

AUREANA MATOS LISBOA

**SENSORIAMENTO REMOTO NA AVALIAÇÃO DE PASTO DE
*Brachiaria decumbens***

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

Orientadora: Fernanda H. Martins Chizzotti

**VIÇOSA - MINAS GERAIS
2020**

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

T

L769v
2020
Lisboa, Aureana Matos, 1991-
Sensoriamento remoto na avaliação de pastos de capim-braquiária
/ Aureana Matos Lisboa. - Viçosa, MG, 2020.
59 f. : il. (algumas color.) ; 29 cm.

Orientador: Fernanda Helena Martins Chizzotti.
Dissertação (mestrado) - Universidade Federal de Viçosa.
Referências bibliográficas: f. 53-59.

1. Pastagens. 2. Vegetação - Mapeamento. 3. Sensoriamento
remoto. 4. Planejamento. I. Universidade Federal de Viçosa.
Departamento de Zootecnia. Programa de Pós-Graduação em
Zootecnia. II. Título.

CDD 22. ed. 633.202

AUREANA MATOS LISBOA


**SENSORIAMENTO REMOTO NA AVALIAÇÃO DE PASTO DE
*Brachiaria decumbens***

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

APROVADA: 10 de julho de 2020.

Assentimento:


Aureana Matos Lisboa
Autora


Fernanda H. Martins Chizzotti
Orientadora

A Deus pai celestial.

*A minha maravilhosa mãe por todo o amor,
carinho e apoio.*

*A meu irmão guerreiro e exemplo
profissional.*

*A meu saudoso e amado pai, por tudo que
me ensinou e o tanto que me cuidou até
aqui.*

*A minha tia avó (no coração) Elzenir, minha
grande amiga e incentivadora.*

AGRADECIMENTOS

A Deus, por me guiar, fortalecer e amparar em todos os meus passos e decisões durante este período. Sem Ele nada do que descreverei abaixo seria possível.

A minha mãe guerreira, que mesmo longe durante esse processo se fez presente com ligações diárias, orações e suporte emocional incondicional. A meu irmão que também de longe me ouviu e me apoiou. Agradeço também a meu pai herói, já não presente, mas que me deu a base para estar onde estou. A todos da minha família, que me incentivaram a essa escolha, que acompanharam meus passos, principalmente a minha tia avó que me deu abrigo, amor e carinho no início disso e hoje descansa em paz, Elzenir.

A todos os amigos que se envolveram direta e indiretamente nessa etapa, em especial Daiana Lopes Lelis, Marina Lima e Priscila Valote.

A Caio Henrique, que tanto me apoiou, segurou minha mão e me fortaleceu, “mil milhões” de vezes obrigada, você foi parte fundamental dessa fase.

Aos melhores estagiários, Bruno Fontes, Jetro Fernandes, Filipe Bueno, Lara Moura e Luciano Moreira, sem vocês não seria possível o andamento do projeto.

A minha orientadora Dr^a. Fernanda H. M. Chizzotti, por todo o auxílio no desenvolvimento do projeto. Assim como o Prof. Dr. Francisco de Assis de Carvalho Pinto que, junto com seu aluno Ms. Jorge Tadeu tornou possível a utilização de todos os aparelhos de Sensoriamento Remoto.

Aos funcionários do setor de Agrostologia, Sr. Divino e Vilmar, que tanto me auxiliaram durante todos os meses que estivemos juntos. Assim como o funcionário Edson, do departamento de Zootecnia, que se fez muito presente, principalmente na construção da área experimental.

Não podendo esquecer o Prof. Dr. Dilermando Fonseca, por ceder a área experimental, assim como me dar suporte durante o andamento do projeto.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO

LISBOA, Aureana Matos, M.Sc., Universidade Federal de Viçosa, julho de 2020.
Sensoriamento remoto na avaliação de pasto de *Brachiaria decumbens*.
Orientadora: Fernanda Helena Martins Chizzotti.

A Zootecnia de Precisão tem sido amplamente utilizada para gerar informações no campo, assim como auxiliar na tomada de decisão em diversas áreas, inclusive no manejo das pastagens. Neste contexto, um dos maiores entraves do pecuarista para gestão adequada da produção animal baseada em pastagens é determinar a quantidade e o valor nutritivo da forragem ofertada aos animais. Geralmente, essas informações são geradas por meio de amostragem e secagem da forragem, seguida de análises laboratoriais, sendo trabalhoso e oneroso para o produtor. Assim, foi proposto este experimento com os objetivos de determinar e testar possíveis correlações entre os Índices de Vegetação (IVs) gerados a partir de imagens aéreas multiespectrais e de Sensores Proximais, com as variáveis massa de forragem (MF), altura (ALT) e proteína bruta (PB) do capim-braquiária. Para gerar variação estrutural e química no capim-braquiária foram aplicadas 5 doses de nitrogênio (0; 50; 100; 150 e 200 kg ha⁻¹) após cada colheita de forragens nas parcelas. O delineamento utilizado foi em blocos ao acaso com 5 repetições, totalizando 25 parcelas de 12 m² cada. Foram realizados quatro voos com o VANT Matrice 100 DJI, com a câmera multiespectral *MicaSense RedEdge* a bordo, a cada 21 dias, no período de setembro a dezembro de 2019. Antecedendo cada voo, foram realizadas em cada parcela, aferições da ALT do capim-braquiária, bem como quantificação da clorofila via SPAD e NDVI (*Normalized Difference Vegetation Index*) com o sensor GreenSeeker. Após cada voo, amostras foram colhidas em cada parcela para quantificar a MF e o teor de PB da planta. As imagens obtidas foram calibradas utilizando o *software Agisoft Photoscan* e processadas para determinação dos IVs no *software QGIS 3.2*. Foram calculados os seguintes índices: NDVI, NDRE (*Red Edge Normalized Difference Vegetation Index*), GNDVI (*Green Normalized Difference Vegetation Index*), SR_{Red Edge} (*Red Edge Simple Ratio*), SR (*Simple Ratio*), CI_{Green} (*Green Chlorophyll Index*), CI_{Red Edge} (*Red Edge Chlorophyll Index*) e MTCI (*MERIS Terrestrial Chlorophyll Index*). Todos os IVs gerados foram correlacionados com as variáveis: MF, PB (% MS), e ALT pelo Teste *t-student*, a 5% de significância. Em geral, foram observadas fortes

correlações entre IVs e variáveis determinadas no capim-braquiária. Os resultados sugerem potencial de utilização do Sensoriamento Remoto utilizando câmeras multiespectrais, bem como do sensor GreenSeeker em modelos de predição da massa de forragem, altura e teor de PB de pastos de *B. decumbens* (*syn. U. decumbens*). Índices que utilizam a banda espectral *Red Edge* em substituição a banda do vermelho visível possuem melhor correlação com MF e teor de PB e podem melhorar o desempenho preditivo das variáveis de interesse, embora mais pesquisas sejam necessárias para escolha do melhor índice a ser utilizado, bem como desenvolvimento de modelos de predição acurados para pastagens tropicais.

Palavras-chave: Índices de Vegetação. Sensoriamento remoto. Biomassa. VANT. Nitrogênio.

ABSTRACT

LISBOA, Aureana Matos, M.Sc., Universidade Federal de Viçosa, July, 2020. **Remote Sensing in the assessment of *Brachiaria decumbens***. Adviser: Fernanda Helena Martins Chizzotti.

Precision livestock has been widely used to generate accurate information in the field, as well as assist in decision-making in several areas, including pasture management. In this context, one of the biggest obstacles of the cattle rancher for the adequate management of animal production based on pastures is to determine the quantity and the nutritional value of the forage offered to the animals. Generally, this information is generated by the cutting and drying of the forage followed by laboratory analysis, a laborious and costly process. Thus, an experiment was carried out with the objectives of determining and testing possible correlations between vegetation indices (IVs) generated from multispectral aerial images and Proximal Sensors, with the forage mass (FM), canopy height (CH), and crude protein content (CP) of signalgrass. To generate structural and chemical variation in the signalgrass, 5 nitrogen doses (0; 50; 100; 150 and 200 kg ha⁻¹) were applied after each cut. The design used was in randomized blocks with 5 replications, totaling 25 plots of 12 m² each. Four flights were performed with the UAV Matrice 100 DJI, with the MicaSense RedEdge multispectral camera on board, every 21 days from September to December 2019. In advance of each flight, IAF, IL and canopy height measurements were performed at each plot, as well as quantification of the chlorophyll SPAD and NDVI (Normalized Difference Vegetation Index) with the GreenSeeker sensor. After each flight, samples were taken from each plot to quantify the forage mass and the protein content of the plant. The images obtained were calibrated using the Agisoft PhotoScan software and processed to determine the IVs using the QGIS 3.2 software. The following indices were calculated: NDVI, NDRE (Normalized Difference Red Edge), GNDVI (Green Normalized Difference Vegetation Index), SR_{Red Edge} (Red Edge Simple Ratio), SR (Simple Ratio), CI_{Green} (Green Chlorophyll Index), CI_{Red Edge} (Red Edge Chlorophyll Index) and MTCI (MERIS Terrestrial Chlorophyll Index). All the IVs generated were correlated with the variables (MF, PB [% MS], and canopy height through the t-student test) at a 5% significance level. In general, strong correlations were observed between IVs and pasture variables. The results suggest potential use of aerophotogrammetry

using multispectral cameras and the Proximal Sensors in prediction models of forage mass, CH and CP of *B. decumbens* (syn. *U. decumbens*) pastures. Indices that use the Red-Edge spectral band to replace the visible red band have a better correlation with FM and CP content and can improve the predictive performance of the variables of interest, although more research is needed to choose the best index to be used, as well as to spur development of accurate prediction models for tropical pastures.

Keywords: Vegetation Index. Remote Sensing. Biomass. UAV. Nitrogen.

LISTA DE ILUSTRAÇÕES

Figura 1 - Comparação entre imagens obtidas via Satélite (A) e a partir de VANT (B)	19
Figura 2 - Aeronave com asas fixas, eBee, desenvolvido pela empresa SenseFly (A) e com asas rotativas, Matrice 100 DJI, desenvolvido pela empresa DJI (B).....	20
Figura 3 - Resposta espectral das plantas	22
Figura 4 - Dados de temperatura e precipitação durante o período experimental.....	27
Figura 5 - Croqui da área experimental.....	28
Figura 6 - VANT Matrice 100 DJI (A) e câmera multiespectral Micasense RedEdge (B)	31
Figura 7 - Composição em cor verdadeira da área experimental com respectivos pontos de controle, usando uma câmera MAPIR SURVEY 3	31
Figura 8 - Sensor Remoto Proximal GreenSeeker (A e B) e medidor indireto de clorofila foliar, <i>Soil-Plant Analyses Development</i> (SPAD) (C).....	33
Figura 9 - Gabaritos (A) e colheita da forragem utilizando cortador de cerca viva (B)	34
Figura 10 - Fluxograma das atividades experimentais da implantação dos canteiros até o quarto corte.	35
Figura 11 - Índices de Vegetação médios obtidos em cada colheita nas duas diferentes alturas de voo (40 e 80m). Barras seguidas de letras diferentes se diferem pelo Teste Tukey ($P<0.05$).....	39
Figura 12 - Índices de Vegetação médios obtidos em cada colheita nas duas diferentes alturas de voo (40 e 80m). Barras seguidas de letras diferentes se diferem pelo Teste Tukey ($P<0.05$).....	41
Figura 13 - Correlações entre os Índices de Vegetação obtidos pela câmera multiespectral embarcada no VANT e pelos Sensores Proximais com as variáveis do pasto, referente a segunda colheita. Correlações marcadas por * foram significativas ($P<0.05$) pelo Teste <i>t-student</i>	42
Figura 14 - Correlações entre os Índices de Vegetação obtidos pela câmera multiespectral embarcada no VANT e pelos Sensores Proximais com as variáveis do pasto, referente a terceira colheita. Correlações marcadas por * foram significativas ($P<0.05$) pelo Teste <i>t-student</i>	43

Figura 15 - Correlações entre os Índices de Vegetação obtidos pela câmera multiespectral embarcada no VANT e pelos Sensores Proximais com as variáveis do pasto, referente a quarta colheita. Correlações marcadas por * foram significativas ($P < 0.05$) pelo Teste *t-student*.....44

LISTA DE TABELAS

Tabela 1 - Classificação de Veículos Aéreos Não Tripulados (VANTs)	19
Tabela 2 - Resultado da análise química de macrominerais dos solos dos blocos da área experimental.....	29
Tabela 3 - Distribuição dos tratamentos nas parcelas experimentais	30
Tabela 4 - Índices de Vegetação obtidos a partir da câmera multiespectral	32
Tabela 5 - Valor médio da massa de forragem (kg MS ha ⁻¹) e altura (cm) do capim-braquiária em todas as colheitas e doses de Nitrogênio (kg ha ⁻¹ colheita ⁻¹) e média dos teores de proteína bruta (%MS)	36
Tabela 6 - Valor médio dos Índices de Vegetação e ajuste dos modelos linear e quadrático em função das doses de nitrogênio (kg ha ⁻¹ colheita ⁻¹)	37
Tabela 7 - Valor médio do Índices de Vegetação por Diferença Normalizada (NDVI) e clorofila foliar obtidos respectivamente a partir Sensor Proximal GreenSeeker e medidor indireto de clorofila foliar (SPAD), e ajuste dos modelos linear e quadrático em função das doses de nitrogênio (kg ha ⁻¹ colheita ⁻¹)	38

SUMÁRIO

1. INTRODUÇÃO	13
2. REVISÃO DE LITERATURA	16
2.1. Sensoriamento Remoto na agricultura de precisão.....	16
2.2. Índices de Vegetação	21
3. MATERIAL E MÉTODOS	27
3.1. Área experimental e caracterização do clima.....	27
3.2. Implantação do experimento e delineamento experimental	28
3.3. Aquisição das imagens multiespectrais.....	30
3.4. NDVI e índice SPAD obtidos por Sensor proximal	33
3.5. Quantificação da altura, massa e teor de proteína bruta da forragem	34
3.6. Análises estatísticas	35
4. RESULTADOS.....	36
4.1. Variáveis do pasto.....	36
4.2. Índices de Vegetação	37
4.3. Comparação entre as resoluções espaciais (alturas de voo).....	39
4.4. Análise das correlações entre os Índices de Vegetação e as variáveis do pasto	41
5. DISCUSSÃO	45
6. CONCLUSÕES	52
REFERÊNCIAS.....	53

1. INTRODUÇÃO

O Brasil possui um efetivo bovino de aproximadamente 213,5 milhões de cabeças e ostenta o posto de maior exportador mundial de carne bovina (IBGE, 2018). Segundo o censo agropecuário mais recente (IBGE, 2017), o país possui em torno de 158 milhões de hectares de pastagens, onde 70% são cultivadas. Neste contexto, destaca-se a importância das pastagens para pecuária nacional uma vez que a pecuária de corte e leite tem como base a alimentação a pasto.

