, G. H., Chilibroste, P., & Lattanzi, F. A. (2017). Persistence of tall fescue in a subtropical environment: Tiller survival over summer in response to flowering control and nitrogen supply. *Grass and Forage Science*, 72(3), 454–466. <https://doi.org/10.1111/gfs.12252>
- Jensen J.R. (2009) - Remote Sensing of the Environment: An Earth Resource Perspective. 2nd Eds. Pearson Education.
- Jordan, C. F. (1969). Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. *Ecology*, 50(4), 663–666. <https://doi.org/10.2307/1936256>
- Kaufman, Y. J., & Tanre, D. (1992). Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 261–270. <https://doi.org/10.1109/36.134076>

- Kill-Silveira, R. (2020). Manejo ecofisiológico das gramíneas *Megathyrus maximus* (*Panicum maximum*) cv. Tanzânia, Mombaça e Massai. *Veterinária e Zootecnia*, 27, 1–13. <https://doi.org/10.35172/rvz.2020.v27.421>
- Legg, M., & Bradley, S. (2019). Ultrasonic Proximal Sensing of Pasture Biomass. *Remote Sensing*, 11(20), 2459. <https://doi.org/10.3390/rs11202459>
- Leiva, J. N., Robbins, J., Saraswat, D., She, Y., & Ehsani, R. (2017). Evaluating remotely sensed plant count accuracy with differing unmanned aircraft system altitudes, physical canopy separations, and ground covers. *Journal of Applied Remote Sensing*, 11(3), 036003. <https://doi.org/10.1117/1.JRS.11.036003>
- Lessire, F., Jacquet, S., Veselko, D., Piraux, E., & Dufrasne, I. (2019). Evolution of Grazing Practices in Belgian Dairy Farms: Results of Two Surveys. *Sustainability*, 11(15), 3997. <https://doi.org/10.3390/su11153997>
- Li, S., Ding, X., Kuang, Q., Ata-UI-Karim, S. T., Cheng, T., Liu, X., Tian, Y., Zhu, Y., Cao, W., & Cao, Q. (2018). Potential of UAV-Based Active Sensing for Monitoring Rice Leaf Nitrogen Status. *Frontiers in Plant Science*, 9, 1834. <https://doi.org/10.3389/fpls.2018.01834>
- Li, S., Jiao, J., & Wang, C. (2021). Research on Polarized Multi-Spectral System and Fusion Algorithm for Remote Sensing of Vegetation Status at Night. *Remote Sensing*, 13(17), 3510. <https://doi.org/10.3390/rs13173510>
- Li, Z., Han, G., Zhao, M., Wang, J., Wang, Z., Kemp, D. R., Michalk, D. L., Wilkes, A., Behrendt, K., Wang, H., & Langford, C. (2015). Identifying management strategies to improve sustainability and household income for herders on the desert steppe in Inner Mongolia, China. *Agricultural Systems*, 132, 62–72. <https://doi.org/10.1016/j.agsy.2014.08.011>

- Ma, Q., Chai, L., Hou, F., Chang, S., Ma, Y., Tsunekawa, A., & Cheng, Y. (2019). Quantifying Grazing Intensity Using Remote Sensing in Alpine Meadows on Qinghai-Tibetan Plateau. *Sustainability*, 11(2), 417. <https://doi.org/10.3390/su11020417>
- Maes, W., Huete, A., & Steppe, K. (2017). Optimizing the Processing of UAV-Based Thermal Imagery. *Remote Sensing*, 9(5), 476. <https://doi.org/10.3390/rs9050476>
- Maresma, Á., Ariza, M., Martínez, E., Lloveras, J., & Martínez-Casasnovas, J. (2016). Analysis of Vegetation Indices to Determine Nitrogen Application and Yield Prediction in Maize (*Zea mays* L.) from a Standard UAV Service. *Remote Sensing*, 8(12), 973. <https://doi.org/10.3390/rs8120973>
- Martins, C. D. M., Euclides, V. P. B., Barbosa, R. A., Montagner, D. B., & Miqueloto, T. (2013). Consumo de forragem e desempenho animal em cultivares de *Urochloa humidicola* sob lotação contínua. *Pesquisa Agropecuária Brasileira*, 48(10), 1402–1409. <https://doi.org/10.1590/S0100-204X2013001000012>
- Morota, G., Ventura, R. V., Silva, F. F., Koyama, M., & Fernando, S. C. (2018). BIG DATA ANALYTICS AND PRECISION ANIMAL AGRICULTURE SYMPOSIUM: Machine learning and data mining advance predictive big data analysis in precision animal agriculture1. *Journal of Animal Science*, 96(4), 1540–1550. <https://doi.org/10.1093/jas/sky014>
- Murphy, D. J., Murphy, M. D., O'Brien, B., & O'Donovan, M. (2021). A Review of Precision Technologies for Optimising Pasture Measurement on Irish Grassland. *Agriculture*, 11(7), 600. <https://doi.org/10.3390/agriculture11070600>

- Mutanga, O., Adam, E., & Cho, M. A. (2012). High density biomass estimation for wetland vegetation using WorldView-2 imagery and random forest regression algorithm. *International Journal of Applied Earth Observation and Geoinformation*, 18, 399–406. <https://doi.org/10.1016/j.jag.2012.03.012>
- O'Mara, F. P. (2012). The role of grasslands in food security and climate change. *Annals of Botany*, 110(6), 1263–1270. <https://doi.org/10.1093/aob/mcs209>
- Omote, H., Castro, L. M., & Graciano, V. A. (2021). *Monitoramento tecnológico de cultivares de forrageiras no Brasil*.
- Paciullo, D. S. C., Gomide, C. A. M., Castro, C. R. T., Maurício, R. M., Fernandes, P. B., & Morenz, M. J. F. (2017). Morphogenesis, biomass and nutritive value of *Panicum maximum* under different shade levels and fertilizer nitrogen rates. *Grass and Forage Science*, 72(3), 590–600. <https://doi.org/10.1111/gfs.12264>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E. (2011). Scikit-Learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Pedreira, C. G. S., Silva, V. J., Pedreira, B. C., & Sollenberger, L. E. (2017). Herbage Accumulation and Organic Reserves of Palisadegrass in Response to Grazing Management based on Canopy Targets. *Crop Science*, 57(4), 2283–2293. <https://doi.org/10.2135/cropsci2016.11.0957>

- Peñuelas, J.; Baret, F.; Filella, I. 1995. Semi-empirical indices to assess carotenoids: chlorophyll a ratio from leaf spectral reflectance. *Photosynthetica* 31: 221-230.
- Parsons, A.J.; Chapman, D.F. The principles of pasture growth and utilization. In *Grass: Its Production and Utilization*; Hopkins, A., Holmes, W., Eds.; Blackwell Science for the British Grassland Society: Oxford, UK, 2000; ISBN 0632050179
- Parsons, A. J., & Penning, P. D. (1988). The effect of the duration of regrowth on photosynthesis, leaf death and the average rate of growth in a rotationally grazed sward. *Grass and Forage Science*, 43(1), 15–27. <https://doi.org/10.1111/j.1365-2494.1988.tb02137.x>
- QGIS Development Team (2019). QGIS Geographic Information System. Version 3.2. Open Source Geospatial Foundation Project. Retrieved from: <http://qgis.osgeo.org>.
- Reinermann, S., Asam, S., & Kuenzer, C. (2020). Remote Sensing of Grassland Production and Management—A Review. *Remote Sensing*, 12(12), 1949. <https://doi.org/10.3390/rs12121949>
- Ribeiro, A. C., Guimaraes, P. T. G., Alvarez V., V. H. (Ed.). (1999). Recomendação para o uso de corretivos e fertilizantes em Minas Gerais, 5^o Aproximação. Viçosa, Comissão de Fertilidade do Solo do Estado de Minas Gerais, p. 13–20.
- Richardson, A. J., Wiegand, C. L. (1977). Distinguishing vegetation from soil background information. *Photogrammetric Engineering & Remote Sensing*, 43 (12), 1541-1552.
- Roujean, J. L., & Breon, F. M. (1995). Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3), 375–384. [https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)

- Rouse, W. J., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. Retrieved from [https://ntrs.nasa.gov/search.jsp?R=1974 0 0 2 2614](https://ntrs.nasa.gov/search.jsp?R=1974%20022614)
- Santos, H. G. dos. (2018). *Sistema brasileiro de classificação de solos* (5ª edição revista e ampliada). Embrapa.
- Schons, R. M. T., Laca, E. A., Savian, J. V., Mezzalira, J. C., Schneider, E. A. N., Caetano, L. A. M., Zubieta, A. S., Benvenuti, M. A., & Carvalho, P. C. de. F. (2021). 'Rotatinuous' stocking: An innovation in grazing management to foster both herbage and animal production. *Livestock Science*, *245*, 104406. <https://doi.org/10.1016/j.livsci.2021.104406>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, *6*(1), 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Sripada, R. P., Heiniger, R. W., White, J. G., & Meijer, A. D. (2006). Aerial Color Infrared Photography for Determining Early In-Season Nitrogen Requirements in Corn. *Agronomy Journal*, *98*(4), 968–977. <https://doi.org/10.2134/agronj2005.0200>
- Théau, J., Lauzier-Hudon, É., Aubé, L., & Devillers, N. (2021). Estimation of forage biomass and vegetation cover in grasslands using UAV imagery. *PLOS ONE*, *16*(1), e0245784. <https://doi.org/10.1371/journal.pone.0245784>
- Tiscornia, G., Baethgen, W., Ruggia, A., Do Carmo, M., & Ceccato, P. (2019). Can we Monitor Height of Native Grasslands in Uruguay with Earth Observation? *Remote Sensing*, *11*(15), 1801. <https://doi.org/10.3390/rs11151801>

- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- Tullo, E., Finzi, A., & Guarino, M. (2019). Review: Environmental impact of livestock farming and Precision Livestock Farming as a mitigation strategy. *Science of The Total Environment*, 650, 2751–2760. <https://doi.org/10.1016/j.scitotenv.2018.10.018>
- Valote, P. D., Carvalho, C. A. B. de, Freitas, C. A. S., Morenz, M. J. F., Paciullo, D. S. C., & Gomide, C. A. de M. (2021). Forage mass and canopy structure of Zuri and Quênia guineagrasses pasture under rotational stocking. *Revista Brasileira de Zootecnia*, 50, e20200225. <https://doi.org/10.37496/rbz5020200225>
- Viña, A., Gitelson, A. A., Nguy-Robertson, A. L., & Peng, Y. (2011). Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. *Remote Sensing of Environment*, 115(12), 3468–3478. <https://doi.org/10.1016/j.rse.2011.08.010>
- Vincini, M., Frazzi, E., & D'Alessio, P. (2008). A broad-band leaf chlorophyll vegetation index at the canopy scale. *Precision Agriculture*, 9(5), 303–319. <https://doi.org/10.1007/s11119-008-9075-z>
- Wachendorf, M., Fricke, T., & Möckel, T. (2018). Remote sensing as a tool to assess botanical composition, structure, quantity and quality of temperate grasslands. *Grass and Forage Science*, 73(1), 1–14. <https://doi.org/10.1111/gfs.12312>
- Wang, F., Yi, Q., Hu, J., Xie, L., Yao, X., Xu, T., & Zheng, J. (2021). Combining spectral and textural information in UAV hyperspectral images to estimate rice grain yield. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102397. <https://doi.org/10.1016/j.jag.2021.102397>

- Wijesingha, J., Astor, T., Schulze-Brüninghoff, D., Wengert, M., & Wachendorf, M. (2020). Predicting Forage Quality of Grasslands Using UAV-Borne Imaging Spectroscopy. *Remote Sensing*, 12(1), 126. <https://doi.org/10.3390/rs12010126>
- Yan, S., Yao, X., Zhu, D., Liu, D., Zhang, L., Yu, G., Gao, B., Yang, J., & Yun, W. (2021). Large-scale crop mapping from multi-source optical satellite imageries using machine learning with discrete grids. *International Journal of Applied Earth Observation and Geoinformation*, 103, 102485. <https://doi.org/10.1016/j.jag.2021.102485>
- Yao, H., Qin, R., & Chen, X. (2019). Unmanned Aerial Vehicle for Remote Sensing Applications—A Review. *Remote Sensing*, 11(12), 1443. <https://doi.org/10.3390/rs11121443>
- Yu, R., Evans, A. J., & Malleson, N. (2018). Quantifying grazing patterns using a new growth function based on MODIS Leaf Area Index. *Remote Sensing of Environment*, 209, 181–194. <https://doi.org/10.1016/j.rse.2018.02.034>
- Zanini, G. D., Santos, G. T., & Sbrissia, A. F. (2012). Frequencies and intensities of defoliation in Aruana Guineagrass swards: Accumulation and morphological composition of forage. *Revista Brasileira de Zootecnia*, 41(4), 905–913. <https://doi.org/10.1590/S1516-35982012000400011>

CAPÍTULO II - DETERMINAÇÃO AUTOMATIZADA DA CONCENTRAÇÃO DE PROTEÍNA BRUTA DE CAPIM-BRAQUIÁRIA VIA SENSORIAMENTO REMOTO E MODELO DE APRENDIZADO DE MÁQUINAS.

