



**ESTIMATIVA DA BIOMASSA DE GRAMÍNEAS DO GÊNERO *Urochloa*  
UTILIZANDO SENSOR RGB ACOPLADO EM AERONAVE  
REMOTAMENTE PILOTADA**

Bárbara Louise Pacheco Ramos

2024



**UNIVERSIDADE ESTADUAL DO SUDOESTE DA BAHIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA**

**ESTIMATIVA DA BIOMASSA DE GRAMÍNEAS DO GÊNERO *Urochloa*  
UTILIZANDO SENSOR RGB ACOPLADO EM AERONAVE  
REMOTAMENTE PILOTADA**

Autora: MSc. Bárbara Louise Pacheco Ramos  
Orientador: Prof. Dr. Márcio dos Santos Pedreira

ITAPETINGA  
BAHIA – BRASIL  
Fevereiro de 2024

**BÁRBARA LOUISE PACHECO RAMOS**

**ESTIMATIVA DA BIOMASSA DE GRAMÍNEAS DO GÊNERO  
*Urochloa* UTILIZANDO SENSOR RGB ACOPLADO EM  
AERONAVE REMOTAMENTE PILOTADA**

Tese apresentada como parte das exigências para obtenção do título de DOUTORA EM ZOOTECNIA, no Programa de Pós-Graduação em Zootecnia da Universidade Estadual do Sudoeste da Bahia.

Orientador: Prof. Dr. Márcio dos Santos Pedreira

Co-orientador: Prof. Dr. Odair Lacerda Lemos

ITAPETINGA  
BAHIA – BRASIL

Fevereiro de 2024

633.2 Ramos, Bárbara Louise Pacheco.  
R141e Estimativa da biomassa de gramíneas do gênero *Urochloa* utilizando sensor RGB acoplado em aeronave remotamente pilotada. / Bárbara Louise Pacheco Ramos. – Itapetinga-BA: UESB, 2024.

77p.

Tese apresentada como parte das exigências para obtenção do título de DOUTORA EM ZOOTECNIA, no Programa de Pós-Graduação em Zootecnia da Universidade Estadual do Sudoeste da Bahia. Sob a orientação do Prof. D. Sc. Márcio dos Santos Pedreira e coorientação de Prof. D. Sc. Odair Lacerda Lemos.

1. Gramíneas *Urochloa* – Avaliação de pastagem. 2. Gramíneas tropicais - Sensor RGB - Avaliação. 3. Drone - Sensoriamento remoto em pastagens. I. Universidade Estadual do Sudoeste da Bahia - Programa de Pós-Graduação de Doutorado em Zootecnia, *Campus* de Itapetinga. II. Pedreira, Márcio dos Santos. III. Lemos, Odair Lacerda. IV. Título.

**CDD(21): 633.2**

Catálogo na Fonte:

Adalice Gustavo da Silva – CRB 535-5ª Região  
Bibliotecária – UESB – Campus de Itapetinga-BA

Índice Sistemático para desdobramentos por Assunto:

1. Pastagens - Avaliação - Sensoriamento remoto - Sensor RGB

## DECLARAÇÃO DE APROVAÇÃO

**Título:** “Estimativa da biomassa de gramíneas do gênero *Urochloa* utilizando sensor rgb acoplado em aeronave remotamente pilotada”

**Autora:** Bárbara Louise Pacheco Ramos

**Orientador:** Prof. Dr. Márcio dos Santos Pedreira

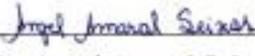
**Coorientador:** Prof. Dr. Odair Lacerda Lemos

Aprovada como parte das exigências para obtenção do Título de DOUTORA EM ZOOTECNIA, ÁREA DE CONCENTRAÇÃO PRODUÇÃO DE RUMINANTES, pela Banca Examinadora:

  
Prof. Dr. Márcio dos Santos Pedreira (Orientador) - UESB

  
Prof. Dr. Leandro Gonçalves dos Santos - IF Baiano

  
Prof. Dr. Carlos Alberto Alves de Oliveira Filho – Pós-Doutorando PPZ/UESB

  
Prof. Dr. Angel Amaral Seixas - UESB

  
Prof. Dr. Daniel Lucas Santos Dias - UEFS

Data de realização: 23 de fevereiro de 2024.