Dentre as espécies mais difundidas nas pastagens brasileiras estão presentes as plantas do gênero *Brachiaria* (*syn. Urochloa*). Neste cenário, a *Brachiaria decumbens* (*syn. Urochloa decumbens*) cv. Basilisk se destaca por suas características de adaptação a solos com baixa fertilidade, baixos índices pluviométricos, rusticidade, elevada produção de sementes e aceitabilidade animal, sendo muito utilizada em regiões montanhosas com baixo uso de insumos (PACIULLO *et al.*, 2016).

Contudo, para aumentar a eficiência de utilização do pasto é fundamental que o manejo da pastagem e do pastejo sejam realizados de maneira correta. No entanto, uma das principais dificuldades enfrentadas pelos pecuaristas é determinar a variabilidade espacial e temporal da quantidade e valor nutritivo da forragem ofertada aos animais. O conhecimento da massa de forragem e de seu valor nutritivo é fundamental para o planejamento alimentar da produção animal em pastagens (FERRAZ *et al.*, 2010).

Neste contexto, a Zootecnia de Precisão tem sido amplamente utilizada para gerar informações precisas no campo, assim como auxiliar na tomada de decisão em diversas áreas, inclusive no manejo das pastagens. Geralmente, essas informações são geradas por meio de medidas diretas por meio de colheita de amostras da forragem, seguida pela secagem das mesmas e análises laboratoriais.

Este método de avaliação, consiste em técnicas destrutivas que possuem algumas limitações como tempo de execução e custos elevados. Além disso, medidas diretas da massa de forragem se baseiam em amostragens aleatórias, e, em condições de campo, frequentemente nos deparamos com áreas de grande extensão, montanhosas, de difícil acesso e com grande heterogeneidade, dificultando o princípio da representatividade na obtenção de amostras. Assim, destaca-se a importância da calibração de metodologias indiretas que permitam efetuar tais avaliações em tempo

real e com maior acurácia, por permitir avaliação de grandes áreas levando em consideração a variabilidade espacial da pastagem. A determinação do valor nutritivo é ainda mais complexa pois depende de amostragem correta e representativa, além dos custos serem mais elevados.

Neste cenário, o Sensoriamento Remoto vem se destacando, uma vez que, por meio de informações espectrais obtidas por imagens de satélites ou aéreas, ou pelo uso de sensores como espectrorradiômetros e medidores portáteis de clorofila, diversos Índices de Vegetação (IVs) podem ser calculados. Esses IVs são associados com as avaliações diretas de interesse, como biomassa de forragem, altura do pasto, teor de nitrogênio entre outros (XUE & SU, 2017, TONG *et al.*, 2019). Entre os índices, o mais comumente utilizado é o Índice de Vegetação por Diferença Normalizada (NDVI), o qual é calculado utilizando as bandas do vermelho e Infravermelho Próximo (QUEMADA *et al.*, 2014).

Diversos trabalhos têm comprovado a relação do NDVI com características estruturais da vegetação e teor de nitrogênio (CATUREGLI *et al.*, 2016; XUE *et al.*, 2017), porém este índice perde sensibilidade em condições de elevada biomassa e alto teor de clorofila, o que pode subestimar as predições.

Alguns índices tais como o Índice de Vegetação melhorado (EVI), o Índice de Vegetação por Diferença Normalizada que utiliza as bandas *Red Edge* (NDRE) e o Índice de Clorofila (CI) podem minimizar esse efeito de saturação em níveis elevados de clorofila e biomassa (MAGNEI *et al.*, 2017; WALSH *et al.*, 2018). Tong *et al.*, (2019), também demonstraram que a combinação de diferentes IVs no modelo apresentam melhores estimativas da produção de biomassa de pastagens.

Assim, considerando que diversos índices são amplamente aplicados para culturas anuais, tais como arroz, trigo e milho, torna-se necessária a investigação, calibração e aplicação desses índices para culturas perenes, como é o caso das pastagens. No entanto, estudos com Sensoriamento Remoto aplicado à forrageiras tropicais, típicas de pastagens brasileiras, como forrageiras do gênero *Brachiaria* (*syn. Urochloa*), predominantes no país, bem como em áreas de grande extensão e alta variabilidade espacial ainda são muito escassos.

Portanto, estudos que envolvam a correlação de IVs, principalmente com massa, teor de proteína bruta na forragem, altura e IAF, podem auxiliar o produtor no gerenciamento dos seus pastos de forma rápida e acurada, além de inferir sobre o melhor momento de ofertar aos animais uma forragem de melhor qualidade, ajustar a

taxa de lotação de acordo com a disponibilidade de forragem, bem como permitir um melhor ajuste na composição do suplemento de acordo com as variações do valor nutritivo do pasto ao longo das estações do ano.

O presente estudo foi conduzido com o objetivo de determinar e testar possíveis correlações entre os IVs gerados a partir de imagens aéreas multiespectrais e dos sensores portáteis, com as variáveis massa de forragem (MF), altura (ALT) e teor de proteína bruta (PB) do capim-braquiária, bem como identificar os índices melhor correlacionados com tais variáveis.

2. REVISÃO DE LITERATURA

2.1. Sensoriamento Remoto na agricultura de precisão

O conceito de Agricultura de Precisão (AP) não é difícil de ser entendido, embora vários autores o apresentem de formas distintas. Neste trabalho usaremos a abordagem feita por Brasil (2012), que afirma que AP é um sistema que possibilita o gerenciamento agrícola baseando na variação espacial, assim como variação temporal da unidade produtiva, visando o manejo adequado da produção, que possibilita aumento na sustentabilidade com menores efeitos no meio ambiente.

Essa tecnologia é uma alternativa moderna que permite a otimização do uso de recursos agrícolas, sendo, além disso, um meio para aumentar a competitividade no mercado interno e externo pela redução dos custos de produção animal e agrícola (BAIO *et al.*, 2017).

Partindo deste conceito, é possível determinar caminhos a serem seguidos dentro da AP focados em manejo das pastagens, como o Sensoriamento Remoto (SR). Uma das primeiras explanações sobre o SR seria de que é uma forma de conseguir informações de determinado objeto sem estar próximo ao mesmo (ELACHI, 1987). Este é o conceito básico dessa ciência, mas é necessário discutir mais sobre, para que possamos desenvolver pesquisas na área. Sensoriamento Remoto é classificado por Meneses *et al.* (2012a), como uma ciência que trabalha na obtenção de imagens da superfície da terra, por meio da detecção e medição quantitativa das respostas das interações da radiação eletromagnética com os materiais terrestres.

Para que seja possível o uso dessa tecnologia, é necessário entender em quais fatores o SR é baseado, ou seja, entender a resposta espectral dos objetos que serão alvos de estudos, e também como são adquiridos esses dados. Meneses *et al.* (2012) e Ponzoni (2002) ressaltam a importância de se conhecer os comprimentos de onda e com o que os mesmos estão relacionados.

Segundo Meneses *et al.* (2012a), o sensor, seja de um satélite ou câmera, consegue capturar a radiância de um objeto, ou seja, a energia que sai do mesmo, mas esta pode sofrer muitas alterações, devido ao próprio movimento da terra, até mesmo a superfície solar que a projeta. Assim, é de suma importância conhecer a irradiância, ou seja, a energia que está incidindo no objeto, para minimizarmos os erros. Os dados utilizados para o Sensoriamento Remoto são baseados então em

reflectância, que é a razão entre a quantidade de energia radiante que deixa uma unidade de área no terreno (radiância) pela quantidade de energia incidente naquela área (irradiância), sendo seu valor expresso em porcentagem.

A utilização dessa tecnologia dentro do agronegócio permite reduzir as falhas nos manejos dentro da propriedade rural, assim como mapear áreas mais ou menos produtivas, auxiliando assim na tomada de decisão (JORGE & INAMASU, 2014).

Meneses *et al.* (2012b) ressaltaram a importância de que para ser denominado Sensoriamento Remoto, é necessário que o sensor não esteja próximo ao objeto alvo em questão. Ademais, enfatiza como premissas dessa ciência: a ausência de matéria no espaço entre o objeto e o sensor, assim toda a informação advinda do objeto consegue chegar ao sensor, e que a radiação eletromagnética é a única energia que é possível ser transportada pelo espaço, assim é o que possibilita essa comunicação entre objeto e sensor.

É importante entender quais tipos de Sensoriamento Remoto temos a disposição para o uso agrícola e quais as vantagens e desvantagens de cada um.

Newton *et al.* (2009), relataram que a utilização de imagens de satélite são indicadas para identificação de paisagens, florestas, ou até mesmo o que ele classifica como paisagens grosseiras (sem um detalhamento e com grandes escalas), partindo da sua resolução. Satélites com alta resolução espacial, como QuickBird, IKONOS e RapidEye, conseguem aumentar a capacidade de identificar a heterogeneidade espacial do status de nitrogênio da cultura, conseguindo então mapear a área por qualidade ou defasagem nutricional. (ALI *et al.*, 2017; SHOU *et al.*, 2017)

Contudo uma grande desvantagem do uso de satélites citada por Turner *et al.* (2003), refere-se a sua incapacidade de identificar objetos que estejam em intervalos de tamanhos menores que 30 m ou até mesmo 10 m, devido à baixa resolução deste sensor. Assim, ao se utilizar imagens de satélites existe a limitação da resolução dos mesmos, o que nos limita a áreas maiores de estudo.

Outro fator relevante na escolha dos satélites é baseado na premissa citada por Meneses *et al.* (2012b), onde o espaço entre o objeto a ser estudado e o sensor deve ser vazio, logo a presença comum de nuvens causaria um impedimento. Paneque - Galvéz *et al.* (2014) reafirmaram essa questão e ainda citaram como outra desvantagem o período de revisita do satélite (resolução temporal). Hoje já é possível obter essas imagens em intervalos menores e com resoluções variadas, sendo importante analisar a viabilidade e a logística para obtenção das mesmas.


Por outro lado, aparelhos terrestres, como o SPAD (*Soil-Plant Analyses Development*), possibilita a quantificação clorofila nas lâminas foliares e consequentemente o mapeamento da área (MONOSTORI *et al.*, 2016; LI *et al.*, 2018; LIU *et al.*, 2018; RÖLL *et al.*, 2019). Li *et al.* (2020) estudaram a correlação entre índice SPAD com N em híbridos de trigo e reportaram uma alta confiabilidade desde aparelho para estimar a qualidade nutricional da cultura.

Outras tecnologias de SR vem crescendo exponencialmente no mercado, sanando as dificuldades dos satélites e a logística do SPAD, como os veículos aéreos não tripulados (VANTs) - também denominados sistemas de aeronaves pilotadas remotamente (RPAs) ou sistemas de aeronaves não tripuladas (UAS) (NEX *et al.*, 2014; COLOMINA *et al.*, 2014).


As possibilidades dentro das pesquisas e de gerenciamento de propriedades aumentaram a função deste novo método de SR. Este pode fornecer imagens com resoluções altas, permitindo assim o maior detalhamento dos objetos, contrapondo os satélites (Figura 1). Outro fato a favor do uso de VANT em SR é a sua independência perante dias com nuvens, já que é possível controlar sua altura de voo, não passando de 120 metros em sua maioria, a facilidade de poder controlar este voo e também por ter baixo custo (WATTS *et al.*, 2010). Na Figura 1 é possível visualizar a diferença entre uma imagem obtida via Satélite e a mesma imagem obtida a partir de VANT.

Figura 1 - Comparação entre imagens obtidas via Satélite (A) e a partir de VANT (B)

A.



B.



Fonte: <https://sensix.com.br/2017/05/14/agricultura-drone-ou-satelite/>

Ainda, existem disponíveis no mercado uma série de modelos de VANTs, que Segundo Alves Júnior (2015), podem ser classificados de duas formas, conforme descrito na Tabela 1 e mostrados na Figura 2.

Tabela 1 - Classificação de Veículos Aéreos Não Tripulados (VANTs)

CATEGORIA	DESCRIÇÃO
Asa-fixa (Figura 1A)	Aeronaves com asas fixas que exigem uma pista para decolagem e pouso, ou uma catapulta no caso do lançamento
Asa-rotativa (Figura 1B)	Aeronaves com asas rotativas (hélices), pouso e decolagem na vertical. Possuem a capacidade de pairar no ar e alta capacidade de execução de manobras

Fonte: Adaptado de Alves Júnior (2015).