RESUMO

O monitoramento em tempo real e não destrutivo da concentração de proteína bruta (PB) em áreas de pastagens é de suma importância para manejo preciso da nutrição animal em pastejo. Considerando que modelos de predição da concentração de PB dos pastos tropicais são incipientes, objetivou-se desenvolver um modelo para prever esta variável nos pastos de *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Basilisk a partir de Sensor Remoto e técnica de Aprendizado de Máquinas. Foram obtidas imagens multiespectrais a partir de Veículo Aéreo Não Tripulado (VANT) entre os anos de 2019 e 2021 em 30 canteiros de 3 m² com diferentes idades de rebrotação, totalizando 20 voos. As imagens foram processadas para extração dos valores médios e desvio padrão da média dos Índices de Vegetação (IVs). Utilizou-se o algoritmo *Random Forest* para desenvolver o modelo de predição da concentração de PB em % da matéria seca (MS) com base em dados de referência coletados a campo e estimados em laboratório. Os resultados demonstraram que 40.52% (R²) dos dados se ajustam ao modelo de regressão através dos IVs selecionados com erros de 2.13% de PB na MS dos pastos de *U. decumbens*. A estimativa da concentração de PB dos pastos de forma remota é complexa e esforços devem ser direcionados a fim de aumentar o ajuste no modelo e reduzir os erros na predição desta variável. Sugere-se o estudo aprofundado do *Enhanced Vegetation Index* (EVI), *Leaf Chlorophyll Index* (LCI), *Photochemical Reflectance Index* (PRI) e *Ratio Vegetation Index* (RVI) que participaram efetivamente do modelo e foram bem correlacionados de forma a atingir os objetivos propostos num futuro próximo. Por fim, outras técnicas de análises de dados para predição de PB devem ser avaliadas, assim como outras variáveis no modelo como dados meteorológicos e bandas espectrais, o que pode auxiliar no desenvolvimento de modelos capazes de prever com maior precisão e acurácia esta variável.

Palavras-chave: Inteligência Artificial. Manejo. *Random Forest*. Valor nutritivo, VANTS. Zootecnia de Precisão

1. INTRODUÇÃO

As áreas de pastagens ocupam cerca de 160 milhões de hectares (IBGE, 2017) e constituem a base da dieta dos ruminantes na maioria dos sistemas de produção das regiões tropicais. Estas, são responsáveis pela alimentação de cerca de 0.2 mil milhões de búfalos, mil milhões de cabras, 1.2 mil milhões de ovinos e 1.5 mil milhões de bovinos em todo o mundo (FAOSTAT, 2016).

Considerando-se a importância da pastagem no cenário mundial, determinar os nutrientes disponíveis é um dos principais balizadores da produtividade animal manejados sob pastejo (da Silva et al., 2015; Dubeux Jr. et al, 2004). À medida que o manejo é intensificado, conhecer estas concentrações de nutrientes são ainda mais relevantes no planejamento forrageiro, pois auxiliam na determinação das necessidades de realocação ou de suplementação conforme a categoria animal. Também contribuem para o zoneamento das áreas de pastejo de forma a otimizar a dieta do animal, o manejo do pastejo e da pastagem em direção a pecuária de precisão e a sustentabilidade desses sistemas (Bendig et al., 2014).

Sobre os parâmetros nutricionais das plantas forrageiras, sabe-se que a concentração de nitrogênio (N) da forragem está positivamente correlacionada com a concentração de proteína (PB) (Clifton et al., 1994; Wang et al., 2004). Na nutrição, a proteína compreende um nutriente importante para os herbívoros (Prins & Beekman, 1989; Prins & Van Langevelde, 2008). Esta possui papel essencial de suprir as exigências metabólicas dos animais, fazendo com que os mesmos se desenvolvam e produzam de acordo com seus limites fisiológicos.

No entanto, a estimativa da concentração de PB depende de métodos tradicionais, baseados principalmente em levantamentos de campo. Tais métodos são caracterizados por serem além de destrutivos, onerosos e demorados (Borra-Serrano et al., 2019; Castro et al., 2020; Delevatti et al., 2019; Ma et al., 2019). Somado a isso, a qualidade nutricional da planta é muito variável. Tais variações de qualidade ocorrem não somente entre gêneros, espécies ou cultivares, mas também, com as diferentes partes das plantas, estágio de maturidade, fertilidade do solo e com as condições locais e estacionais, que comprometem a estimativa para toda área e implicam na redução da precisão dos dados coletados (Bretas et al., 2021; Norton, 1982).

Nesses casos, o uso de métodos indiretos e modernos podem ser mais rápidos e eficazes para obter as informações acerca das pastagens. Dessa forma, a detecção remota fornece uma alternativa que pode fornecer estimativas do valor nutritivo da forragem com menor tempo de resposta. Devido ao avanço da tecnologia e a partir de estudos que envolvem zootecnia e agricultura de precisão muitas atividades dentro das fazendas foram otimizadas (Leiva et al., 2017).

O Sensoriamento Remoto (SR) compreende um desses avanços. Dentre as tecnologias de SR, destacam-se o uso de imagens obtidas via satélite e a utilização de Veículos Aéreos Não Tripulados (VANTS), como instrumentos de coleta de dados. O SR por satélite oferece grande possibilidade de monitoramento de culturas em larga escala (Yan et al., 2021). No entanto, vários estudos destacaram condições climáticas adversas (por exemplo, cobertura de nuvens) e a baixa resolução temporal resultante como as principais limitações do uso de satélites para monitoramento das pastagens (Barrett et al., 2014; Wang et al., 2019; Murphy et al., 2021).

Já os VANTS, surgem como uma promissora plataforma de SR devido à sua flexibilidade (Yao et al., 2019) e foram amplamente investigados para monitoramento de culturas com sensores de imagem (S. Li et al., 2021; Maresma et al., 2016; Wang et al., 2021). A partir de sensores a bordo de VANTS é possível rastrear pequenas áreas com alta resolução espaço-temporal e acompanhar uma estação inteira de crescimento com versatilidade em termos de planejamento de voo, excluindo as limitações inerentes ao uso das imagens obtidas via satélite (Maes et al., 2017).

A possibilidade do acompanhamento das áreas agrícolas via sensores deve-se à capacidade dos mesmos em capturar as diferentes ondas do espectro eletromagnético emitidas pela vegetação e outros alvos, tais como água e solo exposto. A cobertura vegetal, por exemplo, reflete proporções diferentes de energia nas regiões do Azul, Verde, Vermelho, *Red Edge* e Infravermelho Próximo (Hamid Muhammed & Larsolle, 2003). A partir dessas informações e associando técnicas de refletância, segundo Jensen (2009), são gerados os chamados Índices de Vegetação (IVs). Os IVs se correlacionam com diferentes aspectos agrônômicos das culturas (Viña et al., 2011) e, com isso, podem auxiliar no ajuste de uma gama de atividades agropecuárias.

Porém, estes dados baseados em sensores, são gerados em alta velocidade e com diferentes formatos, criando um “*big data*” que excede a capacidade de análise

pelas ferramentas tradicionais (Morota et al. 2018). Dessa forma, técnicas de Inteligência Artificial (IA) têm sido cada vez mais utilizadas nos últimos anos para enfrentar o desafio da complexidade desses dados (Ali et al. 2015; Morota et al. 2018), e contribui para a produção no campo de forma rápida, dinâmica, indireta e precisa (Wachendorf et al., 2018).

Entre as principais ferramentas utilizadas em IA, as técnicas de Aprendizado de Máquinas (AM) têm ganhado destaque devido à capacidade de automatizar a análise de *big data*. Algoritmos de AM podem reconhecer padrões em conjuntos de dados complexos e resolver problemas de classificação de forma rápida e automática ou diversas regressões. Assim, configura-se uma alternativa rápida, dinâmica e precisa em relação às avaliações a nível de campo tradicionalmente estabelecidas (Leiva et al., 2017).

Trabalhos recentes demonstram os avanços em termos de monitoramento do manejo de pastagens e do pastejo animal através do Sensoriamento Remoto (SR) (Bretas et al., 2023; Murphy et al., 2021; Reinermann et al., 2020). Alguns deles, atestaram o potencial do uso de Veículo Aéreo Não Tripulado (VANT), aliado a técnica de Aprendizado de Máquinas (AM) para determinação automatizada de parâmetros quantitativos e nutricionais das pastagens (Batistoti et al., 2019; Insua et al., 2019; Lussem et al., 2019; Wijesingha et al., 2020).

No entanto, modelos de predição da concentração de PB da forragem a partir de SR são uma área nova de pesquisa e incipientes para *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Basilisk, forrageira de origem africana, naturalizada em regiões tropicais e subtropicais do mundo. Assim, estudos que envolvem a análise espectral acerca dessa variável precisam ser aprofundados, somados à dificuldade da estimativa da mesma em função da natureza dinâmica e das interações planta-luz e mobilidade do N através da planta (F. Wang et al., 2021; Zhou et al., 2018).

Neste estudo, objetivou-se avaliar um modelo automatizado para prever a concentração de proteína bruta dos pastos de *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Basilisk via VANT e técnica de Aprendizado de Máquinas, sob a hipótese de que é possível prever esta variável utilizando-se tais ferramentas baseado em uma seleção de Índices de Vegetação.

2. MATERIAL E MÉTODOS

2.1. Localização e descrição da área de estudo

O experimento foi realizado na Unidade de Ensino, Pesquisa e Extensão em Forragicultura (UEPE Forragicultura) (Figura 1), situada na Universidade Federal de Viçosa (UFV), Viçosa, Minas Gerais, Brasil (lat. 20° 45'S, long. 42° 51'W e alt. 651 m).