À minha MÃE e meu PAI,  
pelo AMOR e FORÇA transmitida  
durante toda minha vida, especialmente,  
nessa etapa.

Aos meus irmãos,  
por ABRAÇAR e INCENTIVAR  
todos os meus projetos.

Aos amigos,  
pelo APOIO e COLABORAÇÃO.

DEDICO.

## AGRADECIMENTOS

A Deus pelo dom da vida, proteção e sabedoria. Por ser minha fortaleza e permitir a realização de sonhos. GRATIDÃO.

Aos meus pais, Galdino e Orleide, pelo amor, compreensão, dedicação e orações diárias.

Aos meus irmãos, Michael e Patrick, pelo amor, companheirismo e incentivo.

A minha sobrinha e afilhada Clarice, por transmitir pureza e alegria.

Aos Páias, amigos/irmãos que a UESB concedeu, por todos os momentos compartilhados e apoio de sempre. Em especial, a amiga Luiza Gigante, pela paciência e parceria durante toda a jornada, desde a graduação até o presente momento. MUITO OBRIGADA.

Aos amigos/integrantes do GPAS-LNA pela contribuição excepcional em todas as fases da pesquisa e por estarem sempre à disposição a colaborar. OBRIGADA.

Aos meus familiares e amigos, pelo apoio durante toda essa trajetória.

Ao Prof. Márcio Pedreira, obrigada, pela orientação e suporte, desde o mestrado até o presente momento.

Ao Prof. Odair Lemos, gratidão por todos os ensinamentos, profissionais e de vida, e pelo apoio de sempre.

Aos funcionários, em especial, Daniel e Almir pela ajuda durante a condução do experimento em campo.

A Universidade Estadual do Sudoeste da Bahia (UESB), que desde 2012, vem proporcionando-me a realização profissional (graduação, mestrado e doutorado), de maneira excepcional. Sinto-me honrada e grata.

Ao Programa de Pós-Graduação em Zootecnia (PPZ) por dispor oportunidade de ensino e ser difusor de conhecimentos.

A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), por conceder o financiamento dos estudos.

## BIOGRAFIA

BÁRBARA LOUISE PACHECO RAMOS, filha de Galdino da Silva Ramos e Orleide Pacheco Gomes Ramos, nasceu em 02 de março de 1993, na cidade de Poções, Bahia. Em 2010, concluiu o Ensino Médio no Colégio Estadual Dr. Roberto Santos, município de Poções, Bahia, e em outubro de 2012, ingressou o curso de Engenharia Agrônômica na Universidade Estadual do Sudoeste da Bahia, por meio da Lei de Cotas (Lei 12.711, de 2012), finalizando-o em dezembro de 2017. Aprovada em novembro de 2017 na seleção de mestrado do Programa de Pós-graduação em Zootecnia, na Universidade Estadual do Sudoeste da Bahia – UESB, ingressou em março de 2018, sob a orientação do Professor Dr. Márcio dos Santos Pedreira, na área de Forragicultura e Pastagens, defendendo a dissertação em fevereiro de 2020, e obtendo o título de mestre. Aprovada na seleção de doutorado do Programa de Pós-graduação em Zootecnia, na Universidade Estadual do Sudoeste da Bahia – UESB em novembro de 2019, ingressou em março de 2020 no curso de Pós-graduação em Zootecnia a nível de Doutorado, na linha de pesquisa Forragicultura e Pastagens, sob orientação do Professor Dr. Márcio dos Santos Pedreira. Em abril de 2023, submeteu à banca a tese no exame de qualificação, como parte da exigência para obtenção do título de Doutora em Zootecnia, estando aprovada. Em fevereiro de 2024 apresenta e defende a tese aos membros da banca para a obtenção do título de Doutora em Zootecnia, conquistando a aprovação.