Figura 2 - Aeronave com asas fixas, eBee, desenvolvido pela empresa SenseFly (A) e com asas rotativas, Matrice 100 DJI, desenvolvido pela empresa DJI (B)



Fonte: SenseFly (2015).



Fonte: DJI (2018).

Getzin (2012) reforça essas qualidades do uso de VANT para mapeamento e monitoramento de áreas, mas realça que estes aparelhos possuem tempo de voos reduzidos, já que são dependentes de baterias. Cada veículo possui uma bateria com um tempo de voo média, o que pode influenciar são os implementos que são colocados para captura de imagens e afins.

Com o avanço das tecnologias, que tornam possível a captura e processamento de dados, os VANTs representam uma excelente estratégia, aliando flexibilidade para transportar os sensores e outros dispositivos, trazendo então soluções profissionais para o mapeamento de áreas agrícolas e urbanas a baixo custo (LÓPEZ *et al.*, 2019).

O uso dos VANTs aliado a câmeras multiespectrais torna possível determinar várias características das plantas, como sua altura, produção de biomassa, densidade e até mesmo seu valor nutricional. (TONG *et al.*, 2019; XUE *et al.*, 2017; CATUREGLI *et al.*, 2016; MOECKEL *et al.*, 2016).

Assim, alguns trabalhos foram feitos baseados no uso de VANT e o estudo da vegetação. Utilizando uma câmera multiespectral acoplada em um microdrone, Agüera *et al.* (2011) mediram o nitrogênio do girassol e compararam esses resultados com dados coletados em uma plataforma terrestre. Já Pölönen *et al.* (2013) estimaram o conteúdo de biomassa e nitrogênio com um sensor hiperespectral, o interferômetro Fabry-Perot, montado em um VANT, aumentando assim a confiança da utilização desse tipo de veículo no campo. Girolamo-Neto *et al.* (2019) propôs em seu trabalho

o uso de câmeras acopladas em VANT na detecção e mapeamento de plantas daninhas como o capim-gordura no cultivo da cana, obtendo 83% de sucesso com o uso desta tecnologia.

2.2. Índices de Vegetação

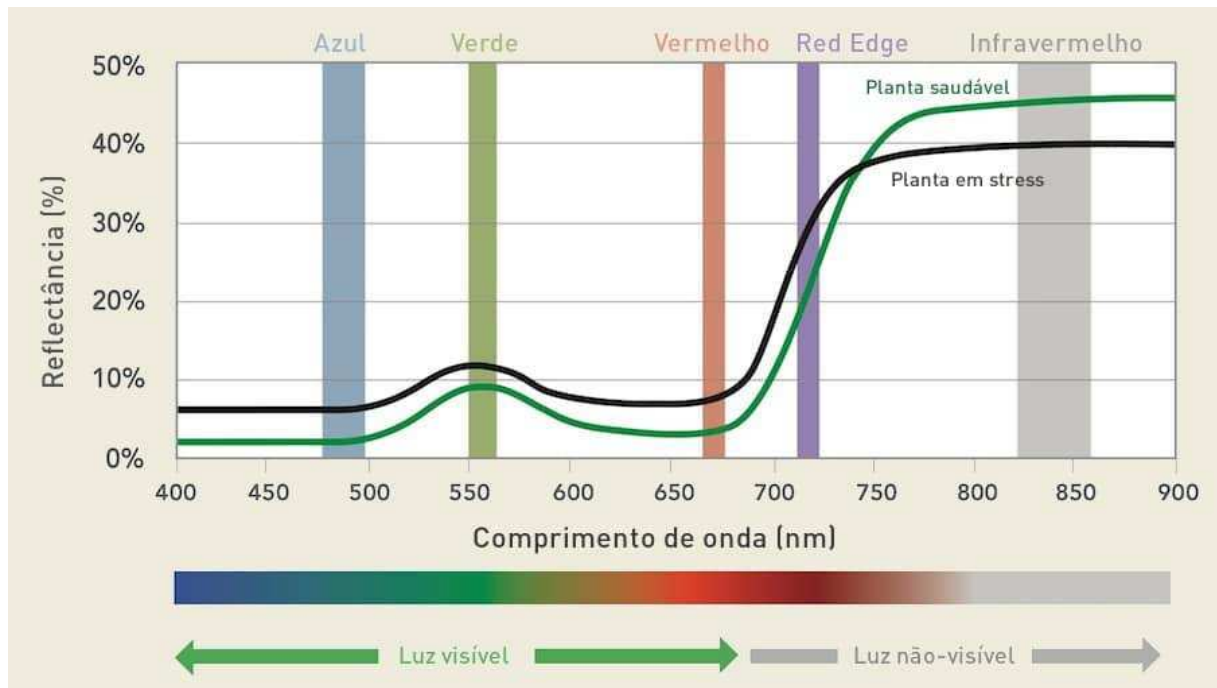
Os Índices de Vegetação (IVs) podem ser classificados como medidas radiométricas adimensionais, que se baseiam em propriedades ou respostas espectrais de plantas a determinadas condições de radiações eletromagnéticas (BERGER *et al.*, 2019). Explora principalmente as regiões do Infravermelho Próximo e a região do visível (*RGB*), que abrange as bandas do Azul, Verde e Vermelho.

Mulla (2012) classifica os espectros de acordo com os seguintes intervalos: Azul (440–510nm), Verde (520-590 nm), Vermelho (630-685nm), *Red Edge* (690-730 nm) Infravermelho Próximo (760-850 nm). As bandas do Vermelho e do Infravermelho são tradicionalmente mais utilizadas quando se busca correlação com a produção de biomassa.

Os IVs mais utilizados para determinar a presença de plantas usam, em maioria, as bandas do Vermelho (*Red*) que possui uma alta taxa de absorção da radiação eletromagnética incidente e a banda do infravermelho, pois essa possui uma alta taxa de reflexão dessa radiação (Borges, 2015). Ponzoni (2002) explica essa resposta espectral devido a própria estrutura físico-química da planta, onde na região do visível (*RGB*), em função dos elevados teores de pigmentos fotossintetizantes, ocorre uma elevada absorção de radiação eletromagnética, possuindo assim baixa refletância (Figura 3). Por outro lado, na região do Infravermelho, ocorre o contrário, já que a refletância é elevada (Figura 3).

Meneses *et al.* (2012) afirmam que essa interação entre as bandas tem como respostas cores cinza mais escuras nas imagens multiespectrais onde não há muita vegetação, ou que o solo esteja exposto. Além disso, em casos onde ocorre maior presença de plantas, as cores cinza ficam mais claras, devido a maior reflexão da radiação.

Figura 3 - Resposta espectral das plantas



O Índice de Vegetação mais utilizado é o NDVI (*Normalized Difference Vegetation Index*), o qual foi proposto por Rouse *et al.* (1973), e que correlaciona as bandas do vermelho com o infravermelho de acordo com a equação 1:

$$\text{Equação 1: } \text{NDVI} = \frac{\rho_{\text{NIR}} + \rho_{\text{Red}}}{\rho_{\text{NIR}} - \rho_{\text{Red}}}$$

Onde, ρ_{NIR} é a reflectância na região do Infravermelho Próximo e ρ_{Red} reflectância na região do Vermelho.

Linhares (2016) afirmou que o NDVI pode variar de -1 a 1, mas que os valores mais comuns em áreas agrícolas são de 0,2 a 0,8, onde quanto mais próximo de +1, maior o vigor da vegetação. Destaca-se que valores inferiores a zero possivelmente representam áreas alagadas ou até mesmo rochosas, e valores muito baixos, porém positivos podem representar áreas com vegetação mais esparsas.

Em estudos realizados em trigo, em duas diferentes fases de crescimento, Walsh *et al.* (2018) reportam fortes correlações entre NDVI e a quantidade de nitrogênio presente na planta na metade de seu ciclo de crescimento e ao final do ciclo, na fase de colheita. No mesmo trabalho, os autores relataram a influência do solo neste índice, podendo reduzi-lo devido à baixa reflectância do mesmo.

Em contrapartida, em um trabalho realizado com milho utilizando câmeras multiespectrais acopladas em VANTs e aviões, a correlação com o mesmo índice e a produção de nitrogênio pela planta não foi significativa (GABRIEL *et al.*, 2017).

Mesmo sendo considerado até então como índice base, o NDVI possui uma desvantagem quando se trata de altos níveis de área foliar (IAF acima de 3) e níveis elevados de adubação, pois a região espectral do visível, principalmente a banda do Vermelho tende a saturar devido a presença de pigmentos fotossintetizantes (PONZONI, 2002). Magney *et al.* (2017) determinaram que com valores acima de 0,7 o índice já não acompanha o desenvolvimento da planta.

Baseado nisso, foi criado outro índice, o NDRE (*Red Edge Normalized Difference Vegetation Index*), proposto por Gitelson *et al.* (1994). Este índice, ao invés de usar a banda do Vermelho como o NDVI, usa-se uma banda com espectro maior, conhecida como *Red Edge*, ou Borda Vermelha (690-730 nm) conforme a equação 2:

$$\text{Equação 2: NDRE} = \frac{\rho_{\text{NIR}} - \rho_{\text{RedEdge}}}{\rho_{\text{NIR}} + \rho_{\text{RedEdge}}}$$

Em que, ρ_{NIR} é a reflectância na região do Infravermelho Próximo e $\rho_{\text{Red Edge}}$ reflectância na região da Borda do Vermelho.

A banda *Red Edge*, assim como a banda do Verde, pode reduzir o efeito da saturação, por possuírem maiores níveis de reflectância, assim está banda possui maiores correlações com produção de biomassa e nitrogênio na planta. (HATFIELD *et al.*, 2010; LI, *et al.*, 2013; SONG *et al.*, 2016).

Comparando os dois índices com a quantidade de nitrogênio do trigo, Walsh *et al.*, (2018) observaram melhores resultados em NDRE, alcançando $R^2 = 0,86$ ainda em fase de crescimento, assim como na fase de colheita onde os valores foram de $R^2 = 0,88$ e $R^2 = 0,82$ para NDRE e NDVI, respectivamente.

Song *et al.*, (2016), avaliaram treze Índices de Vegetação, utilizando um espectrorradiômetro em arroz em treze ângulos zênite, para determinar se o mesmo teria efeito sobre os IVs e qual destes teria maiores correlações com o nitrogênio na planta. Dentre os IVs calculados, o NDRE apresentou maiores valores comprovando assim sua confiabilidade em estimar a produção de nitrogênio na cultura.

Padrão de resposta semelhante foi encontrado por Magney *et al.* (2017), onde contrapondo os dois índices também utilizando a cultura do trigo e comparando o

nitrogênio, obteve $R^2 = 0,81$ para NDRE e resposta linear, já em NDVI o $R^2 = 0,71$ com resposta não-linear.

Mesmo com a interferência da absorção de água, por exemplo, a região espectral do *Red Edge* mostra-se muito correlacionada com a quantidade de nitrogênio presente na planta (WANG *et al.*, 2019).

Gitelson *et al.*, (2003) baseado na necessidade de mais índices que se correlacionassem com a clorofila criaram o CI_{Green} (*Green Chlorophyll Index*) e o $CI_{RedEdge}$ (*Red Edge Chlorophyll Index*) respectivamente apresentados na equação 3 e 4.

$$\text{Equação 3: } CI_{Green} = \frac{\rho_{NIR}}{\rho_{Green}} - 1$$

$$\text{Equação 4: } CI_{RedEdge} = \frac{\rho_{NIR}}{\rho_{Red Edge}} - 1$$

ρ_{NIR} é a reflectância na região do Infravermelho Próximo, ρ_{Green} é a região do verde e $\rho_{Red Edge}$ reflectância na região da Borda do Vermelho.

Souza *et al.* (2015) compararam os dois índices com o objetivo de mapear uma área, que continha mata, pasto e plantio de cana e constataram que o índice de clorofila que utilizou a banda *Red Edge* obteve uma maior capacidade de diferenciar as pastagens das demais áreas. Já o índice que utiliza a banda do verde foi melhor em diferenciar a porção de mata.

Walsh *et al.* (2018), avaliando trigo obtiveram resultados positivos quando analisaram as correlações entre os dois Índices de Vegetação (CI_{green} e $CI_{RedEdge}$) e o conteúdo de nitrogênio presente na planta em fase de crescimento.

Outro Índice de Vegetação simples e muito usado é o SR (*Simple Ratio*), proposto por Jordan (1969) (Equação 5).

$$\text{Equação 5: } SR = \frac{\rho_{NIR}}{\rho_{Red}}$$

Onde, ρ_{NIR} é a reflectância na região do Infravermelho Próximo ρ_{Red} é a reflectância na região do vermelho.

Utilizando o satélite RapidEye, que possui a banda do *Red Edge*, Magney *et al.* (2017) correlacionaram os Índices de Vegetação SR e SR_{RedEdge}, com a presença de nitrogênio na cultura do trigo e encontram valores de $R^2 = 0,64$ e $0,68$, respectivamente. Os autores concluíram que esses índices podem ser utilizados para predição e mapeamento do nitrogênio para a cultura do trigo.

Corroborando com o uso deste IV na cultura do trigo, mas usando VANT, Walsh *et al.* (2018) encontraram fortes correlações entre de SR_{Red Edge} com o teor de nitrogênio das plantas em duas fases diferentes, crescimento e no ponto de colheita, ($R^2 = 0,85$ e $0,88$, respectivamente). Os resultados demonstraram que as correlações entre os IVs com as características das culturas podem variar durante as fases de desenvolvimento.