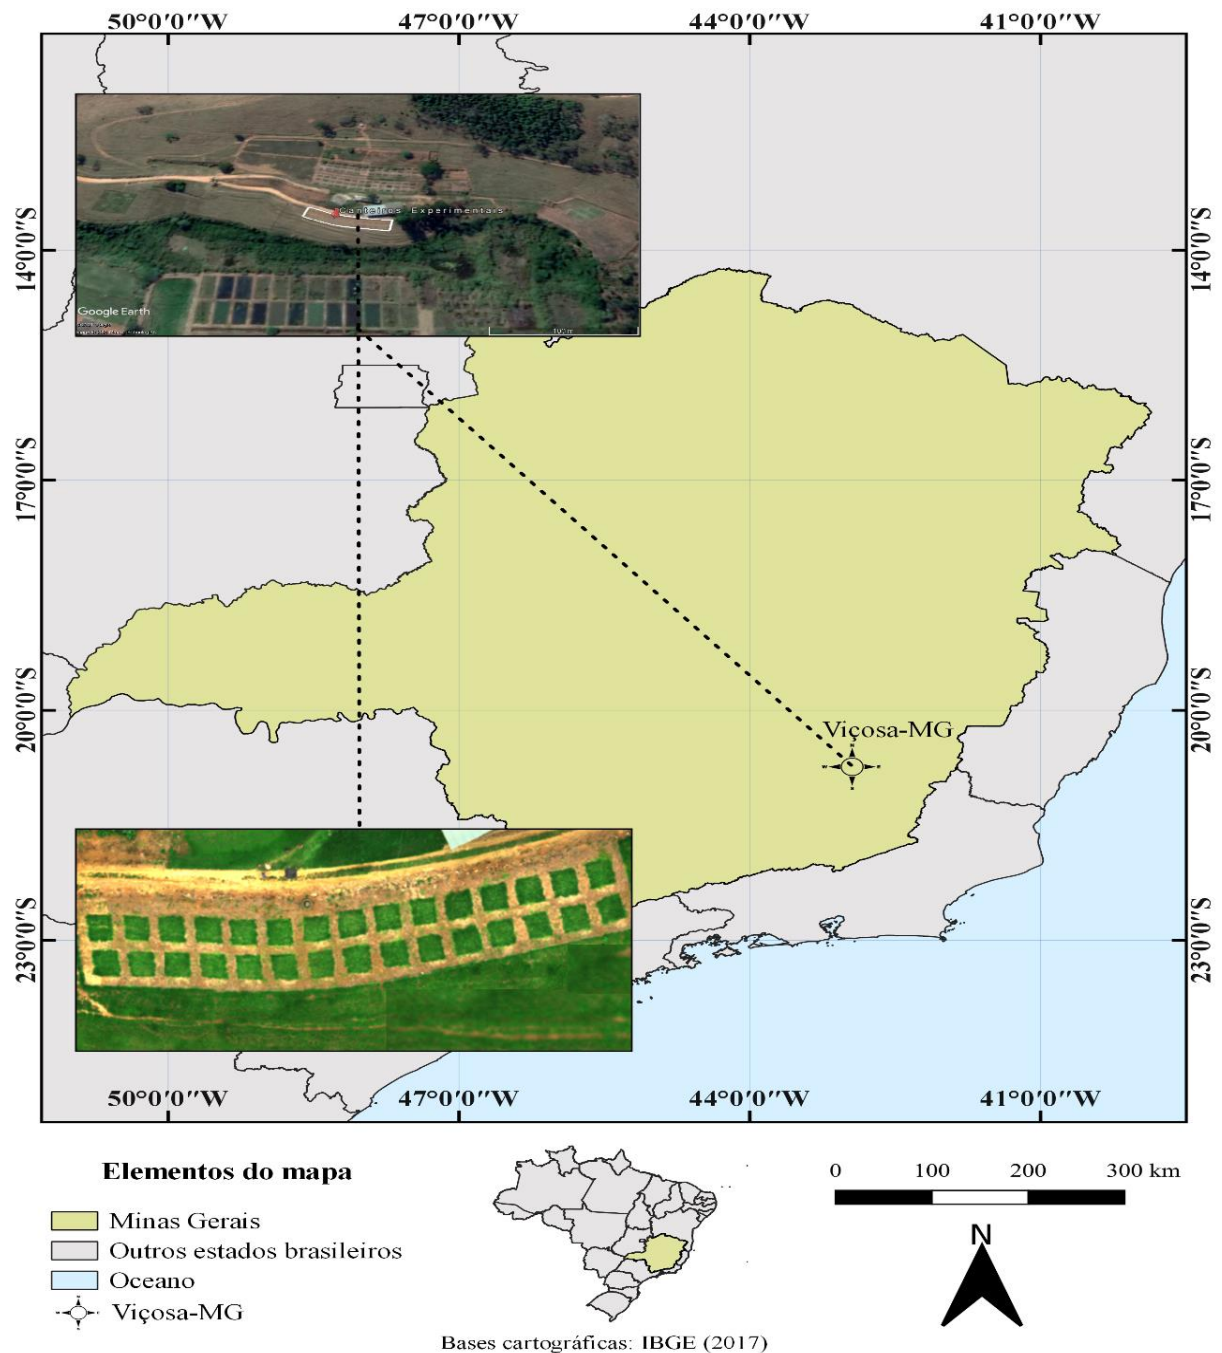


Figura 1. Localização da área de estudo.

Em um piquete previamente formado de *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Basilisk, vedado desde agosto de 2019, uma área de 500 m² foi selecionada, de acordo com a uniformidade do terreno, para alocar 30 canteiros experimentais de 3 m² cada, que foram dispostos em duas linhas horizontais, distantes 1,5 m entre si (Figura 1).

Na Figura 2 estão apresentados os dados meteorológicos referentes ao período de avaliação experimental (setembro de 2019 a março de 2021) obtidos de estação localizada a 550 m da área de estudo. O município de Viçosa possui clima Cwa, subtropical segundo a classificação de Köppen (Alvares et al., 2013). As estações secas e chuvosas da região são bem definidas.

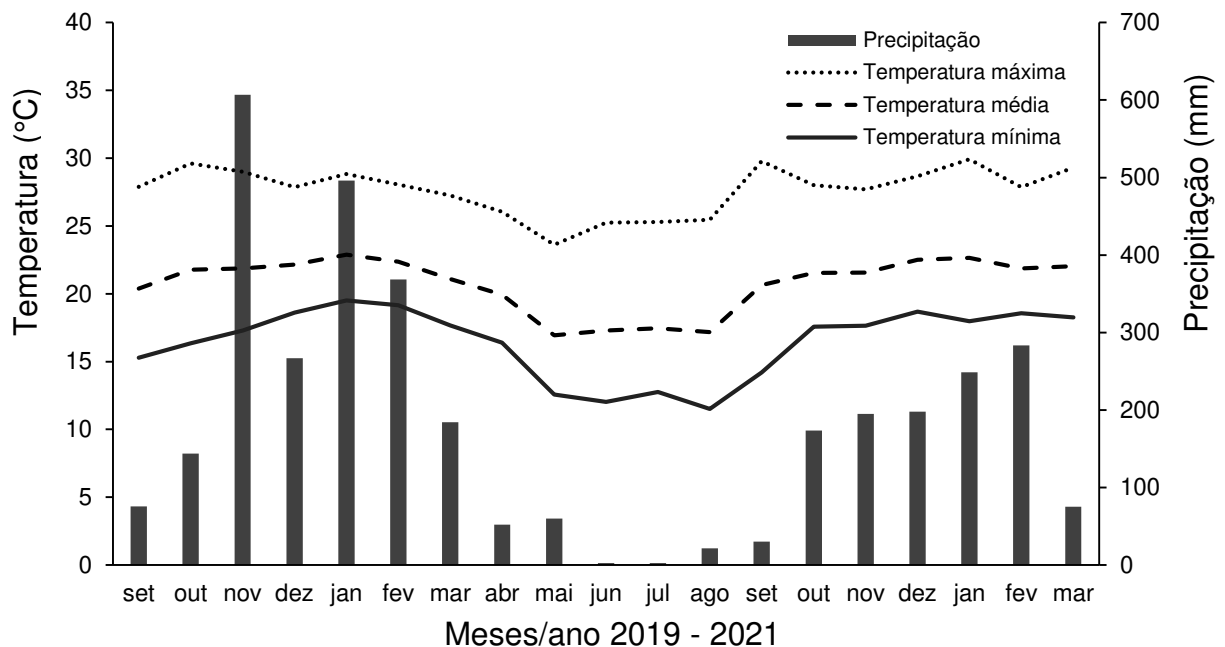


Figura 2. Precipitação pluvial (mm) e temperaturas (°C) máximas, médias e mínimas coletadas durante o período experimental.

O solo da área de estudo é caracterizado como Latossolo Vermelho-Amarelo, de textura argilosa (Santos, 2018). Até o período pré-estudo, nenhum fertilizante havia sido utilizado. Uma amostra composta de solo da área experimental foi encaminhada para análise e o solo foi corrigido de acordo com o resultado da análise química na Tabela 1.

Tabela 1. Resultado da análise química do solo coletado na área experimental.

pH	P	K	V	m	P-rem	
H ₂ O	----- mg dm ⁻³ -----		----- % -----		mg L ⁻¹	
5.6	1.2	77.0	58.0	0.0	24.0	
Ca ²⁺	Mg ²⁺	Al ³⁺	H+Al	SB	T	T
----- cmol _c dm ⁻³ -----						
3.4	0.7	0.0	3.1	4.3	4.3	7.4

Abreviações: pH, potencial hidrogeniônico; P, Fósforo; K: Potássio; V, Índice de Saturação por Bases; m, Índice de Saturação por Alumínio; P-rem, Fósforo Remanescente; Ca²⁺, Cálcio; Mg²⁺, Magnésio; Al³⁺, Alumínio; H + Al, Acidez Potencial; SB, Soma de Bases Trocáveis; t, Capacidade de Troca Catiônica Efetiva; T, Capacidade de Troca Catiônica a pH 7,0.

Foram realizadas duas adubações de manutenção ao longo do período experimental com 30 kg.ha⁻¹ de P₂O₅ e 150 kg.ha⁻¹ de N de acordo com Ribeiro et al. (1999), considerando-se médio nível tecnológico. A primeira adubação foi parcelada em três datas (12/11/2019; 27/02/2020; 10/03/2020) e a segunda em duas datas (22/09/2020; 17/12/2020) de aplicações. A quantidade de adubo foi igualmente fracionada e distribuída para os 30 canteiros.

2.2. Dados de campo

O período experimental incluiu a primavera e o verão de 2019 a 2021 e foram totalizados 20 voos com a aeronave Matrice 100 com câmera MicaSense RedEdge - MX[®] a bordo. A câmera possui cinco sensores semicondutores de óxido metálicos complementares que fornecem informações sobre as bandas espectrais Azul (~475 nm), Verde (~560 nm), Vermelho (~668 nm), Red Edge (~717 nm) e Infravermelho Próximo (~840 nm).

Antes de cada voo, obteve-se uma foto do painel de calibração da refletância incluída no *kit* da câmera MicaSense RedEdge - MX[®] com objetivo de ajustar o conjunto de imagens de acordo com as condições de iluminação do dia (calibração radiométrica).

O plano de voo foi programado para garantir: (1) sobreposição frontal e lateral de 75%, (2) altura fixa de 50 metros e (3) tempo de voo fixo. A resolução espacial foi de quatro cm por *pixel*. Os voos aconteceram sob clima estável e condição de céu limpo, sempre no mesmo horário, às 12 h 00 min (horário local), para limitar as variações no ângulo do sol e as condições de iluminação.