Com o objetivo de determinar um IV para prever a cobertura vegetal para *Olea Europaea* L., Lima-Cueto *et al.* (2019) utilizaram o GNDVI (*Green Normalized Difference Vegetation Index*) criado por Gitelson *et al.* (1996), representada na Equação 6.

$$\text{Equação 6: } \text{GNDVI} = \frac{\rho\text{NIR} - \rho\text{Green}}{\rho\text{NIR} + \rho\text{Green}}$$

Em que, ρNIR é a reflectância na região do Infravermelho Próximo e ρGreen é a reflectância na região do Verde.

Neste estudo foi observado uma correlação positiva entre o GNDVI com a cobertura vegetal. Da mesma forma, Borges (2015), usando imagens de satélite em *Brachiaria decumbens* (*syn. Urochloa decumbens*) encontrou correlações significativas com a produção de biomassa total no final da primavera assim como no período de seca.

Experimento conduzido com arroz com o intuito de estudar as correlações existentes entre os IVs já existentes e a produção de *Oryza sativa* L., apresentaram boas correlações quando se utilizaram o GNDVI (MORENO-GARCIA *et al.*, 2018). Valores ainda maiores são encontrados quando se correlaciona este índice com a produção de nitrogênio foliar (SONG *et al.*, 2016).

Com base nas correlações já existentes entre as bandas do Vermelho, Infravermelho e *Red Edge*, Dash *et al.* (2004) criaram o MTCI (*MERIS Terrestrial Chlorophyll Index*) (Equação 7):

$$\text{Equação 7: } \text{MTCI} = \frac{\rho_{\text{NIR}} - \rho_{\text{Red Edge}}}{\rho_{\text{Red Edge}} + \rho_{\text{Red}}}$$

Onde, ρ_{NIR} é a reflectância na região do Infravermelho Próximo, ρ_{Red} é a reflectância na região do vermelho, e $\rho_{\text{Red Edge}}$ reflectância na região da Borda do Vermelho.

Yu *et al.* (2013) encontraram boas correlações do MTCI para determinação de nitrogênio na planta na cultura do arroz, utilizando espectrorradiômetro. Os autores enfatizaram que o uso da banda *Red Edge* possibilita maiores correlações tanto da estrutura do dossel quanto do conteúdo de nitrogênio.

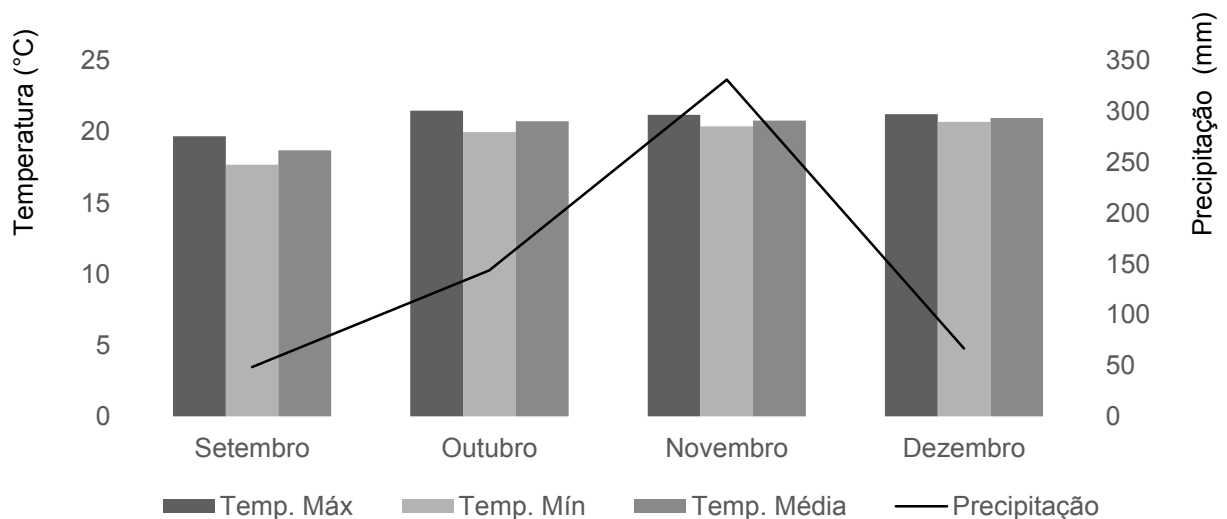
3. MATERIAL E MÉTODOS

3.1. Área experimental e caracterização do clima

O experimento foi conduzido no período de setembro de 2019 a dezembro de 2019, no município de Viçosa-MG, localizado a 20° 45' de latitude sul, 46°51' de longitude oeste e 689 m de altitude, pertencente a Unidade de Ensino, Pesquisa e Extensão em Forragicultura do Departamento de Zootecnia da Universidade Federal de Viçosa. O solo da área experimental é caracterizado como Latossolo Vermelho-Amarelo, de textura argilosa (EMBRAPA, 2006).

O clima da região de Viçosa, de acordo com o sistema Köppen, é do tipo Cwa, apresenta precipitação anual média de 1.340 mm e umidade relativa do ar média de 80%. Os dados meteorológicos registrados durante o período experimental foram obtidos na Estação Meteorológica do Departamento de Engenharia Agrícola da UFV, situada a cerca de 550 m da área experimental (Figura 4).

Figura 4 - Dados de temperatura e precipitação durante o período experimental




Fonte: Estação Meteorológica do Departamento de Engenharia Agrícola da UFV.

3.2. Implantação do experimento e delineamento experimental

Antes do início do experimento, a área de pastagem com *Brachiaria decumbens* (*syn. Urochloa decumbens*) foi cercada e subdividida em parcelas. Em seguida, foi realizado o arranquio da *Brachiaria humidicula* (*syn. Urochloa humidicula*), presente como invasora em algumas parcelas. Após o controle, foram então efetuados cortes com roçadeira costal na altura de 10 cm e replantio da *Brachiaria decumbens* (*syn. Urochloa decumbens*) em áreas com menor cobertura do solo.

A área experimental consistiu em 0,7 ha de *Brachiaria decumbens* (*syn. Urochloa decumbens*) cv. Basilisk estabelecida em 2011. A área foi dividida em 25 parcelas de 12 m² cada (3x4 m) distribuídos em cinco blocos homogêneos (B1, B2, B3, B4, B5) com espaçamento de 2 m entre os mesmos e 1,5 m entre as parcelas (Figura 5).

Figura 5 - Croqui da área experimental



Antes do início do experimento, 20 amostras de solo na camada de 0 a 20 cm foram coletadas em cada bloco, utilizando o trado holandês, para verificar a necessidade de calagem e adubação de manutenção. O resultado da análise química de macrominerais dos solos dos blocos da área experimental pode ser consultado na Tabela 2.

Tabela 2 - Resultado da análise química de macrominerais dos solos dos blocos da área experimental

BLOCOS	pH (H ₂ O)	P	K (mg dm ⁻³)	Ca⁺	Mg²⁺ (cmol _c dm ⁻³)	P- Rem mg L ⁻¹
1	5,39	4,5	109	2,37	0,93	24,8
2	5,23	3,4	100	1,99	0,80	23,7
3	5,47	3,6	142	2,25	0,90	26,5
4	5,17	2,7	87	1,77	0,77	26,2
5	5,23	2,7	66	2,06	0,77	25,8
BLOCOS	Al³⁺	H+Al	SB (cmol _c dm ⁻³)	t	T	m (%)
1	0,00	4,1	3,58	3,58	7,68	0,0
2	0,18	4,0	3,05	3,23	7,05	5,6
3	0,00	3,7	3,51	3,51	7,21	0,0
4	0,18	4,1	2,76	2,94	6,86	6,1
5	0,09	4,0	3,00	3,09	7,00	2,9

P, K: Extrator Mehlich-1; Ca²⁺, Mg²⁺, Al³⁺: Extrator (KCl - 1 mol L⁻¹); P-rem = Fósforo Remanescente; H + Al: Extrator (Acetato de Cálcio 0,5 mol L⁻¹ - pH 7,0); SB = Soma de Bases Trocáveis; t = Capacidade de Troca Catiônica Efetiva; T = Capacidade de Troca Catiônica a pH 7,0. m = Índice de Saturação por Alumínio.

Devido à baixa saturação por alumínio, associada à boa tolerância da forrageira à acidez e à baixa exigência em fertilidade, o pH, bem como os níveis de cálcio e magnésio do solo foram considerados satisfatórios e não houve necessidade de calagem em nenhum bloco (Tabela 2). No entanto, de acordo com Ribeiro et al., (1999) notou-se baixa disponibilidade de fósforo, sendo recomendado aplicação de 30 kg ha⁻¹ de P₂O₅ em manutenção, equivalente a 200 g de superfosfato simples/parcela. Ainda segundo recomendações do mesmo autor, foi necessária aplicação de 40 kg ha⁻¹ de K₂O, equivalente a 8 g de KCl/parcela, somente no bloco 5.

Com o objetivo de gerar variação nas características estruturais bem como no teor proteico da planta, foram aplicadas diferentes doses de nitrogênio nas parcelas. Essas aplicações foram divididas em cinco doses por colheita (0, 50, 100, 150 e 200 kg ha⁻¹). As aplicações de nitrogênio foram parceladas em doses de 50 kg ha⁻¹

utilizando ureia como fonte do nutriente. A aplicação da primeira dose foi realizada após cada colheita e as demais parceladas a cada 3 dias de forma que todas as parcelas receberam toda a dose de N até uma semana antes da colheita seguinte. Após cada evento de adubação, cada parcela foi irrigada.

A altura de resíduo foi mantida em 10 cm para todos os tratamentos, para manter o crescimento homogêneo em cada parcela. Na Tabela 3 estão as parcelas que receberam os tratamentos com de acordo com as doses de nitrogênio.

Tabela 3 - Distribuição dos tratamentos nas parcelas experimentais

TRATAMENTOS	DOSES DE N (kg ha ⁻¹)	PARCELAS
1	0	2 – 8 – 11 – 20 – 25
2	50	4 – 10 – 13 – 17 – 23
3	100	1 – 7 – 12 – 18 – 21
4	150	5 – 9 – 15 – 19 – 24
5	200	3 – 6 – 14 – 16 – 22

3.3. Aquisição das imagens multiespectrais

Para aquisição das imagens, foram realizados voos semanais com um VANT multirrotor do tipo Matrice 100 DJI, com uma câmera multiespectral Micasense RedEdge a bordo (Figura 6A), capaz de capturar 5 bandas espectrais: *Red* (668 nm com a largura de 10 nm), *Green* (560 nm com a largura de 20 nm), *Blue* (475 nm com a largura de 20 nm), *NIR* (840 nm com a largura de 40 nm) e *Red Edge* (717 nm com a largura de 10 nm) simultaneamente (Figura 6B).

As imagens foram obtidas nas alturas de voo de 40 e 80 m, correspondendo a 9 e 25 cm² de resolução espacial respectivamente. Os voos foram conduzidos em duas diferentes alturas para observar uma possível influência da resolução espacial da imagem, sobre os parâmetros avaliados. O intervalo entre disparos foi de dois segundos com uma sobreposição de 75% longitudinal e 80% lateral para montagem de um mosaico da área.

Figura 6 - VANT Matrice 100 DJI (A) e câmera multiespectral Micasense RedEdge (B)

A.



B.



Fonte: Arquivo pessoal.

Cada parcela foi previamente georeferenciada utilizando o GPS Trimble Pro xr e antes de cada voo, uma imagem do painel de calibração da câmera foi capturada a uma altura de cinco metros para posterior calibração radiométrica. Os voos foram realizados sempre entre 11 e 12 horas, uma vez que neste horário a angulação da luz solar incidente é a mais adequada para captura da reflectância. Na figura 7 observa-se uma composição em cor verdadeira da área experimental com respectivos pontos de controle.

Figura 7 - Composição em cor verdadeira da área experimental com respectivos pontos de controle, usando uma câmera MAPIR SURVEY 3



Fonte: Arquivo pessoal.

Após a aquisição das imagens, foi realizado o pré-processamento das mesmas utilizando-se o *software Agisoft Metashape Professional* (AGISOFT, 2019) para calibração da reflectância do alvo (parcelas) por meio dos dados do painel de calibração, alinhamento das imagens, construção de uma nuvem tridimensional de pontos, densificação da nuvem tridimensional, e construção de um modelo digital de elevação (DEM) para obtenção do ortomosaico.

Após a construção do ortomosaico, estes foram exportados em formato *tiff* para ambiente SIG, utilizando o *software QGIS 3.2* (QGIS Development Team, 2019), onde foi utilizado a calculadora matricial para determinação dos Índices de Vegetação (Tabela 4) em cada imagem. Após essa etapa, foram criadas imagens vetoriais para que fosse possível um recorte em cada parcela representando o corte da forrageira feito *in loco*. A partir desse recorte, foi calculada a média de cada índice em cada parcela usando a ferramenta de estatística zonal do *software QGIS*.