As amostras de forragem foram coletadas imediatamente após cada voo. Até o 7º voo, foram amostrados 30 canteiros experimentais ($n = 210$). Do 8º voo até o vigésimo voo, dez canteiros com diferentes idades de rebrotação foram amostrados por voo ($n=130$). Com o objetivo de gerar variação nas alturas do capim-braquiária, os 30 canteiros foram cortados em idades distintas de rebrotação, sendo que 10 eram cortados em intervalos que variavam de 10-15 dias, outros 10 a cada 21-28 dias e 10 entre 35-42 dias. A Figura 3 mostra as variações geradas.



Figura 3. Variações de altura criadas nos canteiros experimentais.

As amostras de forragem foram coletadas com auxílio de uma moldura metálica com dimensões de 1 m x 0,5 m, alocada no centro de cada canteiro experimental. A forragem contida na moldura foi cortada rente ao solo utilizando uma foice de poda (cutelo), armazenadas em sacolas plásticas e transportadas para pesagem. Dessa amostra, uma subamostra de aproximadamente 400 g foi retirada e levada para estufa por 72 horas a 55 °C e, então, pesada novamente, com a finalidade de estimar a porcentagem de amostra seca ao ar (ASA) de acordo com a Equação 1.

$$\%ASA = \frac{\text{PESO DA AMOSTRA VERDE (g)} - \text{PESO DA AMOSTRA SECA (g)}}{\text{PESO DA AMOSTRA SECA (g)}} \times 100 \quad (1)$$

As amostras secas previamente foram moídas em moinho de facas com peneiras de porosidade de 1 mm e, cerca de 2 g foram levadas à estufa de circulação forçada de ar para secagem definitiva a 105 °C, por 16 horas. Depois desse período, uma nova pesagem em balança com precisão de 0,0001 g foi realizada, constituindo a amostra seca em estufa (ASE), segundo a Equação 2.

$$\% ASE = \frac{\text{PESO DA AMOSTRA SECA (g)} - \text{PESO DA AMOSTRA SECA (105°C) (g)}}{\text{PESO DA AMOSTRA SECA (105°C) (g)}} \times 100 \quad (2)$$

De posse da amostra moída de cada uma das coletas de campo, foi então determinada a concentração de PB da forragem, pelo método proposto por Kjeldahl. Para tanto, foram retiradas subamostras de 2 g da planta total, a qual foi submetida a três etapas distintas: digestão, destilação e titulação (Detmann et al., 2012). Totalizaram-se 340 observações da concentração de proteína bruta (% MS). Na Figura 4, estão apresentadas as concentrações de PB observadas ao longo de cada voo em cada canteiro avaliado durante o período experimental. A menor e a maior concentração de PB na MS observadas foram, respectivamente de 2.17% e 18.35%, com valor médio de 9.13%. Obteve-se 1.44% de desvio padrão e 16% de coeficiente de variação.




Figura 4. Concentrações de Proteína Bruta (%) obtidas em cada voo ao longo do período experimental.

2.3. Pré - processamento e construção dos ortomosaicos

Após a aquisição das ortofotos, as mesmas foram pré-processadas a partir do *software* Agisoft Metashape Professional® versão 1.7 (Agisoft, 2019) para construção do ortomosaico em seis etapas: (1) calibração automática a partir da foto do painel calibração de refletância, (2) alinhamento das imagens, (3) construção de uma nuvem tridimensional de pontos, (4) densificação da nuvem tridimensional, (5) construção de um modelo digital de superfície e (6) construção do ortomosaico. Após a construção do ortomosaico, o mesmo foi exportado em formato *Tiff* e, em ambiente de Sistemas de Informação Geográfica (SIG), para o *software* QGIS®, versão 3.2 (QGIS Development Team, 2019). Foram criados polígonos de contorno manualmente, excluindo as bordas para cada canteiro experimental dos quais as amostras de forragem eram coletadas para cada voo.

2.4. Índices de Vegetação

Para cada *pixel* que formaram a imagem recortada de cada canteiro, foram obtidos os valores das cinco diferentes bandas espectrais, Azul (~475 nm), Verde (~560 nm), Vermelho (~668 nm), *Red Edge* (~717 nm) e Infravermelho Próximo (~840 nm). Com base nos valores obtidos das bandas do VERM e NIR, foi calculado o valor

médio do *Normalized Difference Vegetation Index* (NDVI) de cada uma das imagens recortadas. O NDVI é um dos Índices de Vegetação (IVs) mais explorados, proposto por Rouse et al. (1974), calculado segundo a Equação 3.

$$\text{NDVI} = \frac{\text{NIR} - \text{VERM}}{\text{NIR} + \text{VERM}} \quad (3)$$

Como as imagens recortadas também traziam informações do solo, as mesmas foram filtradas a partir da média dos valores de NDVI para cada voo em cada canteiro. Essa estratégia foi utilizada com objetivo de remover *pixels* irrelevantes, isto é, para eliminar detalhes que não são de interesse para as etapas subsequentes do processamento. Totalizaram-se quatro máscaras de filtragem: NDVI > 0, NDVI > 0.20, NDVI > 0.40, NDVI > 0.60. Os valores médios de todos os IVs utilizados no estudo, incluindo o NDVI e também o desvio padrão da média de cada um deles foram calculados com base nas máscaras de filtragem. Para o cálculo dos índices médios de vegetação, foi considerado apenas os *pixels* com valor um na referida máscara.

Ao todo, nesse estudo, foram calculados 23 IVs (Tabela 2) a partir da linguagem de programação Python 3.7 e a biblioteca *Scikit-Learn* (Pedregosa et al., 2011).

Tabela 2. Índices de Vegetação (IVs) utilizados no estudo.

IVs	Autor	Operação Aritmética
ARVI	(Kaufman & Tanre, 1992)	$\frac{\text{NIR} - \text{VERM} - (\text{A} - \text{VERM})}{\text{NIR} + \text{VERM} - (\text{A} - \text{VERM})}$
CI_{Green}	(Gitelson et al., 2003)	$\text{NIR} \div (\text{V} - 1)$
$\text{CI}_{\text{Red Edge}}$		$\text{NIR} \div (\text{RE} - 1)$
CVI	(Vincini et al., 2008)	$\text{NIR} \times (\text{VERM} \div \text{V}^2)$
DVI	(Richardson & Wiegand, 1977)	$\text{NIR} - \text{VERM} / 32767.5$
EVI	(Huete, 1997)	$\frac{2.5 \times ((\text{NIR} - \text{VERM}) \div (\text{NIR} + 6 \times \text{VERM} - 7.5 \times \text{A} + 1))}{1}$
GNDVI	(Gitelson et al., 1996)	$(\text{NIR} - \text{V}) \div (\text{NIR} + \text{V})$
GRVI	(Sripada et al., 2006)	$\text{V} - \text{VERM} / \text{V} + \text{VERM}$
IRG	(Gamon & Surfus, 1999)	$\text{VERM} - \text{V} / 32767.5$
LCI	(Datt, 1999)	$(\text{NIR} - \text{RE}) \div (\text{NIR} - \text{VERM})$
MSR	(Chen, 1996)	$\frac{(\text{NIR} \div \text{VERM} - 1) \div ((\text{NIR} \div \text{VERM})^{0.5} + 1)}{1}$
NDVI	(Rouse et al., 1974)	$(\text{NIR} - \text{VERM}) \div (\text{NIR} + \text{VERM})$
$\text{NDVI}_{\text{Red Edge}}$	(Gitelson et al., 2003)	$(\text{NIR} - \text{RE}) \div (\text{NIR} + \text{RE})$
NGRDI	(Tucker, 1979)	$(\text{V} - \text{VERM}) \div (\text{V} + \text{VERM})$
PRI	(Gamon et al., 1992)	$\text{A} - \text{V} / \text{VERM} + \text{V}$
RDVI	(Roujean & Breon, 1995)	$(\text{NIR} - \text{VERM}) \div (\text{NIR} + \text{VERM})^{0.5}$
RVI	(Jordan, 1969)	VERM / NIR
SIPI	(Peñuelas et al., 1995)	$\text{NIR} - \text{A} / \text{NIR} + \text{A}$
SR	(Birth & McVey, 1968)	NIR / VERM
$\text{SR}_{\text{Red Edge}}$	(Gitelson, 2005)	NIR / RE
TVI	(Deering et al., 1975)	$\frac{((\text{NIR} - \text{VERM}) \div (\text{NIR} + \text{VERM}))^{0.5} + 0.5}{1}$
$\text{VARI}_{\text{Green}}$	(Gitelson et al., 2002)	$(\text{V} - \text{VERM}) \div (\text{V} + \text{VERM} + \text{A})$
$\text{VARI}_{\text{Red Edge}}$		$\frac{(\text{RE} - (1.7 \times \text{VERM}) + (0.7 \times \text{A})) \div (\text{RE} + (2.3 \times \text{VERM}) + (1.3 \times \text{A}))}{1}$

Abreviações: A, Azul; V, Verde; VERM, Vermelho; RE, Red Edge e NIR, Infravermelho Próximo; ARVI, Atmospherically Resistant Vegetation Index; CI_{Green} , Chlorophyll Index; $\text{CI}_{\text{Red Edge}}$, Chlorophyll Index Red Edge; CVI, Chlorophyll Vegetation Index; DVI, Difference Vegetation Index; EVI, Enhanced Vegetation Index; GNDVI, Green Normalized Difference Vegetation Index; GRVI, Green-Red Vegetation Index; IRG, Red-Green Ratio Index; LCI, Leaf Chlorophyll Index; MSR Modified Simple Ratio; NDVI, Normalized Difference Vegetation Index; $\text{NDVI}_{\text{Red Edge}}$, Normalized Difference Red Edge; NGRDI, Normalized Red-Green Difference Index; PRI, Photochemical Reflectance Index; RDVI, Red Green Ratio Index; RVI, Ratio Vegetation Index; SIPI, Structure Insensitive Pigment Index; SR, Simple Ratio; $\text{SR}_{\text{Red Edge}}$, Red-Edge Simple Ratio; TVI, Transformed Vegetation Index; $\text{VARI}_{\text{Green}}$, Vegetation Atmospherically Resistant Index e $\text{VARI}_{\text{Red Edge}}$, Visible Atmospherically Resistant Indices Red Edge.

2.5. Modelagem

Para construção do modelo utilizou-se o algoritmo de *Random Forest* (RF), a partir da linguagem de programação Python 3.7 e a biblioteca *Scikit-Learn* (Pedregosa et al., 2011).

No 1º passo, dos 20 voos realizados para obtenção das imagens aéreas dos canteiros, 75% deles (15 voos) foram selecionados aleatoriamente para treinamento do algoritmo de Aprendizado de Máquinas. Os 25% restantes dos voos (5 voos) foram utilizados para testar o modelo treinado e assim determinar as métricas de avaliação do modelo.

No 2º passo, selecionou-se o número de *features* ideais a partir da validação cruzada (VC) nos dados de treinamento (75% dos voos) com 5-Kfolds. Em cada rodada de treinamento e VC, definiu-se um modelo de RF. Baseado neste modelo, uma *feature* foi selecionada para compor o mesmo. Foram usadas como *features*, os valores médios e o desvio padrão da média de todos os IVs utilizados no estudo, nas referidas máscaras de filtragem a partir do NDVI. O processo foi repetido com uma até 30 *features*. Após realizar esse processo nos 5-Kfolds, utilizou-se a estabilidade do Raiz Quadrada do Erro Médio (RMSE) para seleção das *features*.