Tabela 4 - Índices de Vegetação obtidos a partir da câmera multiespectral

ÍNDICE DE VEGETAÇÃO	EQUAÇÃO	REFERÊNCIA
C_{green} (Chlorophyll Index)	$(\text{NIR} / \text{Green}) - 1$	Gitelson <i>et al.</i> (2003)
C_{red} (Rededge Chlorophyll Index)	$(\text{NIR} / \text{Red Edge}) - 1$	Gitelson <i>et al.</i> (2003)
GNDVI (Green Normalized Difference Vegetation Index)	$(\text{NIR} - \text{Green}) / (\text{NIR} + \text{Green})$	Gitelson <i>et al.</i> (1996)
NDRE (Red Edge Normalized Difference)	$(\text{NIR} - \text{Red Edge}) / (\text{NIR} - \text{Red Edge})$	Gitelson <i>et al.</i> (1994)
NDVI (Normalized Difference Vegetation Index)	$(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$	Rouse <i>et al.</i> (1973)
MTCI (MERIS Terrestrial Chlorophyll Index)	$(\text{NIR} - \text{Red Edge}) / (\text{Red Edge} + \text{Red})$	Dash <i>et al.</i> (2004)
$SR_{\text{Red Edge}}$ (Red Edge Simple Ratio)	$\text{NIR} / \text{Red Edge}$	McMurtrey <i>et al.</i> (1994)
SR (Simple Ratio)	NIR / Red	Jordan (1969)

3.4. NDVI e índice SPAD obtidos por Sensor proximal

O Sensor Remoto Proximal GreenSeeker (Figura 8A e Figura 8B) foi utilizado em cada parcela antes de cada voo, sempre as 11:00 horas, e manuseado pelo mesmo operador para obtenção do NDVI. Foram realizadas leituras em seis pontos aleatórios e representativos da massa de forragem dentro de cada parcela. A média das 6 leituras representou o NDVI de cada parcela experimental. Para realização da leitura por meio do sensor, o mesmo foi posicionado a um metro acima e paralelo à superfície do dossel para obtenção do NDVI (Figura 8A).

O medidor indireto de clorofila foliar, *Soil-Plant Analyses Development* (SPAD) modelo 502 Minolta, foi utilizado antes dos voos, as 10:00 horas, para mensuração do índice SPAD, que está relacionado ao teor de clorofila da planta. Foram selecionados aleatoriamente 30 pontos em cada parcela e as leituras foram efetuadas no terço médio da lâmina foliar mais nova totalmente expandida, ou seja, quando a lígula está exposta. (Figura 8C).

Figura 8 - Sensor Remoto Proximal GreenSeeker (A e B) e medidor indireto de clorofila foliar, *Soil-Plant Analyses Development* (SPAD) (C)

A.



B.



C.



Fonte:Arquivo pessoal.

3.5. Quantificação da altura, massa e teor de proteína bruta da forragem

Durante todo o período experimental, a altura das plantas foi monitorada antes de cada voo. Foram escolhidos 10 pontos aleatórios por unidade experimental, desconsiderando a bordadura e utilizando-se uma régua graduada em cm.

Para quantificação da massa de forragem, amostras foram colhidas a cada 21 dias, utilizando 2 gabaritos de 1 m² cada, alocados no centro de cada unidade experimental (Figura 9). As amostragens para quantificação da massa de forragem foram realizadas utilizando-se um aparador de cerca viva (Husqvarna, modelo 122HD60).

A forragem contida na área delimitada pelo gabarito foi colhida logo após a aquisição das imagens a uma altura de resíduo de 10 cm. Após o corte, as amostras foram armazenadas em sacos plásticos e foram levadas ao laboratório para pesagem e separação de duas sub-amostras. Uma sub-amostra de 100 g foi destinada à estufa de ventilação forçada a 55 °C, por 72 horas, para determinação da matéria seca ao ar (ASA). Após a secagem, as amostras de massa total de forragem, foram moídas com peneira de porosidade de 1 mm para posteriores avaliações da matéria seca definitiva (INCT-CA G-003/1) e da proteína bruta (INCT-CA N-001/1) seguindo metodologia de Detmann *et al.* (2012).

Figura 9 - Gabaritos (A) e colheita da forragem utilizando cortador de cerca viva (B)

A.



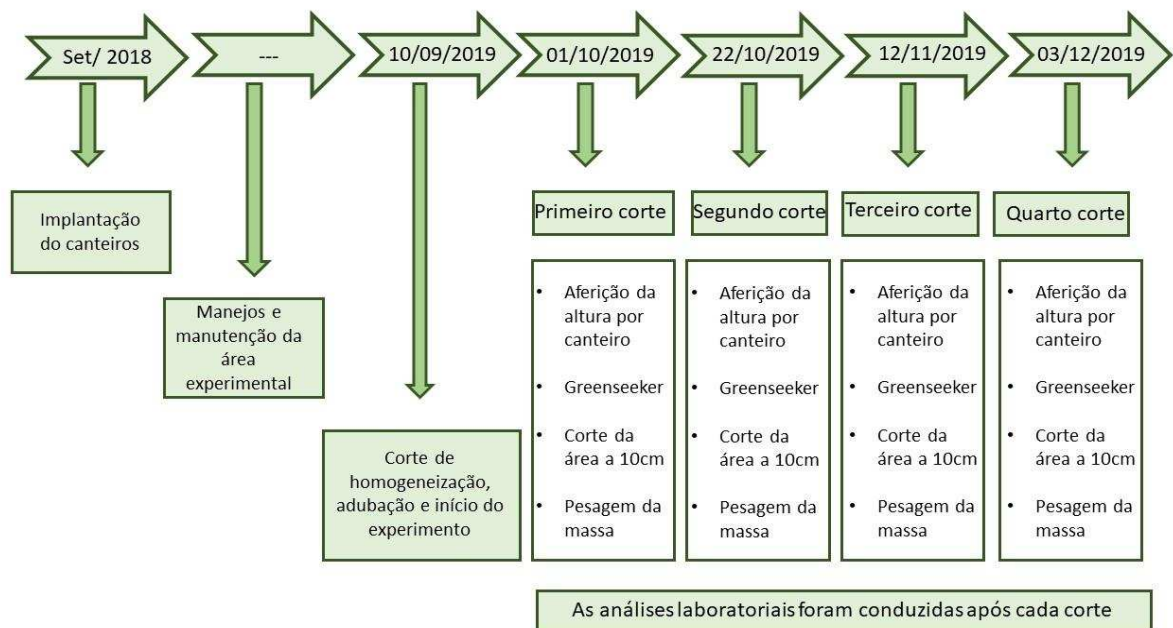
B.



Fonte: Arquivo pessoal.

Todas as etapas citadas a cima, desde a implantação até condução do experimento estão resumidas no fluxograma ilustrado na Figura 10.

Figura 10 – Fluxograma das atividades experimentais da implantação dos canteiros até o quarto corte.



3.6. Análises estatísticas

Os dados obtidos foram analisados utilizando o proc GLM do SAS (SAS, 2002; SAS *Institute*, Cary, NC, USA) considerando-se um delineamento em blocos casualizados. O modelo incluiu efeitos fixos de dose de Nitrogênio e colheita (voo) e efeito aleatório de blocos. Efeitos lineares e quadráticos dos níveis de nitrogênio sobre as variáveis do pasto bem como sobre os Índices de Vegetação foram testados utilizando contrastes ortogonais. Diferenças entre os tratamentos foram consideradas significativas quando $P \leq 0.05$. Foi realizada uma análise de correlação entre os todos os Índices de Vegetação e as variáveis do pasto. As correlações foram testadas ao nível de 5% de probabilidade por meio do Teste *t-student*.

4. RESULTADOS

4.1. Variáveis do pasto

Houve efeito significativo da adubação nitrogenada ($P < 0,0001$), colheita ($P < 0,0001$) e da interação entre adubação nitrogenada e colheita ($P < 0,0001$) sobre a massa de forragem e altura do capim-braquiária. Contudo, para os teores de Proteína bruta da planta observou-se efeito significativo apenas das doses de nitrogênio ($P < 0,001$). Os valores médios para massa de forragem (MF), teor de proteína bruta (PB) e altura (ALT) são apresentadas na Tabela 5.

O modelo quadrático explicou melhor a variação de todas as variáveis analisadas no capim-braquiária em resposta à adubação nitrogenada, em relação à modelos lineares ao longo de todo período experimental. De forma geral, houve aumento da MF e ALT, com o incremento das doses de N até o nível de 150 kg ha⁻¹, com exceção do corte 4, onde os incrementos observados se deram até o nível de 100 kg N ha⁻¹, com decréscimo acima desse nível de adubação (Tabela 5).

Tabela 5 - Valor médio da massa de forragem (kg MS ha⁻¹) e altura (cm) do capim-braquiária em todas as colheitas e doses de Nitrogênio (kg ha⁻¹ colheita⁻¹) e média dos teores de proteína bruta (%MS)

COLHEITA	DOSES DE N					EPM	P-VALOR	
	0	50	100	150	200		L	Q
MASSA DE FORRAGEM								
1	139,62	257,81	266,41	531,39	323,45	53,22	**	*
2	179,88	556,27	519,88	866,23	656,36	69,67	**	**
3	540,46	3299,44	3614,81	4774,24	2970,98	302,66	***	***
4	575,08	1320,01	1893,07	1156,33	1592,91	183,01	**	**
ALTURA								
1	13,60	16,20	17,00	20,00	17,20	0,89	**	**
2	13,00	17,40	17,00	20,40	17,80	0,77	***	**
3	16,80	29,40	34,00	40,40	35,20	1,62	***	***
4	15,80	23,00	29,80	21,00	26,40	1,88	**	**
PROTEÍNA BRUTA								
MÉDIA	10,39	15,71	19,44	20,01	21,07	0,98	*	**

EPM = Erro padrão da média; L = linear; Q = quadrático.

* p<0,05, ** p<0,01, *** p<0,001.

4.2. Índices de Vegetação

Houve efeito significativo de adubação nitrogenada ($P < 0,0001$), colheita ($P < 0,0001$) e interação entre adubação e colheita ($P < 0,05$) para todos os IVs obtidos com a câmera multiespectral embarcada no VANT.

Na tabela 6 estão representadas as médias de todos os IVs em cada dose de adubação dentro de cada colheita, bem como o valor P das análises de regressão para os desdobramentos da interação entre dose de N e colheita.

Tabela 6 - Valor médio dos Índices de Vegetação e ajuste dos modelos linear e quadrático em função das doses de nitrogênio (kg ha^{-1} colheita $^{-1}$)

COLHEITA	DOSES DE N					EPM	P - valor	
	0	50	100	150	200		L	Q
NDVI (NORMALIZED DIFFERENCE VEGETATION INDEX)								
1	0,58	0,73	0,68	0,77	0,68	0,02	**	**
2	0,77	0,88	0,85	0,90	0,86	0,01	**	**
3	0,89	0,95	0,95	0,96	0,95	0,005	**	***
4	0,76	0,83	0,85	0,82	0,83	0,001	**	***
NDRE (RED EDGE NORMALIZED DIFFERENCE)								
1	0,25	0,34	0,32	0,38	0,32	0,02	***	***
2	0,36	0,48	0,47	0,54	0,50	0,01	**	**
3	0,42	0,59	0,62	0,64	0,62	0,01	***	***
4	0,47	0,58	0,62	0,57	0,60	0,01	***	***
GNDVI (GREEN NORMALIZED DIFFERENCE VEGETATION INDEX)								
1	0,56	0,65	0,63	0,69	0,63	0,02	**	***
2	0,66	0,77	0,75	0,80	0,77	0,01	***	***
3	0,74	0,85	0,86	0,87	0,86	0,01	**	***
4	0,75	0,83	0,85	0,82	0,84	0,01	**	***
SR_{Red Edge} (RED EDGE SIMPLE RATIO)								
1	1,66	2,03	1,95	2,23	1,97	0,06	**	***
2	2,13	2,91	2,82	3,39	3,06	0,11	**	***
3	2,47	3,96	4,30	4,61	4,28	0,13	**	***
4	2,83	3,79	4,22	3,70	4,01	0,14	**	***
SR (SIMPLE RATIO)								
1	3,88	6,67	5,88	8,34	5,96	0,53	**	***
2	24,06	16,91	14,37	20,83	16,12	6,99	ns	ns
3	19,30	45,77	45,80	49,39	43,71	2,42	**	***
4	21,82	34,29	36,40	30,26	32,96	1,67	**	***

Continuação Tabela 6...

CI_{Green} (GREEN CHLOROPHYLL INDEX)								
1	2,64	3,91	3,57	4,65	3,59	0,24	**	***
2	4,03	6,70	6,39	8,12	6,97	0,37	**	***
3	5,91	11,71	12,92	14,18	12,77	0,59	***	***
4	6,44	9,71	11,39	9,11	10,42	0,55	**	***
CI_{Red Edge} (RED EDGE CHLOROPHYLL INDEX)								
1	0,66	1,03	0,95	1,23	0,97	0,07	**	**
2	1,15	1,91	1,84	2,39	2,07	0,11	**	**
3	1,47	2,88	3,21	3,51	3,21	0,14	***	***
4	1,83	2,79	3,22	2,69	3,01	0,15	***	***
MTCI (MERIS TERRESTRIAL CHLOROPHYLL INDEX)								
1	0,46	0,79	0,71	0,97	0,72	0,06	**	***
2	0,91	1,62	1,52	2,04	1,73	0,10	***	***
3	1,10	2,65	2,92	3,20	2,91	0,11	***	***
4	1,61	2,50	2,88	2,39	2,68	0,13	**	***

EPM = Erro padrão da média; L = linear; Q = quadrático.

* p<0,05, ** p<0,01, *** p<0,001.

Houve efeito significativo de adubação nitrogenada ($P<0,0001$), colheita ($P<0,0001$) e interação entre adubação e colheita ($P=0,01$) para NDVI obtido com o GreenSeeker enquanto que para o índice SPAD houve efeito ($P<0,001$) apenas das doses de nitrogênio (Tabela 7).

Tabela 7 - Valor médio dos Índices de Vegetação por Diferença Normalizada (NDVI) e índice SPAD obtidos respectivamente a partir Sensor Proximal GreenSeeker e medidor indireto de clorofila foliar (SPAD), e ajuste dos modelos linear e quadrático em função das doses de nitrogênio (kg ha^{-1} colheita⁻¹)

COLHEITA	DOSES DE N					EPM	P-VALOR	
	0	50	100	150	200		L	Q
NDVI – GreenSeeker								
1	0,49	0,66	0,64	0,72	0,65	0,03	**	**
2	0,64	0,84	0,80	0,88	0,82	0,02	**	***
3	0,81	0,94	0,95	0,96	0,95	0,01	***	***
4	0,84	0,93	0,93	0,91	0,92	0,01	***	***
SPAD								
MÉDIA	37,23	45,38	46,06	48,42	47,16	1,74	*	*

EPM = erro padrão da média; IL = linear; Q = quadrático.