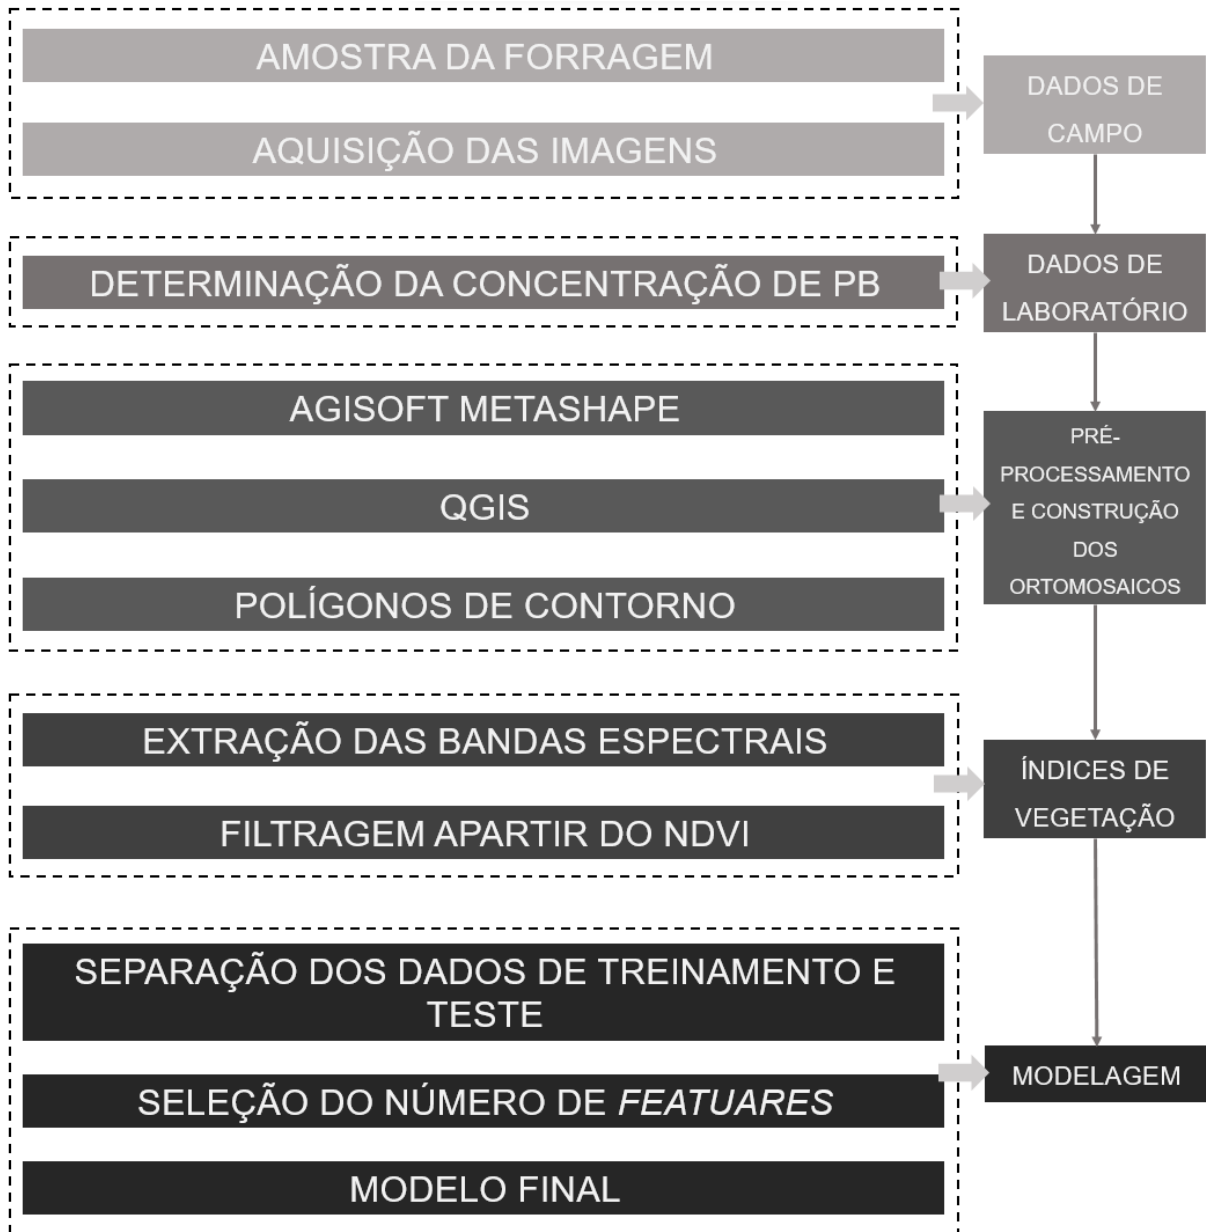
O 3º passo compreendeu a seleção das variáveis e para isso foi utilizado a importância (%) das *features* determinada pelo próprio RF. As mesmas foram ranqueadas de maneira automatizada pelo algoritmo de acordo com a influência no modelo. Com as *features* selecionadas e ranqueadas, no 4º passo, foi definido o modelo final de RF treinado com todos os dados de treinamento. No último passo, já com o modelo treinado, aplicou os dados de teste e obteve-se os valores preditos e observados da concentração de proteína bruta (PB) em % na matéria seca (MS). O Coeficiente de Determinação (R^2), RMSE e Erro Médio Absoluto (MAE) nas Equações 4, 5 e 6, respectivamente, foram utilizados para avaliar o modelo.

$$R^2 = 1 - \frac{\sum_{i=1}^n (V_{obs}^i - \hat{V}_{est})^2}{\sum_{i=1}^n (V_{obs}^i - \bar{V}_{obs})^2} \quad (4)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{V}_{est} - V_{obs}^i)^2} \quad (5)$$

$$MAE = \left(\sum_{i=1}^n [V_{obs}^i - \hat{V}_{est}^i] / n \right) \quad (6)$$

Onde n é o número de variáveis observadas, V_{obs}^i é a variável observada, \hat{V}_{est} é a predição do modelo e \bar{V}_{obs} é a média das variáveis observadas. O fluxograma de aquisição dos dados de campo até a modelagem está apresentado na Figura 5.



Abreviação: NDVI, *Normalized Difference Vegetation Index*; PB, proteína bruta.

Figura 5. Fluxograma de aquisição dos dados e modelagem.

3. RESULTADOS

3.1. Seleção do número de *features* e correlações

Foram definidas 7 *features* como classificatórias para o modelo. Esse resultado foi definido em função da Raiz do Erro Quadrático Médio (RMSE) com 2.75 de média (Figura 6).





Figura 6. Seleção do número ideal de *features*.

O *ranking* das *features* (importância em %) selecionadas para compor o modelo estão apresentadas na Figura 7. Foi selecionado como *feature* a média de todos os IVs que contribuíram para o modelo. Entre as *features* selecionadas, o valor médio do *Leaf Chlorophyll Index* (LCI) foi o mais expressivo para o modelo na máscara de filtragem NDVI > 0.60, com importância de 28.41%. O mesmo IV foi selecionado também nas máscaras de filtragem NDVI > 0.40, NDVI > 0.20 e NDVI > 0 com 16.38%, 13.58% e 9.33% de participação no modelo, respectivamente (Figura 6).

O *Ratio Vegetation Index* (RVI), na máscara de filtragem de NDVI > 0.4; participou do modelo com importância de 16.61%. Já, a média dos valores do *Photochemical Reflectance Index* (PRI) na máscara de filtragem de NDVI > 0.2 participou com 10.43% de importância (Figura 6).



Abreviações: EVI_mean_0, média dos valores do *Enhanced Vegetation Index* na máscara de filtragem de NDVI > 0; LCI_mean_0; LCI_mean_2; LCI_mean_4; LCI_mean_6, média dos valores do *Leaf Chlorophyll Index* na máscara de filtragem de NDVI > 0, NDVI > 0.2 NDVI > 0.4 e NDVI > 0.6, respectivamente; PRI_mean_2, média dos valores do *Photochemical Reflectance Index* na máscara de filtragem de NDVI > 0.2; RVI_mean_4 média dos valores do *Ratio Vegetation Index* na máscara de filtragem de NDVI > 0.4; NDVI, *Normalized Difference Vegetation Index*; Mean, média.

Figura 7. Ranking das features (%) determinado pelo *Random Forest*.

Por último, contribuindo com 5.32% para a construção do modelo, selecionou-se o *Enhanced Vegetation Index* (EVI) na máscara de filtragem de NDVI > 0 (Figura 7).

Na Figura 8, aparecem os valores encontrados para as correlações entre cada uma das sete features selecionadas. A maior correlação dos valores de PB (% MS) mensurados foi com a média do *Enhanced Vegetation* (EVI) na máscara de filtragem NDVI > 0 (0.66). As correlações foram crescentes em relação ao *Leaf Chlorophyll Index* (LCI) à medida que as máscaras de filtragem a partir do NDVI foram aumentadas. Obteve-se boa correlação (0.60) entre os valores do IV *Leaf Chlorophyll Index* (RVI). A menor correlação observada foi referente ao *Photochemical Reflectance Index* (PRI) na máscara de filtragem NDVI > 0.20 (Figura 8).

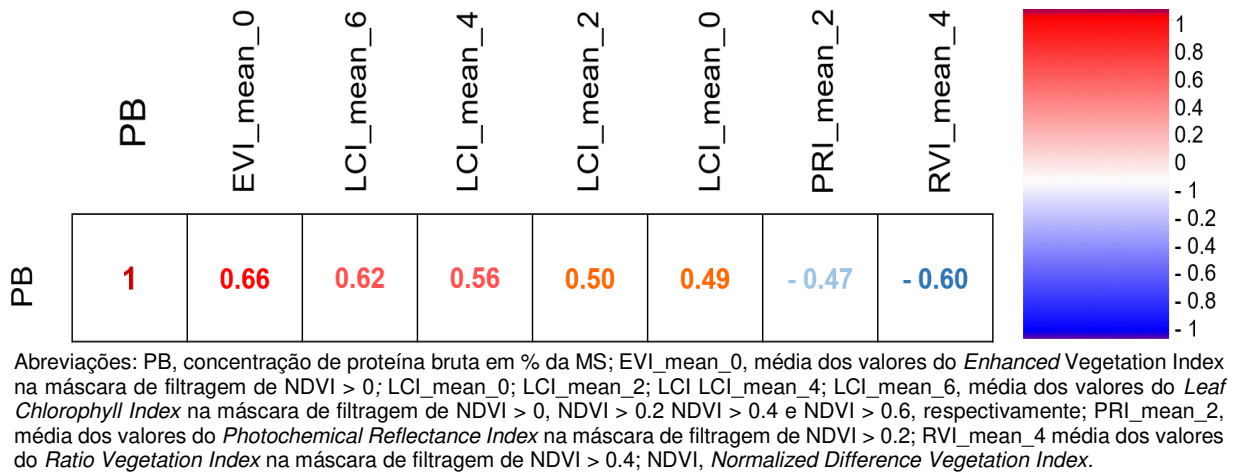
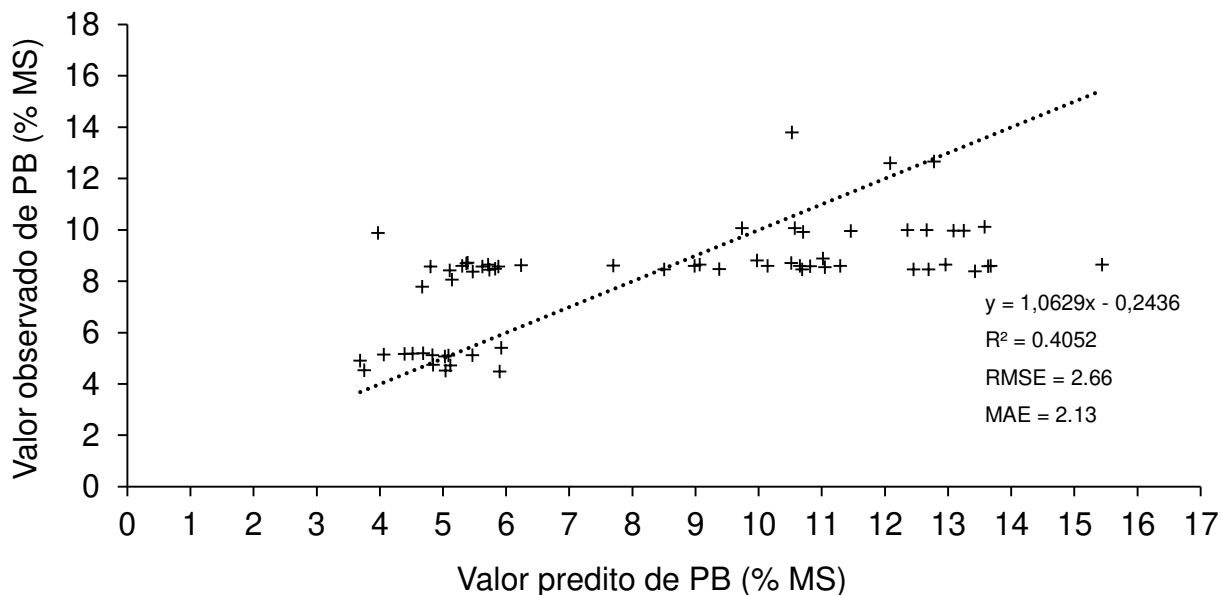


FIGURA 8. Correlações entre os valores de proteína bruta (% MS) e as *features* selecionadas para compor o modelo.