* p<0,05, ** p<0,01, *** p<0,001.

4.3. Comparação entre as resoluções espaciais (alturas de voo)


De forma geral, não houve diferença significativa ($P > 0,05$) entre os índices obtidos nas diferentes resoluções espaciais, com exceção da primeira colheita e dos índices NDVI e SR durante a última colheita (Figura 11A e Figura 11E). Nota-se que, durante a primeira colheita, todos os IVs foram significativamente mais elevados quando obtidos a 80 m, com a resolução espacial de $25\text{cm}^2/\text{pixel}$ em comparação a voos de 40 m, com a resolução espacial de $9\text{cm}^2/\text{pixel}$. Durante a primeira colheita, as parcelas ainda não se encontravam em pleno desenvolvimento e apresentavam diversas falhas, devido às condições climáticas ainda desfavoráveis da transição seca-águas. Logo, o efeito da altura de voo (resolução espacial da imagem) sobre os Índices de Vegetação observado apenas no primeiro corte, pode ser devido a maior participação de *pixels* de solo exposto na imagem obtida a 40 m (com maior resolução espacial, $9\text{cm}^2/\text{pixel}$), reduzindo o valor dos índices. Estes resultados eram esperados, e devido à comprovada ausência de diferença significativa entre as diferentes resoluções espaciais da imagem, optamos por apresentar as correlações e discussões do presente estudo apenas para uma das alturas de voo (80 metros) para evitar redundância.

Figura 11 - Índices de Vegetação médios obtidos em cada colheita nas duas diferentes alturas de voo (40 e 80m). Barras seguidas de letras diferentes se diferem pelo Teste Tukey ($P < 0,05$).


A.




B.




C.




D.




E.




F.



G.



H.



4.4. Análise das correlações entre os Índices de Vegetação e as variáveis do pasto


Para primeira data de colheita da forragem (voo 1), a maioria dos IVs apresentaram correlações positivas significativas com as variáveis da forragem, com exceção da relação entre SPAD versus ALT que não foram significativas. Em geral, foram observadas correlações mais fortes dos IVs com MF e correlações mais fracas entre os IVs e teor de PB (Figura 12).

Figura 12 - Índices de Vegetação médios obtidos em cada colheita nas duas diferentes alturas de voo (40 e 80m). Barras seguidas de letras diferentes se diferem pelo Teste Tukey ($P < 0.05$).

MF													
Altura	0,76*												
Proteína bruta	0,57 *	0,72										0,99	
Spad	0,55 *	0,37	0,44 *									0,66	
NDVI/Greenseeker	0,77 *	0,76 *	0,65 *	0,63 *								0,33	
NDVI	0,74 *	0,75 *	0,55 *	0,69 *	0,91 *							0,00	
NDRE	0,78 *	0,77 *	0,66 *	0,67 *	0,93 *	0,97 *						-0,33	
GNDVI	0,75 *	0,76 *	0,59 *	0,66 *	0,91 *	0,99 *	0,99 *					-0,66	
Srrededge	0,80 *	0,77 *	0,65 *	0,67 *	0,93 *	0,97 *	1,00 *	0,98 *				-0,99	
SR	0,79 *	0,77 *	0,59 *	0,65 *	0,92 *	0,97 *	0,98 *	0,97 *	0,99 *				
Cigreen	0,80 *	0,78 *	0,61 *	0,64 *	0,92 *	0,97 *	0,99 *	0,99 *	1,00 *	0,99 *			
Cired	0,80 *	0,77 *	0,65 *	0,67 *	0,93 *	0,97 *	1,00 *	0,98 *	1,00 *	0,99 *	1,00 *		
MTCI	0,80 *	0,78 *	0,64 *	0,67 *	0,93 *	0,97 *	0,99 *	0,98 *	1,00 *	0,99 *	1,00 *	1,00 *	

De forma geral, fortes correlações tanto para os IVs da câmera multiespectral quanto para os índices obtidos por Sensores Proximais foram observadas na terceira colheita (Figura 14).

Figura 14 - Correlações entre os Índices de Vegetação obtidos pela câmera multiespectral embarcada no VANT e pelos Sensores Proximais com as variáveis do pasto, referente a terceira colheita. Correlações marcadas por * foram significativas ($P < 0.05$) pelo Teste *t-student*



5. DISCUSSÃO

Conforme esperado, com o aumento das doses de nitrogênio houve incremento na massa de forragem (MF), altura (ALT) e teor de proteína bruta (PB) da forragem. Contudo, o primeiro corte ocorreu no início da primavera, ou seja, a rebrotação da planta forrageira ocorreu em um período desfavorável a seu crescimento, caracterizado por baixa precipitação e temperaturas mais baixas. Além disso, observou-se que nessa época, mesmo sob irrigação, algumas parcelas apresentaram baixa produção de forragem e áreas de solo exposta. De acordo com PONZONI (2001), os Índices de Vegetação baixos, como por exemplo NDVI < 0,4 podem estar relacionados a uma menor quantidade de clorofila presente na planta, ocorrendo menor absorção na região do visível e conseqüentemente maior reflectância. Já Borges (2015) afirma que o comportamento espectral das forrageiras no mês de setembro segue um padrão de baixa absorção na região do visível, pelos teores de nitrogênio na planta se apresentarem reduzidos devido a estação do ano (transição seca-água) e alta reflectância na região do infravermelho, já que essa região está relacionada a estrutura da planta, assim os valores dos IVs são reduzidos, podendo o NDVI ter valores abaixo de 0,4.

Nos cortes subsequentes houve um melhor desenvolvimento em todas as variáveis citadas, pois com o início da estação da primavera as condições climáticas se tornaram mais favoráveis ao desenvolvimento das plantas (Figura 5). Assim como demonstrado nos trabalhos de Villar *et al.* (2015); Walsh *et al.* (2018) e Santos *et al.* (2017), com o aumento da precipitação e também da temperatura as plantas respondem melhor às adubações, acelerando seu crescimento, aumentando sua produção, e preenchendo melhor o solo, o que pode justificar as correlações mais fortes em relação às observadas para a primeira colheita. Adotou-se para o presente trabalho que valores de correlação abaixo de 0,4 foram considerados baixos, entre 0,4 e 0,69 = moderados, 0,70 a 0,89 = altos e 0,81 a 1 = muito altos.

O padrão de resposta das variáveis analisadas (MF, altura e PB) em relação as doses de nitrogênio recebidas não foi linear, mesmo apresentando baixa exigência e sendo muito responsiva a grandes dosagens de adubação nitrogenada. Uma possível explicação para tal comportamento é que a aplicação de grandes doses de adubo nitrogenado em um período curto de tempo provavelmente impossibilitou a planta de absorver este nitrogênio e então apresentar seu melhor desenvolvimento.

Contudo, o único objetivo com as doses crescentes de N após cada colheita era gerar variação estrutural e química na planta para identificar Índices de Vegetação que apresentassem o mesmo padrão de resposta que as variáveis da *B. decumbens* (*syn. U. Urochloa*), ou seja, se os IV seriam capazes de constatar as variações na forragem. Além disso, Índices de Vegetação podem ser utilizados para identificar a o status de saúde das plantas.

Analisando o comportamento dos IVs nas diferentes resoluções espaciais, constatou-se que houve efeito na primeira colheita em todos os índices estudados. Isso se deve ao fato das parcelas possuírem nessa primeira colheita vários espaços com solo exposto, assim com resoluções espaciais maiores (valores menores do tamanho de cada *pixel*), maior será o detalhamento e a participação de *pixels* de valores reduzidos. Nas colheitas subsequentes (segunda, terceira e quarta) não foi constatado efeito significativo das resoluções espaciais sobre os IVs, pois como a parcela já estava com toda sua área coberta por forragem, não houveram *pixels* que representassem somente o solo.

Notou-se que as correlações com MF foram significativas para todos os IVs avaliados, sendo que estes valores são maiores quando se utiliza índices que não possuem bandas na região do visível, em especial a do vermelho. Isso demonstra o potencial de utilização de IVs para desenvolvimento de modelos de predição da massa de forragem em pastos de capim-braquiária.

As correlações com o teor de proteína bruta também se apresentaram positivas e moderadas, onde se destacam os IVs que utilizam a banda *Red Edge*, como o NRDE. Isso é explicado devido ao fato de que a mesma consegue penetrar mais profundamente no dossel e possui uma maior sensibilidade as características bioquímicas e físicas das plantas, trazendo melhores resultados em condições de elevada massa de forragem e teor proteico. Como visto no presente estudo, vários trabalhos citam este IV como melhor indicador de produção de biomassa e teor proteico de forrageiras, indicando que índices que usam a banda *Red Edge* possuem maiores correlações e são melhores para predizer massa de forragem, IAF e teor de nitrogênio (GOSWAMI *et al.* 2015; WALSH *et al.* 2018; FU *et al.* 2020; ALI *et al.* 2019).

Caturegli *et al.* (2016) correlacionaram o NDVI advindo do GreenSeeker com o de câmera Canon S100, em três distintas forrageiras, e obtiveram correlações significativas com teor de proteína em todos os casos, alcançando um R² acima de 0,81 nas três culturas. No presente trabalho, foi constatado que em situação de

reduzida produção de biomassa devido a fatores climáticos, o NDVI possui correlação moderada com o teor de proteína, com isso, o indicado seria a utilização de outro índice para prever esta variável.

Assim como observado por Li *et al.* (2020), houve correlação positiva, porém moderada, entre o índice SPAD com a PB na primeira colheita. Segundo Peng *et al.* (1996), fatores como espécies, climas regionais, tipo de solo manejo e fonte de adubos podem interferir nos valores, o que permite concluir que houve interferência do período da transição inverno-início da primavera.

Em geral, quando foram analisadas as correlações com todas as variáveis, os índices que não utilizam as bandas da região do visível, mas sim a banda *Red Edge*, apresentaram maiores correlações, como o NDRE, $SR_{Red\ Edge}$ e CI_{Red} , respectivamente. Isso corrobora com os resultados encontrados por Zhang *et al.* (2019), que também afirmaram sobre a maior correlação do NDRE com as características agrônomicas. Resultados semelhantes foram encontrados em trabalhos realizados com trigo, conduzidos por Walsh *et al.* (2018).

Para a segunda colheita, realizada no dia 22/10/2019, houve incremento nos valores de MF (Tabela 5), o que é explicado pelo maior efeito da estação da primavera, com elevação das temperaturas e precipitação (Figura 5), com conseqüente aumento nos Índices de Vegetação (Tabelas 6 e 7). Junto a elevação da produção de MF houve também o aumento das correlações com os IVs de todas as variáveis, onde, excetuando o *Simple Ratio*, todas as correlações foram significativas e demonstraram um aumento em relação a primeira colheita.

Assim como relatado na primeira colheita, nota-se que ao usar a banda *Red Edge* na construção dos índices, seus valores de correlação são maiores do que os vistos usando a banda do vermelho. Este padrão de resposta de maiores correlações também foi relatado por Santos *et al.* (2017), usando IVs em fases diferentes de desenvolvimento da cana de açúcar e Walsh *et al.* (2018), usando diferentes fases de desenvolvimento de trigo em três localidades distintas.

Assim, conforme diversos relatos na literatura (TANAKA *et al.* 2015; WALSH *et al.* 2018; ZHENG *et al.* 2018; FU *et al.* 2020), os índices que se utilizam da banda *Red Edge* possuem maiores correlações não somente com a massa, mas também com o conteúdo de nitrogênio foliar.

Walsh *et al.* (2018) pesquisaram índices durante dois estádios de crescimento em trigo, os IVs NDRE, $SR_{Red\ Edge}$ e $CI_{Red\ Edge}$ apresentaram boas correlações durante

todos os estádios da cultura, sendo os IVs mais indicados para determinação de nitrogênio e produção de biomassa.

Mesmo com este aumento nas correlações com todas as variáveis, quando se analisa o NDVI, a correlação com o teor de PB se mantém moderada, com um leve aumento comparado a primeira colheita. Já o índice *Simple Ratio*, que usa as mesmas bandas do índice anterior, apresentou valores negativos de correlação com o teor de proteína e muito baixos as outras variáveis, comportamento este que só ocorreu nesta colheita.

Índices que usam três bandas, como é o caso do MCTI, apresentam maiores correlações com a produção de biomassa, pois aumentando o número de bandas e assim abrangendo mais aspectos da forragem, maior será o potencial descritivo da cultura analisada. Li *et al.* (2014), relatam que foi encontrado em três anos seguidos, boas correlações entre o índice e a produção de biomassa e baixas, porém significativas correlações com o teor de nitrogênio na cultura do arroz.

Assim como apresentado na Figura 13 (segunda colheita), as correlações entre as variáveis e o MTCTI foram altas a muito altas, equiparando com o NDRE. Com isso, reforça a premissa que índices que usam a banda *Red Edge* tendem a ter maiores correlações com as variáveis analisadas, tornando-se mais indicados em todas as fases da cultura.

Outros IVs de destaque foram os que usam a banda *Green*, como o GNDVI e *CIGreen*, trazendo correlações altas a muito altas nas duas primeiras colheitas, principalmente com a produção de massa de forragem, o que ocorre devido ao pico de reflectância que a mesma possui, como citado em trabalhos como Gitelson *et al.* (2013) e Hassan *et al.* (2018).

Corroborando os valores significativos da correlação com o teor PB, Villar *et al.* (2015) observaram que o índice SPAD possui uma maior correlação com o nitrogênio foliar do que outros Índices de Vegetação, como o VARI e MCARI/OSAVI, sendo considerado um bom preditor para esta variável. De fato, observou-se forte correlação entre o índice SPAD e o teor de proteína bruta do capim-braquiária na segunda colheita (figura 15).

Analisando os dados referentes a terceira colheita, realizada no dia 12/11/2019, nota-se que a forrageira apresentou um maior desenvolvimento, o que é explicado pelo aumento na precipitação e na temperatura nos meses de outubro e novembro, que favoreceu o crescimento da forragem, como pode ser visto na Figura 5.

Com o aumento da massa de forragem ocorreu também uma elevação no valor de todos os Índices de Vegetação, destacando o *Simple Ratio*. Este IV é baseado na divisão de bandas com comportamentos opostos, onde a reflectância da banda do infravermelho continua crescendo com o aumento da planta, pois a mesma está relacionada a estrutura da planta e a reflectância da banda do vermelho não, já que a mesma pode saturar com o aumento da clorofila, ou seja, mesmo com o aumento deste pigmento não ocorre aumento da absorção.

Este aumento acentuado do índice *Simple Ratio* com o aumento da massa de forragem total, também foi observado por Viña *et al.* (2011), em situações de maiores acúmulos de matéria seca, fazendo com que esse IV possa ser usado para inferir sobre a produção de forragem, assim como o NDVI. Como visto no presente trabalho, Huang *et al.* (2015), observaram correlações fortes dos índices NDVI e SR com as variáveis: produção de biomassa acima do solo, índice de área foliar e teor de nitrogênio na planta de arroz.

Juntamente com o aumento da MF, houve aumento também das correlações entre o teor de PB e os IVs, como por exemplo o GNDVI, que de acordo com Candiag *et al.* (2015) é mais sensível a clorofila presente na planta que o NDVI, apresentando valores mais correlacionados com essa variável assim como com produção de biomassa, como visto no presente trabalho. A banda do *Green* está mais relacionada a clorofila a e b, sendo a última considerada um pigmento acessório, com isso suas correlações com PB são melhores que a banda do *Red*.

Analisando outro índice, que também utiliza da banda verde, o CI_{Green} , foi possível ter correlações muito altas com o teor de PB e com a massa de forragem, já que o mesmo também possui a banda do infravermelho, que apresenta alta relação com a estrutura das plantas. Tanaka *et al.* (2015) acrescenta que o CI_{Green} possui também altas correlações com o índice de área foliar na cultura do trigo de inverno.

Tian *et al.* (2015) discutiram em seu trabalho que mesmo em concentrações baixas de clorofila na planta, as bandas do azul e do vermelho saturam com facilidade, devido a uma maior absorção de REM, o que torna os IVs que usam essa banda menos representativos quanto aos teores de nitrogênio, como relatado também no presente trabalho, onde índices como NDVI demonstraram correlações moderadas com a PB.

Quantificando o teor de nitrogênio na planta e na folha de arroz, Zheng *et al.* (2018) concluíram que os índices $CI_{Red\ Edge}$ e GNDVI possuíam correlações fortes e

iguais, chegando a $R^2 = 0,88$, valores que corroboram os resultados obtidos neste estudo. Goswami *et al.* (2015) relataram que o GNDVI pode sofrer ação da saturação mesmo usando a banda verde, podendo não ser um IV indicado para obtenção de IAF, o que não foi observado no presente trabalho.

Hassan *et al.* (2018) concluíram que mesmo em situações de pouca ou muita irrigação, os índices NDRE, GNDVI e SR apresentaram altas correlações com IAF e teor de clorofila na cultura do trigo, assim como foi encontrado neste trabalho.

Notou-se que as correlações dos dois sensores (GreenSeeker e SPAD) se apresentaram de alta a muita alta para todas as variáveis, exceto para MF quando se usa o SPAD, assim como este sensor demonstrou valores menores de correlação quando comparado ao GreenSeeker. Isso é explicado pois este sensor está relacionado diretamente com o teor de proteína bruta das culturas e não com a produção de biomassa, como pode ser visto também no trabalho de Yokoyama *et al.* (2018), que mesmo quando houve aumento do IAF não houve incremento nos valores de SPAD.

Na última colheita, realizada no dia 03/12/2019, os índices demonstraram uma leve queda, assim como as variáveis, o que pode ser explicado devido à um corte mais severo (5 cm) após a terceira colheita, que causou um estresse, atraso no desenvolvimento da forragem e desuniformidade nas parcelas, assim como fortes chuvas entre as colheitas, levando a perdas na adubação por lixiviação.

Todos os índices apresentaram correlações significativas com a produção de MF, o que condiz com trabalho realizado por Cheng *et al.* (2017), que usando índices de diferença normalizada e índices de clorofila para determinação de biomassa no arroz encontraram valores altos e significativos para todos as variáveis.

As correlações entre os IVs e as variáveis apresentaram-se altas, com uma queda no sensor SPAD, que foi moderada. Assim como visto na pesquisa atual, em seu estudo, Maresma *et al.* (2018) compararam NDVI e SPAD em diferentes doses de adubação nitrogenada no milho *Zea mays L.*, e os valores do primeiro índice apresentaram correlações melhores que o segundo, sendo nos dois casos significativas.

Bazame *et al.* (2020) afirmaram que o uso do SPAD possui limitações em comparação ao GreenSeeker, pois como seu uso necessita de contato com a superfície foliar isso pode causar comprometimento na coleta de dados, assim como demanda um tempo superior ao outro sensor mencionado.

Diferente do que foi visto neste corte, Gabriel *et al.* (2017) relatam em seu trabalho que o NDVI possui correlação não significativa com a produção de nitrogênio do milho, mesmo usando dois meios de Sensoriamento Remoto diferentes.

Como visto nas três primeiras colheitas citadas acima, os IVs que usam na sua composição a banda *Red Edge* possuem valores mais altos de correlação, como demonstrado por Delegido *et al.* (2011), que trazem em estudos feitos com o satélite Sentinel-2 a importância do uso das bandas de Borda Vermelha para predição da produção de massa de forragem e teor de proteína.

De forma geral, observou-se que os IVs apresentaram padrão de resposta semelhante ao observado para as variáveis massa de forragem, altura e proteína bruta (Tabelas 5, 6 e 7), ou seja, houve efeito significativo da adubação ($P < 0,05$) em todos os Índices de Vegetação assim como para as variáveis do pasto. Dessa forma, os Índices de Vegetação avaliados demonstraram possuir sensibilidade as mudanças ocorridas na forragem que receberam diferentes doses de adubo, podendo ser utilizados em equações de predição da massa de forragem, altura e teor de proteína bruta do capim-braquiária.

6. CONCLUSÕES

A aerofotogrametria é uma ferramenta promissora para estimativa indireta da altura, massa de forragem e teor de proteína bruta em áreas de pastagens.

Os Índices de Vegetação NDVI, NDRE, GNDVI, CI_{Green} , $CI_{Red\ Edge}$, $SR_{Red\ Edge}$ e MTCI apresentam potencial para serem utilizados em modelos de predição de massa de forragem, altura e teor de proteína bruta em pastos de *Brachiaria decumbens* (*syn. Urochloa decumbens*) cv. Basilisk. Contudo, ressalta-se que em períodos de seca ou transição seca-águas, quando a massa de forragem é baixa, as correlações são mais fracas o que demonstra a necessidade de mais estudos para identificar Índices de Vegetação que corrijam ou minimizem essas interferências.

Índices que utilizam a banda espectral *Red Edge* em substituição a banda do vermelho visível possuem elevadas correlações com MF e teor de PB e podem melhorar o desempenho preditivo dessas variáveis, embora mais pesquisas sejam necessárias para escolha do melhor índice a ser utilizado, bem como desenvolvimento de modelos de predição acurados para pastagens tropicais.

REFERÊNCIAS

Agisoft LLC: **Agisoft Metashape Professional (2019)**. www.agisoft.ru

AGÜERA, F.; CARVAJAL, F.; PÉREZ, M. Measuring the nitrogen status of the sunflower from an unmanned aerial system and a device on the ground. In: INTERNATIONAL ARCHIVES OF THE PHOTOGRAMMETRY, REMOTE SENSING AND SPATIAL INFORMATION SCIENCES, 38., 2011, Zurich. **Anais...** Zurich: ISPRS, 2011. p. 33-37.

ALVES JUNIOR, L. R. **Análise de produtos cartográficos obtidos com câmera digital não métrica acoplada a um veículo aéreo não tripulado em áreas urbanas e rurais no estado de Goiás**. 2015. 113f. Dissertação (Mestrado em Geografia) - Universidade Federal de Goiás, Goiânia, 2015.

BAIO, F. H. R.; SILVA, S. P.; CAMOLESE, H. S.; NEVES, D. C. Financial analysis of the investment in precision agriculture techniques on Cotton crop. **Engenharia Agrícola**, v.37, n.4, p.838-847, 2017.

BERGER, R.; DA SILVA, J. A. A.; FERREIRA, R. L. C.; CANDEIRAS, A. L. B.; RUBILAR, R. Vegetation indices to estimate the leaf area index in clonal plantations of *Eucalyptus saligna* Smith. **Ciência Florestal**, v. 29, n.2, p.885-899, 2019

BORGES, K. L. C. **Dados espectrorradiométricos de campo e índices de vegetação para estimar porcentagem de cobertura vegetal verde de pastagens cultivadas**. 2015. 92p. Dissertação (Mestrado em Geociência) Universidade de Brasília, Brasília, 2015.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Portaria nº 852 - Art. 1º Criar a Comissão Brasileira de Agricultura de Precisão – CBAP. **Diário Oficial da República Federativa do Brasil, Brasília, DF**, n.184, 2012.

CATUREGLI, L.; CORNIGLIA, M.; GAETANI, H.; GROSSI, N.; MAGNI, S.; MIGLIAZZI M. Unmanned Aerial Vehicle to Estimate Nitrogen Status of Turfgrasses. **Plos One**, v.11, n.6, p.1-13, 2016.

CHENG, T.; SONG, R.; LI, D.; ZHOU, K.; ZHENG, H.; YAO, X.; TIAN, Y.; CAO, W.; ZHU, Y.; Spectroscopic Estimation of Biomass in Canopy Components of Paddy Rice Using Dry Matter and Chlorophyll Indices. **Remote Sensing**, v.9, n.4:319, 2017.

COLOMINA, I.; MOLINA, P.; Unmanned aerial systems for photogrammetry and remote sensing: a review. **Remote Sensing**, v.92, p.79-97, 2014.

DELEGIDO, J.; VERRELST, J.; ALONSO, L.; MORENO, L. Evaluation of Sentinel-2 Red-Edge Bands for Empirical Estimation of Green LAI and Chlorophyll Content. **Sensors**, v.11, n.7, p.7063-7081, 2011.

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. **Métodos para análise de alimentos, INCT**. Visconde do Rio Branco - MG. Universidade Federal de Viçosa, Departamento de Zootecnia. 214p.

ELACHI, C. **Introduction to the Physics and Techniques of Remote Sensing**. Nova York, EUA: Wiley, 1987.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. Centro Nacional de Pesquisa do Solo. **Sistema brasileiro de classificação de solos**. 2.ed. Rio de Janeiro, Embrapa Solos, 2006. 306p.

FERRAZ, J. B. S.; FELÍCIO, P. E. D. Production systems - An example from Brazil. **Meat Science**, v. 84, p.238-243, 2010.

FU, Z.; JIANG, J.; GAO, Y.; KRIENKE, B.; WANG, M.; ZHONG, K.; CAO, Q.; TIAN, Y.; ZHU, Y.; CAO, W.; LIU, X. Monitoring wheat growth and yield estimate based on unmanned aerial vehicle with multiple rotors. **Remote Sensing**, v.12 n.3:508, 2020.

GABRIEL, J. L.; ZARCO - TEJADA, P. J.; LOPEZ-HERRERA, P. J.; PEREZ - MARTIN, E.; ALONSO - AYUSO, M.; QUEMADA, M. Airborne and ground level sensors for monitoring nitrogen status in a maize crop. **Biosystems Engineering**, v.160, p.124-133, 2017.

GETZIN, S.; WIEGAN, K.; SCHOENING, E. I. Avaliação da biodiversidade em florestas usando imagens de alta resolução e veículos aéreos não tripulados. **Métodos em Ecologia e Evolução**, v.3, p.397-404, 2012.

GIROLAMO - NETO, C.; SANCHES, I. D.; NEVES, A. K.; PRUDENTE, V. H. R.; KORTING, T. S.; PICOLI, M. C. A.; ARAGÃO, L. E. O. C. Evaluation of texture characteristics for detection of bermuda grass (*Cynodon dactylon*) in sugarcane plantations. **Remote Sensing**, v.3, n.2:36, 2019.

GITELSON, A. A.; GRITZ, Y.; MERZLYAK, M. N. Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive assessment of chlorophyll in upper leaves of plants. **Journal of Plant Physiology**, v.160, p.271-282, 2003.

GOSWAMI, S.; GAMON, J.; VARGAS, S.; TWEEDIE, C. NDVI, Biomass and Leaf Area Index (IAF) relationships for six major plant species in Barrow, Alasca. **PeerJ PrePrints**, 3: e913v1 <https://doi.org/10.7287/peerj.preprints.913v1>.

HASSAN, M. A.; YANG, M.; RASHEED, A.; JIN, X.; XIA, X.; XIAO, Y.; HE, Z.; Multispectral indices of the time series of unmanned aerial vehicle images reveal senescence rate in wheat. **Remote Sensing**, v.10, n.6:809, 2018.