3.2. Predições

Conforme a Figura 9, 40.52% dos dados se ajustam ao modelo de regressão através dos IVs selecionados como *features* com erros de 2.13% da concentração de PB na matéria seca (MS) dos pastos de *U. decumbens*.



Abreviações: PB, proteína bruta; R^2 , Coeficiente de determinação; RMSE, Raiz Quadrada do Erro quadrado médio; MAE, Erro Médio Absoluto.

FIGURA 9. Predição da concentração de proteína bruta (PB), em % da matéria seca (% MS) com base na validação cruzada e dados de teste usando o algoritmo *Random Forest*. As métricas de predição apresentadas referem-se aos dados de teste.

4. DISCUSSÃO

Em geral, todas as bandas espectrais da câmera MicaSense RedEdge - MX® utilizadas no presente estudo mostraram-se importantes para predição da concentração de proteína bruta (PB) dos pastos de *U. decumbens* (Sin. *B. decumbens*) cv. *Basilisk* (Tabela 3). Estas foram consideradas nos IVs selecionados para participarem do modelo (Figura 7).

Apesar da grande representatividade das bandas da região do VERM e NIR, no presente estudo, o NDVI não foi selecionado para compor o modelo. Nos estudos acerca de parâmetros quantitativos e qualitativos da vegetação, o IV comumente utilizado é o *Normalized Difference Vegetation Index* (NDVI) (Quemada et al., 2014; Rouse et al., 1974), calculado utilizando-se as bandas do Vermelho (VERM) e Infravermelho Próximo (NIR) (Tabela 3).

Trabalhos como o de Caturegli et al. (2016), Rissini et al. (2015) e Xue & Su (2017) têm comprovado a relação do NDVI com as características estruturais da vegetação e concentração de nitrogênio (N). No entanto, nenhum desses estudos avaliou a precisão da predição da concentração de PB da espécie do gênero *Urochloa*. Caturegli et al. (2016), por exemplo, compararam a refletância espectral *Cynodon dactylon x transvaalensis*, *Zoysia matrella* e *Paspalum vaginatum* através da aquisição de NDVI via VANT com uma câmera digital a bordo e por GreenSkecer, instrumento terrestre. Os objetivos eram testar a sensibilidade das duas fontes de aquisição de dados na detecção da variação induzida nos níveis de N em diferentes espécies forrageiras. Os autores encontraram correlações superiores a 0.81 entre variação dos níveis de N e as diferentes fontes de aquisição do NDVI (Caturegli et al., 2016).

Nossos resultados indicam a possibilidade de exploração de outros IVs para predição da concentração de PB das plantas forrageiras, sobretudo, de *U. decumbens* (Sin. *B. decumbens*) cv. *Basilisk*. De fato, os IVs selecionados apresentam alguma relação com a concentração de N das plantas e precisam ser explorados nas culturas perenes, tais como as pastagens.

O IV que mereceu destaque foi o *Leaf Chlorophyll Index* (LCI) em todas as máscaras de filtragem do NDVI (NDVI > 0; NDVI > 0.2; NDVI > 0.4 e NDVI > 0.6). A maior correlação obtida para este IV foi mediante aplicação da máscara de filtragem de NDVI > 0.60. Isso demonstra que a participação da máscara de filtragem na

remoção de *pixels* irrelevantes foi essencial para esse IV, visto que as correlações aumentaram de acordo com o aumento da filtragem em relação ao NDVI. Este índice se relaciona fortemente com a variação na refletância causada pela absorção de clorofila (Datt, 1999). Também foram considerados no modelo o *Ratio Vegetation Index* (RVI) (Jordan, 1969). Tal IV, é obtido a partir da razão entre a banda VERM e NIR (Tabela 3).

Muitos IVs configurados para estimar o conteúdo de clorofila apresentaram melhor desempenho quando utilizam as bandas do VERM (Croft et al., 2014; Frampton et al., 2013; Gitelson, 2005). E, alguns trabalhos, demonstraram que IVs que incluem as bandas VERM, *Red Edge* (RE) e NIR possuem maiores correlações e são melhores para predizer não só massa de forragem e IAF, como também a concentração de N (Ramoelo et al., 2012; Widjaja Putra & Soni, 2017; Wu et al., 2016).

De fato, entre os IVs selecionados, apenas o *Photochemical Reflectance Index* (PRI), proposto por (Gamon et al., 1992) considera as bandas da região do Azul (A) e Verde (V) e o EVI considera a banda espectral do A. (Tabela 3). Curiosamente, a banda A não é frequentemente usada em estudos que envolvam avaliação das concentrações de N e conseqüentemente PB, em contraste com as bandas de borda VERM que estão correlacionadas com a concentração de clorofila (Clevers & Gitelson, 2013). No entanto, Cisneros et al. (2020) destacou a importância entre correlações de IVs que utilizou a banda A e concentração de N foliar de duas espécies de gramíneas forrageiras: *Megathyrsus maximum* (Sin. *Panicum maximum*) cv Mombaça e *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Marandu. Estes autores observaram que, mediante aumento da concentração de N foliar, aumentava-se a refletância da banda da região do A.

As bandas na região do visível, sobretudo a VERM, geralmente se correlacionam bem com o conteúdo de N das culturas e logo, com concentração de PB, devido à correlação com os pigmentos fotossintéticos e sua absorbância (Novo, 2010). A maior participação desses pigmentos, encontrados nos cloroplastos, corresponde à clorofila (65%), seguido pela xantofila (29%) e por último os carotenos (6%). Dentro das bandas de absorção, existem duas bandas centradas aproximadamente em 480 nm (que corresponde a região do A), possivelmente devido à presença de carotenos, e em 680 nm (região do VERM), relacionada com a concentração de clorofila. Há também um pico de refletância em torno de 550 nm,

correspondente à região V do espectro (Rosa, 2009). Isto justifica a participação dos IVs PRI e EVI no modelo.

O PRI, apesar da sua menor correlação, foi selecionado com *feature* para compor o modelo. Tal IV considera mudanças nas proporções dos pigmentos encontrados nas plantas em função do estresse hídrico (Zarco-Tejada et al., 2016). De fato, as chuvas foram menos frequentes durante os meses de outubro a março de 2020 e 2021 do que em relação aos mesmos meses no ano de 2019 e 2020 (Figura 2). Ainda, vale lembrar que os canteiros experimentais não foram irrigados.

Já o *Enhanced Vegetation Index* (EVI), apesar de também não ser o IV melhor ranqueado entre as *features* selecionadas (Figura 4), foi o melhor IV correlacionado com a concentração de PB (% MS) (Figura 5). O EVI é um IV bastante responsivo às variações estruturais do dossel, incluindo Índice de Área Foliar (IAF), tipo de dossel e arquitetura e fisionomia vegetal. O mesmo também atua na redução do efeito da saturação dos níveis de clorofila (Huete, 1997).

Considerando-se os efeitos individuais e dinâmicos do N, qualidade da luz e as interações planta-luz no crescimento da planta, somados à mobilidade do N através da planta (Bian et al., 2020; F. Wang et al., 2021; Zhou et al., 2018) pode-se considerar os valores de correlação encontrados razoáveis, mas o modelo precisa de ajustes para melhorar a predição dessa variável. Nesse estudo, as variações causadas nos canteiros experimentais foram feitas mediante rebaixamento mecânico dos mesmos. Em outros estudos, as estratégias utilizadas para gerar variação experimental, foram a dosagem de adubo nitrogenado e a irrigação das parcelas experimentais (Caturegli et al., 2016; Cisneros et al., 2020).

Assim como os valores de correlações encontrados, o ajuste do modelo ($R^2=40.52\%$) não foi satisfatório. A partir de imagens obtidas do Sentinel, Cisneros et al. (2020), avaliaram alguns parâmetros biofísicos de *Megathyrus maximum* (Sin. *Panicum maximum*) cv Mombaça e *Urochloa decumbens* (Sin. *Brachiaria decumbens*) cv. Marandu, tais como produtividade de biomassa, a concentração de nitrogênio foliar (FNC), altura da planta e o Índice de Área Foliar (IAF). Esses parâmetros foram correlacionados com os IVs *Three Ratio Band Index* (TBI), *Difference light Height* (DLH), *Three Band Dall'Olmo* (DO), *Normalized Area Over reflectance Curve* (NAOC) e NDVI. No entanto, os autores também encontraram valores medianos a baixos de R^2 . Para o parâmetro FNC, a melhor correlação encontrada foi para o índice TBI com

R^2 de 0.38 e RMSE de 3.4 g kg^{-1} de N foliar. Os autores não consideram a validação dos dados.

Salienta-se que, a entrada de mais dados de referência que não foram contabilizados para criação do modelo de predição, tais como dados climáticos, tipo de solo, efeito do pastejo realizado pelos animais, adubação, parâmetros estruturais entre outros, podem auxiliar na criação de modelos dinâmicos capazes de prever com maior precisão esta variável. Estudos recentes de Chen et al. (2021) e Bretas et al. (2021), por exemplo, demonstraram a importância da inclusão de dados meteorológicos, principalmente temperatura e precipitação para a criação de modelos acerca das áreas de pastagens.

Deve-se considerar também, que as imagens aéreas capturam informações do estrato superior do dossel. Porém, a estrutura do pasto, ou seja, a distribuição geométrica tridimensional dos componentes da vegetação (Laca & Lemaire, 2000) é descrita por características da planta com Índice de Área Foliar (IAF), biomassa acima do solo (AGB), e outras características estruturais do dossel e da folha (Gianelle & Vescovo, 2007; Müller-Linow et al., 2015; Serrano et al., 2000). Estas características, somadas a fatores básicos como o crescimento da forragem, pastejo, adubação, precipitação e radiação solar, podem influenciar a dinâmica de absorção e dispersão da luz (Ollinger, 2011; Roelofsen et al., 2014).