HATFIELD, J.L.; PRUEGER, J.H. Value of using different vegetative indices to quantify the characteristics of agricultural crops at different stages of growth under different management practices. **Remote Sensing**, v.2, p.562-578, 2010.

HUANG, S.; MIAO, Y.; ZHAO, G.; YUAN, F.; MA, X.; TAN, C.; YU, W.; LENZ-WIEDEMANN, V. I.; RASCHER, U.; BARETH, G. Station diagnosis based on satellite remote sensing of rice nitrogen status in northeastern China. **Remote Sensing**, v.7, n.8, p.10646-10667, 2015.

IBGE, INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo Agropecuário: Resultados definitivos: Tabelas**. 2017

JORGE, L. A. C.; INAMASU, R. Y. Uso de Veículos Aéreos Não Tripulados (VANT) em Agricultura de Precisão. In: BERNARDI et al. (Ed.) **Agricultura de precisão: resultados de um novo olhar**. Brasília: EMBRAPA, 2014. p.109-134

LI, F.; MISTELE, B.; HU, Y.; CHEN, X.; SCHMINDHALTER, U. Reflectance estimation of canopy nitrogen content in winter wheat using optimized hyperspectral spectral indices and partial least squares regression. **European of Journal Agronomy**, v.52 p.198-209, 2014.

LI, H.; ZHANG, Y.; LEI, Y.; ANTONIUK, V.; HU, C. Evaluation of different non-destructive estimation methods for the nitrogen status of winter wheat (*Triticum aestivum* L.) based on the canopy spectrum. **Remote Sensing**, v.12, n.1:95, 2020.

LI, Z.; JIN, X.; YANG, G.; DRUMMOND, J.; YANG, H.; CLARK, B.; LI, Z.; ZHAO, C. Remote sensing of leaf and canopy nitrogen status in winter wheat (*Triticum aestivum* L.) based on the N-PROSAIL model. **Remote Sensing**, v.10, n.1463, 2018.

LIMA - CUETO, F. J.; BLANCO - SEPULVEDA, R.; GÓMEZ - MORENO, M. L.; GALACHO - JIMENEZ, F. B. Using Vegetation Indices and a UAV Imaging Platform to Quantify the Density of Vegetation Ground Cover in Olive Groves (*Olea Europaea* L.) in Southern Spain. **Remote Sensing**, v.11, n.2564, 2019.

LINHARES, M. M. DE A. **Uso de Veículo Aéreo Não Tripulado na determinação de Índice de Vegetação em área de pastagem em Nova Mutum-MT**. 2016. 119f. Dissertação (Mestrado em Geografia) - Universidade Federal de Goiás, Goiânia, 2016.

LIU, C.; FANG, Z.; CHEN, Z.; ZHOU, L.; YUE, X.; WANG, Z.; WANG, C.; MIAO, Y. Nutritional diagnosis of winter wheat nitrogen based on ASD Field Spec3. **Transactions of the Chinese Society of Agricultural Engineering**, v.19, n.34, p.162-169, 2018.

LÓPEZ, J. J.; MULERO - PÁZMÁNY, M. Drones for Conservation in Protected Areas: Present and Future. **Drones**, v.3, n.10, 2019.

MAGNEY, T.S; EITEL, J.U.H.; VIERLING, L.A. Mapping wheat nitrogen uptake from RapidEye vegetation indices. **Precision Agriculture**, v.18, n.429, 2017.

MARESMA, A.; ARIZA, M.; MATÍNEZ, E.; LLOVERAS, J.; MARTÍNEZ CASASNOVAS, J. A. Analysis of Vegetation Indices to Determine Nitrogen Application and Yield Prediction in Maize (*Zea mays* L.) from a Standard UAV Service. **Remote Sensing**, v.10, n.3:368, 2018.

MENESES, P. R.; ALMEIDA, T.; ROSA, A. N. C. S.; SANO, E. E.; SOUZA, E; B.; BAPTISTA, G. M. M.; BRITES, R. S. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília, p.147-150, 2012a.

MENESES, P. R.; ALMEIDA, T.; ROSA, A. N. C. S.; SANO, E. E.; SOUZA, E; B.; BAPTISTA, G. M. M.; BRITES, R. S. **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília, p.21-23, 2012b.

MOECKEL, T.; DAYANANDA, S.; NIDAMANURI, R.R.; NAUTIYAL, S.; HANUMAIAH, N.; BUERKERT, A.; Wachendorf, M. Estimation of Vegetable Crop Parameter by Multi-temporal UAV-Borne Images. **Remote Sensing**, v.10, n.805, 2018.

MONOSTORI, I.; ÁRENDÁS, T.; HOFFMAN, B.; GALIBA, G.; GIERCZIK, K.; SZIRA, F.; VÁGÚJFALVI, A. The relationship between SPAD value and grain yield can be affected by the cultivar, environment and nitrogen content of the soil in wheat. **Euphytica**, v.211, p.103-112, 2016.

MORENO - GARCIA, B.; CASTERAD, M. A.; GUILLÉN, M.; QUÍLEZ, D. Agronomic and economic potential of the vegetation indices of the N rice recommendations under organic and mineral fertilization in the Mediterranean regions. **Remote Sensing**, v.10, n.12:1908, 2018.

MULLA, D. J. Twenty-five years of remote sensing in precision agriculture: Key advances and remaining knowledge gaps. **Biosystems Engineering**, v.114, n.4, p. 358-371, 2012.

NEWTON, A. C., HILL, R. A., ECHEVERRI'A, C., GOLICHER, D., REY BENAYAS, J. M., CAYUELA, L. & HINSLEY, S. Remote sensing and the future of landscape ecology. **Progress in Physical Geography**, v.33, p.528-546, 2009.

NEX, F.; REMONDINO, F.; UAV for 3D mapping application: a review. **Applied Geomatics**, v.6, p.1-15, 2014.

PACIULLO, D. S. C.; GOMIDE, C. A. M.; LEITE, J. L. B.; RESENDE, H. Tecnologia e custo de produção de *Brachiaria decumbens* para o uso sob pastejo. **CIRCULAR TECNICA**. EMBRAPA. 2016

PANEQUE - GALVEZ, J.; MCCALL, M. K.; NAPOLETANO, B. M.; WICH S. A.; KOH, L. P. Small Drones for Community-Based Forest Monitoring: An Assessment of Their Feasibility and Potential in Tropical Areas. **Florestas**, v.5, p.1481–1507, 2014.

PENG, S.; GARCIA, F.V.; LAZA, R. C.; SANICO, A. L.; VISPERAS, R. M.; CASSMAN, K. G. Increased N-use efficiency using a chlorophyll meter on high-yielding irrigated rice. **Field Crops Research**, v.47, p.243–252, 1996.

PÖLÖNEN, I.; SAARI, H.; KAIVOSOJA, J.; HONKAVAARA, E.; PESONEN, L. Estimates of biomass and nitrogen content based on hyperspectral image from light UAV. **Proc. SPIE**, v.8887, 2013.

PONZONI, F. J. **Sensoriamento remoto no estudo da vegetação: Diagnosticando a mata atlântica**. Ministério da ciência de tecnologia Instituto Nacional de Pesquisas Espaciais. São José dos Campos, 2002.

PONZONI, F. J.; SHIMABUKURO, Y.E. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos: Parêntese, 127p., 2001.

QGIS Development Team (2019). QGIS Geographic Information System. Version 3.2. **Open Source Geospatial Foundation Project**. <http://qgis.osgeo.org>

QUEMADA, M.; GABRIEL, J. L.; ZARCO - TEJADA, P. Airborne hyperspectral images and ground-level optical sensors as assessment tools for maize nitrogen fertilization. **Remote Sensing**, v.6, n.4, p.2940-2962, 2014.

RIBEIRO, A. C.; GUIMARAES, P. T. G.; ALVAREZ V. V. H. (Ed.). **Recomendação para o uso de corretivos e fertilizantes em Minas Gerais: 5º Aproximação**. Viçosa: Comissão de Fertilidade do Solo do Estado de Minas Gerais, 1999. 359p.

SANTOS, G. O.; ROSALEN, D.; FARIA, R. T. Use of active optical sensor in the characteristics analysis of the fertigated *brachiaria* with treated sewage. **Engenharia Agrícola**, v.37, n.6, p.1213-1221, 2017.

SHOU, L.; JIA, L.; CUI, Z.; CHEN, X.; ZHANG, F. Using high-resolution satellite imagery to assess the nitrogen status of winter wheat. **Journal of Plant Nutrition**, v.30, p.1669-1690, 2017.

SONG, X.; FENG, W.; HE, L.; XU, D.; ZHANG, H. Y.; LI, X.; WANG, Z. J.; COBURN, C. A.; WANG, C. Y.; GUO, T. C. Examining view angle effects on leaf N estimation in wheat using field reflectance spectroscopy. **Journal of Photogrammetry and Remote Sensing**, v.122, p.57-67, 2016.

SOUZA, C. H. W.; LAMPARELLI, R. A. C.; JUSTINA, D. D. D.; ROCHA, J. V.; Estudo da Banda *Red Edge* do satélite Rapideye na discriminação da cobertura vegetal. In: XVII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO - SBSR, 2015, João Pessoa. **Anais...** João Pessoa: INPE, 2015. p.3612-3618.

TANAKA, S.; KAMAWAMURA, K.; MAKI, M.; MURAMOTO, Y.; YOSHIDA, K.; AKIYAMA, T.; Spectral index for quantifying the index of leaf area of winter wheat by hyperspectral field measurements: a case study in Gifu Prefecture, Central Japan. **Remote Sensing**, v.7 n.5, p.5329-5346, 2015.

TIAN, Y. C.; YAO, X.; YANG, J.; CAO, W. X.; HANNAWAY, D. B.; ZHU, Y.; Assessing newly developed and published vegetation indices for estimating rice leaf nitrogen concentration with ground- and space-based hyperspectral reflectance. **Remote Sensing**, v.7, p.5329-5346, 2015.

TONG, X.; DUAN, L.; LIU, T.; SINGH, V. P. Uso combinado de índices de vegetação hiperespectral in situ para estimar a biomassa da pastagem no pico do período produtivo para decisão de colheita. **Precision Agriculture**, v.20, p.477–495, 2019.

TURNER, W.; SPECTOR, S.; GARDINER, N.; FLADELAND, M.; STERLING, E.; STEININGER, M. Remote sensing for biodiversity science and conservation. **Trends in Ecology e Evolution**, v.18, p.306–314, 2003.

VIAN, A. L.; BREDEMEIER, C.; SILVA, P. R. F.; SANTI, A. L.; GIORDANO, C. P. S.; SANTOS, F. L. Limites críticos de NDVI para estimativa do potencial produtivo do milho. **Revista Brasileira de Milho e Sorgo**, v.17, n.1, p.91-100, 2018.

VILLAR, F. M. M.; PINTO, F. A. C.; FONSECA, D. M.; QUEIROZ, D. M.; ALCÂNTARA, G. R. Sufficiency Index for defining nitrogen recommendation in Brachiaria grass pasture. **Bioscience Journal**, v.31, n.5, p.1333-1340, 2015.

VIÑA, A.; GITELSON, A. A.; NGUY-ROBERTSON, A. L.; PENG, Y. Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. **Remote Sensing of Environment**, v.115, n.12, p.3468-3478, 2011.

WALSH, S.O.; SHAFIAN, S.M.; MARSHALL, J.; JACKSON, C.R.; MCCLINTICK-CHESS, J.M.; BLANSCET, S.; SWOBODA, K.; THOMPSON, C.M.; BELMONT, K. E.L.; WALSH, W. Avaliação dos índices de vegetação baseados em UAV para estimativa de concentração de nitrogênio no trigo da primavera. **Avanços em Sensoriamento Remoto**, n.7, p.71-90, 2018.

WANG, L.; CHANG, Q.; LI, F.; YAN, L.; HUANG, Y.; WANG, Q.; LUO, L. Effects of the development of the growth stage in the forecast models of the leaf area index of paddy rice. **Remote Sensing**, v.11, n.3:361, 2019.

WATTS, A. C., PERRY, J. H., SMITH, S. E., BURGESS, M. A., WILKINSON, B. E., SZANTOI, Z. IFJU, P. G.; PERCIVAL, H. F. Small unmanned aircraft systems for low-altitude aerial surveys. **Journal of Wildlife Management**, v.74, p.1614-1619, 2010.

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

YOKOYAMA, A. H.; RIBEIRO, R. H.; JUNIOR, A. A. B.; FRANCHINI, J. C.; DEBIASI, H.; ZUCARELI, C.; Leaf area index and SPAD of soybean after offseason crops and nitrogen fertilization, and their relation to grain yield. **Revista de Ciências Agrárias**, v.41, n.4, p.953-962, 2018.

YU, K.; LI, F.; GNYP, M. L.; MIAO, Y.; BARETH, G.; CHEN, X. Remotely detecting canopy nitrogen concentration and uptake of paddy rice in the Northeast China Plain. **Journal of Photogrammetry and Remote Sensing** v.78, p.102-115, 2013.

ZHANG, K.; G. E. X.; SHEN, P.; LI, W.; LIU, X.; CAO, Y. Z.; CAO, W.; TIAN, Y.; Predicting the yield of rice grains based on dynamic changes in vegetation indexes in the initial and average growth stages. **Remote Sensing**, v.11, n.4:387, 2019.

ZHENG, H.; CHENG, T.; LI, D.; ZHOU, X.; YAO, X.; TIAN, CAO, W.; ZHU, Y.; Evaluation of RGB, colored infrared and multispectral images acquired from unmanned aerial systems to estimate nitrogen accumulation in rice **Remote Sensing**, v.10, n.6:824, 2018.