Sendo assim, métodos baseados em VANT, onde um gimbal é usado para segurar um espectrômetro em diferentes ângulos de visão, podem fornecer uma boa cobertura angular de uma área de interesse (Burkart et al., 2015; Grenzdörffer & Niemeyer, 2012). Dessa forma, as observações multiangulares também podem ser uma opção de fonte de informação adicional como tentativa de melhorar a predição de parâmetros da vegetação (Roosjen et al., 2018).

5. CONCLUSÃO

O uso de imagens multiespectrais obtidas por VANT e técnica de Aprendizado de Máquina no presente estudo apontou que 40.52% dos dados se ajustaram ao modelo de regressão através dos Índices de Vegetação selecionados como *features* com erros de 2.13% na concentração de PB na matéria seca dos pastos de *U. decumbens*.

A estimativa da concentração de proteína bruta de pastos de forma remota é complexa devido à alta variabilidade sazonal e espacial desta variável nas plantas. Assim, esforços devem ser direcionados a fim de aumentar o ajuste no modelo e reduzir os erros na predição desta variável. Por fim, outras técnicas de análises de dados para predição de PB devem ser avaliadas, assim como outras variáveis no modelo como dados meteorológicos e bandas espectrais, o que pode auxiliar no desenvolvimento de modelos capazes de predizer com maior precisão e acurácia esta variável.

REFERÊNCIAS

- Agisoft (2019). Agisoft Metashape Professional. Retrieved from: www.agisoft.ru
- Alvares, C. A., Stape, J. L., Sentelhas, P. C., de Moraes Gonçalves, J. L., & Sparovek, G. (2013). Köppen's climate classification map for Brazil. *Meteorologische Zeitschrift*, *22*(6), 711–728. <https://doi.org/10.1127/0941-2948/2013/0507>
- Batistoti, J., Marcato Junior, J., Ítavo, L., Matsubara, E., Gomes, E., Oliveira, B., Souza, M., Siqueira, H., Salgado Filho, G., Akiyama, T., Gonçalves, W., Liesenberg, V., Li, J., & Dias, A. (2019). Estimating Pasture Biomass and Canopy Height in Brazilian Savanna Using UAV Photogrammetry. *Remote Sensing*, *11*(20), 2447. <https://doi.org/10.3390/rs11202447>
- Bendig, J., Bolten, A., Bennertz, S., Broscheit, J., Eichfuss, S., & Bareth, G. (2014). Estimating Biomass of Barley Using Crop Surface Models (CSMs) Derived from UAV-Based RGB Imaging. *Remote Sensing*, *6*(11), 10395–10412. <https://doi.org/10.3390/rs61110395>
- Bian, Z., Wang, Y., Zhang, X., Li, T., Grundy, S., Yang, Q., & Cheng, R. (2020). A Review of Environment Effects on Nitrate Accumulation in Leafy Vegetables Grown in Controlled Environments. *Foods*, *9*(6), 732. <https://doi.org/10.3390/foods9060732>
- Birth, G. S., & McVey, G. R. (1968). Measuring the Color of Growing Turf with a Reflectance Spectrophotometer¹. *Agronomy Journal*, *60*(6), 640–643. <https://doi.org/10.2134/agronj1968.00021962006000060016x>

- Borra-Serrano, I., De Swaef, T., Muylle, H., Nuyttens, D., Vangeyte, J., Mertens, K., Saeys, W., Somers, B., Roldán-Ruiz, I., & Lootens, P. (2019). Canopy height measurements and non-destructive biomass estimation of *Lolium perenne* swards using UAV imagery. *Grass and Forage Science*, gfs.12439. <https://doi.org/10.1111/gfs.12439>
- Bretas, I. L., Valente, D. S. M., De Oliveira, T. F., Montagner, D. B., Euclides, V. P. B., & Chizzotti, F. H. M. (2023). Canopy height and biomass prediction in Mombaça guinea grass pastures using satellite imagery and machine learning. *Precision Agriculture*. <https://doi.org/10.1007/s11119-023-10013-z>
- Bretas, I. L., Valente, D. S. M., Silva, F. F., Chizzotti, M. L., Paulino, M. F., D'Áurea, A. P., Paciullo, D. S. C., Pedreira, B. C., & Chizzotti, F. H. M. (2021). Prediction of aboveground biomass and dry-matter content in *Brachiaria* pastures by combining meteorological data and satellite imagery. *Grass and Forage Science*, 76(3), 340–352. <https://doi.org/10.1111/gfs.12517>
- Burkart, A., Aasen, H., Alonso, L., Menz, G., Bareth, G., & Rascher, U. (2015). Angular Dependency of Hyperspectral Measurements over Wheat Characterized by a Novel UAV Based Goniometer. *Remote Sensing*, 7(1), 725–746. <https://doi.org/10.3390/rs70100725>
- Castro, W., Marcato Junior, J., Polidoro, C., Osco, L. P., Gonçalves, W., Rodrigues, L., Santos, M., Jank, L., Barrios, S., Valle, C., Simeão, R., Carromeu, C., Silveira, E., Jorge, L. A. de C., & Matsubara, E. (2020). Deep Learning Applied to Phenotyping of Biomass in Forages with UAV-Based RGB Imagery. *Sensors*, 20(17), 4802. <https://doi.org/10.3390/s20174802>

- Caturegli, L., Corniglia, M., Gaetani, M., Grossi, N., Magni, S., Migliazzi, M., Angelini, L., Mazzoncini, M., Silvestri, N., Fontanelli, M., Raffaelli, M., Peruzzi, A., & Volterrani, M. (2016). Unmanned Aerial Vehicle to Estimate Nitrogen Status of Turfgrasses. *PLOS ONE*, *11*(6), e0158268. <https://doi.org/10.1371/journal.pone.0158268>
- Chen, J. M. (1996). Evaluation of Vegetation Indices and a Modified Simple Ratio for Boreal Applications. *Canadian Journal of Remote Sensing*, *22*(3), 229–242. <https://doi.org/10.1080/07038992.1996.10855178>
- Chen, Y., Huang, X., Huang, J., Liu, S., Lu, D., & Zhao, S. (2021). Fractional monitoring of desert vegetation degradation, recovery, and greening using optimized multi-endmembers spectral mixture analysis in a dryland basin of Northwest China. *GIScience & Remote Sensing*, *58*(2), 300–321. <https://doi.org/10.1080/15481603.2021.1883940>
- Cisneros, A., Fiorio, P., Menezes, P., Pasqualotto, N., Van Wittenberghe, S., Bayma, G., & Furlan Nogueira, S. (2020). Mapping Productivity and Essential Biophysical Parameters of Cultivated Tropical Grasslands from Sentinel-2 Imagery. *Agronomy*, *10*(5), 711. <https://doi.org/10.3390/agronomy10050711>
- Clevers, J. G. P. W., & Gitelson, A. A. (2013). Remote estimation of crop and grass chlorophyll and nitrogen content using red-edge bands on Sentinel-2 and -3. *International Journal of Applied Earth Observation and Geoinformation*, *23*, 344–351. <https://doi.org/10.1016/j.jag.2012.10.008>
- Clifton, K. E., Bradbury, J. W., & Vehrencamp, S. L. (1994). The fine-scale mapping of grassland protein densities. *Grass and Forage Science*, *49*(1), 1–8. <https://doi.org/10.1111/j.1365-2494.1994.tb01970.x>

- Croft, H., Chen, J. M., & Noland, T. L. (2014). Stand age effects on Boreal forest physiology using a long time-series of satellite data. *Forest Ecology and Management*, *328*, 202–208. <https://doi.org/10.1016/j.foreco.2014.05.023>
- da Silva, S., Sbrissia, A., & Pereira, L. (2015). Ecophysiology of C4 Forage Grasses—Understanding Plant Growth for Optimising Their Use and Management. *Agriculture*, *5*(3), 598–625. <https://doi.org/10.3390/agriculture5030598>
- Datt, B. (1999). A New Reflectance Index for Remote Sensing of Chlorophyll Content in Higher Plants: Tests using Eucalyptus Leaves. *Journal of Plant Physiology*, *154*(1), 30–36. [https://doi.org/10.1016/S0176-1617\(99\)80314-9](https://doi.org/10.1016/S0176-1617(99)80314-9)
- Deering, D. W.; Rouse, J. W.; Haas, R. H.; Schell, J. A. Measuring “forage production” of grazing units from Landsat MSS data. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 10., Ann Arbor. **Proceedings...** Ann Arbor, MI: ERIM, 1975. v.2, p.1169-1178.
- Detmann, E., Souza, M.A., Valadares Filho, S.C., Queiroz, A.C., Berchielli, T.T., Saliba, E.O.S., Cabral, L.S., Pina, D.S., Ladeira, M.M., & Azevedo, J.A.G. (2012). Methods for food analysis. Visconde do Rio Branco, MG: Suprema, 214p.
- Dubeux, J. C. B., Sollenberger, L. E., Mathews, B. W., Scholberg, J. M., & Santos, H. Q. (2007). Nutrient Cycling in Warm-Climate Grasslands. *Crop Science*, *47*(3), 915–928. <https://doi.org/10.2135/cropsci2006.09.0581>
- Frampton, W. J., Dash, J., Watmough, G., & Milton, E. J. (2013). Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. *ISPRS Journal of Photogrammetry and Remote Sensing*, *82*, 83–92. <https://doi.org/10.1016/j.isprsjprs.2013.04.007>

- FAOSTAT (2016) Banco de dados de emissões FAOSTAT. <http://faostat3.fao.org>. Acessado em 5 de abril de 2022
- Frampton, W. J., Dash, J., Watmough, G., & Milton, E. J. (2013). Evaluating the capabilities of Sentinel-2 for quantitative estimation of biophysical variables in vegetation. *ISPRS Journal of Photogrammetry and Remote Sensing*, *82*, 83–92. <https://doi.org/10.1016/j.isprsjprs.2013.04.007>
- Gamon, J. A., Peñuelas, J., & Field, C. B. (1992). A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. *Remote Sensing of Environment*, *41*(1), 35–44. [https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/10.1016/0034-4257(92)90059-S)
- Gamon, J. A., & Surfus, J. S. (1999). Assessing leaf pigment content and activity with a reflectometer. *New Phytologist*, *143*(1), 105–117. <https://doi.org/10.1046/j.1469-8137.1999.00424.x>
- Gianelle, D., & Vescovo, L. (2007). Determination of green herbage ratio in grasslands using spectral reflectance. Methods and ground measurements. *International Journal of Remote Sensing*, *28*(5), 931–942. <https://doi.org/10.1080/01431160500196398>
- Gitelson, A. A. (2005). Remote estimation of canopy chlorophyll content in crops. *Geophysical Research Letters*, *32*(8), L08403. <https://doi.org/10.1029/2005GL022688>
- Gitelson, A. A., Gritz †, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, *160*(3), 271–282. <https://doi.org/10.1078/0176-1617-00887>

- Gitelson, A. A., Kaufman, Y. J., & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sensing of Environment*, *58*(3), 289–298. [https://doi.org/10.1016/S0034-4257\(96\)00072-7](https://doi.org/10.1016/S0034-4257(96)00072-7)
- Gitelson, A. A., Zur, Y., Chivkunova, O. B., & Merzlyak, M. N. (2002). Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. *Photochemistry and Photobiology*, *75*(3), 272. [https://doi.org/10.1562/0031-8655\(2002\)075<0272:ACCIPL>2.0.CO;2](https://doi.org/10.1562/0031-8655(2002)075<0272:ACCIPL>2.0.CO;2)
- Grenzdörffer, G. J., & Niemeyer, F. (2012). UAV BASED BRDF-MEASUREMENTS OF AGRICULTURAL SURFACES WITH PFIFFIKUS. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, *XXXVIII-1/C22*, 229–234. <https://doi.org/10.5194/isprsarchives-XXXVIII-1-C22-229-2011>
- Hamid Muhammed, H., & Larsolle, A. (2003). Feature Vector Based Analysis of Hyperspectral Crop Reflectance Data for Discrimination and Quantification of Fungal Disease Severity in Wheat. *Biosystems Engineering*, *86*(2), 125–134. [https://doi.org/10.1016/S1537-5110\(03\)00090-4](https://doi.org/10.1016/S1537-5110(03)00090-4)
- Huete, A. (1997). A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment*, *59*(3), 440–451. [https://doi.org/10.1016/S0034-4257\(96\)00112-5](https://doi.org/10.1016/S0034-4257(96)00112-5)
- Instituto Brasileiro de Geografia e Estatística (IBGE). (2017). Censo Agropecuário. Retrieved from: <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=73096> (accessed on 27 May 2020)

- Insua, J. R., Utsumi, S. A., & Basso, B. (2019). 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*, *14*(3), e0212773. <https://doi.org/10.1371/journal.pone.0212773>
- Jensen J.R. (2009) - Remote Sensing of the Environment: An Earth Resource Perspective. 2nd Eds. Pearson Education.
- Jordan, C. F. (1969). Derivation of Leaf-Area Index from Quality of Light on the Forest Floor. *Ecology*, *50*(4), 663–666. <https://doi.org/10.2307/1936256>
- Kaufman, Y. J., & Tanre, D. (1992). Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, *30*(2), 261–270. <https://doi.org/10.1109/36.134076>
- Laca, E. A., & Lemaire, G. (2000). Measuring sward structure. Em L.'T Mannelje & R. M. Jones (Orgs.), *Field and laboratory methods for grassland and animal production research* (1^o ed, p. 103–121). CABI Publishing. <https://doi.org/10.1079/9780851993515.0103>
- Li, S., Jiao, J., & Wang, C. (2021). Research on Polarized Multi-Spectral System and Fusion Algorithm for Remote Sensing of Vegetation Status at Night. *Remote Sensing*, *13*(17), 3510. <https://doi.org/10.3390/rs13173510>
- Lussem, U., Bolten, A., Menne, J., Gnyp, M. L., Schellberg, J., & Bareth, G. (2019). Estimating biomass in temperate grassland with high resolution canopy surface models from UAV-based RGB images and vegetation indices. *Journal of Applied Remote Sensing*, *13*(03), 1. <https://doi.org/10.1117/1.JRS.13.034525>

- Ma, Q., Chai, L., Hou, F., Chang, S., Ma, Y., Tsunekawa, A., & Cheng, Y. (2019). Quantifying Grazing Intensity Using Remote Sensing in Alpine Meadows on Qinghai-Tibetan Plateau. *Sustainability*, 11(2), 417. <https://doi.org/10.3390/su11020417>
- Maes, W., Huete, A., & Steppe, K. (2017). Optimizing the Processing of UAV-Based Thermal Imagery. *Remote Sensing*, 9(5), 476. <https://doi.org/10.3390/rs9050476>
- Maresma, Á., Ariza, M., Martínez, E., Lloveras, J., & Martínez-Casasnovas, J. (2016). Analysis of Vegetation Indices to Determine Nitrogen Application and Yield Prediction in Maize (*Zea mays* L.) from a Standard UAV Service. *Remote Sensing*, 8(12), 973. <https://doi.org/10.3390/rs8120973>
- Morota, G., Ventura, R. V., Silva, F. F., Koyama, M., & Fernando, S. C. (2018). BIG DATA ANALYTICS AND PRECISION ANIMAL AGRICULTURE SYMPOSIUM: Machine learning and data mining advance predictive big data analysis in precision animal agriculture1. *Journal of Animal Science*, 96(4), 1540–1550. <https://doi.org/10.1093/jas/sky014>
- Müller-Linow, M., Pinto-Espinosa, F., Scharr, H., & Rascher, U. (2015). The leaf angle distribution of natural plant populations: Assessing the canopy with a novel software tool. *Plant Methods*, 11(1), 11. <https://doi.org/10.1186/s13007-015-0052-z>
- Murphy, D. J., Murphy, M. D., O'Brien, B., & O'Donovan, M. (2021). A Review of Precision Technologies for Optimising Pasture Measurement on Irish Grassland. *Agriculture*, 11(7), 600. <https://doi.org/10.3390/agriculture11070600>
- Norton, B.W. (1982). Differences between species in forage quality.

- Novo, E.M.L. Sensoriamento Remoto: Principios e Aplicações, 4th ed.; Blücher, E., Ed.; Blusher: São Paulo, Brazil, 2010; ISBN 9788521205401. 50.
- Ollinger, S. V. (2011). Sources of variability in canopy reflectance and the convergent properties of plants. *New Phytologist*, 189(2), 375–394. <https://doi.org/10.1111/j.1469-8137.2010.03536.x>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., Duchesnay, E. (2011). Scikit-Learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Peñuelas, J.; Baret, F.; Filella, I. 1995. Semi-empirical indices to assess carotenoids: chlorophyll a ratio from leaf spectral reflectance. *Photosynthetica* 31: 221-230.
- Prins, H. H. T., & Beekman, J. H. (1989). A balanced diet as a goal for grazing: The food of the Manyara buffalo. *African Journal of Ecology*, 27(3), 241–259. <https://doi.org/10.1111/j.1365-2028.1989.tb01017.x>
- Prins, H. H. T., & Van Langevelde, F. (2008). Assembling a diet from different places. In H. H. T. Prins & F. Van Langevelde (Orgs.), *Resource Ecology* (p. 129–155). Springer Netherlands. https://doi.org/10.1007/978-1-4020-6850-8_12
- QGIS Development Team (2019). QGIS Geographic Information System. Version 3.2. Open Source Geospatial Foundation Project. Retrieved from: <http://qgis.osgeo.org>.
- Quemada, M., Gabriel, J., & Zarco-Tejada, P. (2014). Airborne Hyperspectral Images and Ground-Level Optical Sensors As Assessment Tools for Maize Nitrogen Fertilization. *Remote Sensing*, 6(4), 2940–2962. <https://doi.org/10.3390/rs6042940>

- Reinermann, S., Asam, S., & Kuenzer, C. (2020). Remote Sensing of Grassland Production and Management—A Review. *Remote Sensing*, 12(12), 1949. <https://doi.org/10.3390/rs12121949>
- Richardson, A. J., Wiegand, C. L. (1977). Distinguishing vegetation from soil background information. *Photogrammetric Engineering & Remote Sensing*, 43(12), 1541-1552.
- Rissini, A. L. L., Kawakami, J., & Genú, A. M. (2015). Índice de vegetação por diferença normalizada e produtividade de cultivares de trigo submetidas a doses de nitrogênio. *Revista Brasileira de Ciência do Solo*, 39(6), 1703–1713. <https://doi.org/10.1590/01000683rbcs20140686>
- Roelofsen, H. D., Bodegom, P. M., Kooistra, L., & Witte, J. M. (2014). Predicting leaf traits of herbaceous species from their spectral characteristics. *Ecology and Evolution*, 4(6), 706–719. <https://doi.org/10.1002/ece3.932>
- Rosa, R. Introdução ao Sensoriamento Remoto, 7th ed.; EDUFU, Ed.; EDUFU: Uberlândia, Brazil, 2009; ISBN 9788570781246.
- Roujean, J.-L., & Breon, F.-M. (1995). Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3), 375–384. [https://doi.org/10.1016/0034-4257\(94\)00114-3](https://doi.org/10.1016/0034-4257(94)00114-3)
- Rouse, W. J., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the great plains with ERTS. Retrieved from [https://ntrs.nasa.gov/search.jsp?R=1974 0 0 2 2614](https://ntrs.nasa.gov/search.jsp?R=1974%20022614)
- Santos, H. G. dos. (2018). *Sistema brasileiro de classificação de solos (5ª edição revista e ampliada)*. Embrapa.

- Serrano, L., Gamon, J. A., & Peñuelas, J. (2000). ESTIMATION OF CANOPY PHOTOSYNTHETIC AND NONPHOTOSYNTHETIC COMPONENTS FROM SPECTRAL TRANSMITTANCE. *Ecology*, 81(11), 3149–3162. [https://doi.org/10.1890/0012-9658\(2000\)081\[3149:EOCPAN\]2.0.CO;2](https://doi.org/10.1890/0012-9658(2000)081[3149:EOCPAN]2.0.CO;2)
- Sripada, R. P., Heiniger, R. W., White, J. G., & Meijer, A. D. (2006). Aerial Color Infrared Photography for Determining Early In-Season Nitrogen Requirements in Corn. *Agronomy Journal*, 98(4), 968–977. <https://doi.org/10.2134/agronj2005.0200>
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8(2), 127–150. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- Vincini, M., Frazzi, E., & D'Alessio, P. (2008). A broad-band leaf chlorophyll vegetation index at the canopy scale. *Precision Agriculture*, 9(5), 303–319. <https://doi.org/10.1007/s11119-008-9075-z>
- Wang, F., Yi, Q., Hu, J., Xie, L., Yao, X., Xu, T., & Zheng, J. (2021). Combining spectral and textural information in UAV hyperspectral images to estimate rice grain yield. *International Journal of Applied Earth Observation and Geoinformation*, 102, 102397. <https://doi.org/10.1016/j.jag.2021.102397>
- Wang, Z. J., Wang, J. H., Liu, L. Y., Huang, W. J., Zhao, C. J., & Wang, C. Z. (2004). Prediction of grain protein content in winter wheat (*Triticum aestivum* L.) using plant pigment ratio (PPR). *Field Crops Research*, 90(2–3), 311–321. <https://doi.org/10.1016/j.fcr.2004.04.004>

- Widjaja Putra, B. T., & Soni, P. (2017). Evaluating NIR-Red and NIR-Red edge external filters with digital cameras for assessing vegetation indices under different illumination. *Infrared Physics & Technology*, *81*, 148–156. <https://doi.org/10.1016/j.infrared.2017.01.007>
- Wijesingha, J., Astor, T., Schulze-Brüninghoff, D., Wengert, M., & Wachendorf, M. (2020). Predicting Forage Quality of Grasslands Using UAV-Borne Imaging Spectroscopy. *Remote Sensing*, *12*(1), 126. <https://doi.org/10.3390/rs12010126>
- Wu, Q., Wang, J., Wang, C., & Xu, T. (2016). Study on the optimal algorithm prediction of corn leaf component information based on hyperspectral imaging. *Infrared Physics & Technology*, *78*, 66–71. <https://doi.org/10.1016/j.infrared.2016.07.011>
- Xue, J., & Su, B. (2017). Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. *Journal of Sensors*, *2017*, 1–17. <https://doi.org/10.1155/2017/1353691>
- Zarco-Tejada, P. J., González-Dugo, M. V., & Fereres, E. (2016). Seasonal stability of chlorophyll fluorescence quantified from airborne hyperspectral imagery as an indicator of net photosynthesis in the context of precision agriculture. *Remote Sensing of Environment*, *179*, 89–103. <https://doi.org/10.1016/j.rse.2016.03.024>
- Zhou, W., Chen, Y., Xu, H., Liang, X., Hu, Y., Jin, C., Lu, L., & Lin, X. (2018). Short-Term Nitrate Limitation Prior to Harvest Improves Phenolic Compound Accumulation in Hydroponic-Cultivated Lettuce (*Lactuca sativa* L.) without Reducing Shoot Fresh Weight. *Journal of Agricultural and Food Chemistry*, *66*(40), 10353–10361. <https://doi.org/10.1021/acs.jafc.8b02157>