## SUMÁRIO

	Página
LISTA DE FIGURAS.....	vi
LISTA DE TABELAS.....	vii
RESUMO.....	viii
ABSTRACT.....	ix
I – REFERENCIAL TEÓRICO .....	1
1. Introdução.....	1
2. Pastagens brasileiras.....	2
3. Gramíneas do gênero <i>Urochloa</i> .....	4
4. Pastagens e seus nutrientes .....	6
5. Fertilização em pastagens .....	8
6. Métodos de avaliação das pastagens .....	10
7. Sensoriamento remoto em pastagens .....	11
8. Referências bibliográficas.....	14
II – OBJETIVO.....	25
2.1 Objetivo Geral.....	25
2.2 Objetivos Específicos.....	25
MATERIAL E MÉTODOS.....	27
RESULTADOS.....	39
DISCUSSÃO.....	49
CONCLUSÃO .....	57
REFERÊNCIAS BIBLIOGRÁFICAS.....	58

## LISTA DE FIGURAS

	Página
<b>Figura 1.</b> Precipitação pluviométrica, temperatura mínima (T min), temperatura máxima (T max) e temperatura média (T med) de dezembro de 2021 a janeiro de 2023 .....	27
<b>Figura 2.</b> Nebulosidade (na escala, 0 a 10, onde 0 não tem nuvens e 10 totalidade encoberta) e insolação (quantidade de horas que o disco solar e visível) de dezembro de 2021 a janeiro de 2023.....	27
<b>Figura 3.</b> Composição granulométrica do solo.....	28
<b>Figura 4.</b> Croqui da área experimental, representação da distribuição dos tratamentos nos blocos.....	29
<b>Figura 5.</b> Ponto de controle (a), equipamento RTK (b), mensuração do ponto de controle (c) .....	31
<b>Figura 6.</b> Detalhamento do equipamento utilizado .....	31
<b>Figura 7.</b> Etapas da avaliação da massa de forragem: corte, pesagem, homogeneização e separação das alíquotas .....	33
<b>Figura 8.</b> Pontos geográficos ligados nos vértices para a delimitação de cada parcela experimental .....	34
<b>Figura 9.</b> Correlações de Pearson entre as variáveis do pasto e os índices de vegetação, do período seco a 20 e 10 metros de altura do voo .....	44
<b>Figura 10.</b> Correlações de Pearson entre as variáveis do pasto e os índices de vegetação, do período chuvoso a 20 e 100 metros de altura voo.....	45

## LISTA DE TABELAS

	Página
<b>Tabela 1.</b> Análise química do solo .....	28
<b>Tabela 2.</b> Características dos produtos gerados a partir das configurações estabelecidas de voo.....	32
<b>Tabela 3.</b> Produtividade da massa seca forrageira total e dos componentes morfológicos de gramíneas do gênero <i>Urochloa</i> .	39
<b>Tabela 4.</b> Composição morfológica da massa verde, características estruturais e eficiência do uso de água de gramíneas do gênero <i>Urochloa</i> .....	40
<b>Tabela 5.</b> Teor de matéria seca, matéria mineral e proteína bruta de gramíneas do gênero <i>Urochloa</i> .....	41
<b>Tabela 6.</b> Produtividade da massa seca forrageira total e dos componentes morfológicos dos protocolos de manejo de pastagem .....	42
<b>Tabela 7.</b> Composição morfológica da massa verde dos protocolos de manejo da pastagem .....	42
<b>Tabela 8.</b> Composição dos protocolos de manejo da pastagem.....	43
<b>Tabela 9.</b> Participação dos índices nos modelos de regressão linear obtido nos diferentes períodos e altura de voo .....	46
<b>Tabela 10.</b> Modelos preditivos das variáveis do pasto e métricas de validação dos modelos gerados por sensor RGB .....	47

## RESUMO

RAMOS, Bárbara Louise Pacheco. **Estimativa da biomassa de gramíneas do gênero *Urochloa* utilizando sensor RGB acoplado em aeronave remotamente pilotada.** Itapetinga, BA: UESB, 2024. 74 p. Tese (Doutorado em Zootecnia, Área de Concentração em Produção de Ruminantes).\*

O manejo visa assegurar a produtividade e a sustentabilidade da produção animal no pasto. Para tal, a avaliação precisa da quantidade e qualidade da forragem desempenha um papel crucial, no entanto, essa prática é limitada a depender do método utilizado. Nesse contexto, o objetivo da pesquisa foi verificar o potencial correlativo dos índices gerados a partir do sensor RGB com as variáveis do pasto (quantidade e qualidade). Foram avaliadas quatro gramíneas do gênero *Urochloa* (*U. decumbens* cv. Basilisk, *U. brizantha* cv. Braúna, cv. BRS Paiaguás e *U. híbrida* cv. Camello), sob protocolos de fertilização (fertilizante convencional, fertilizante de liberação controlada e controle), distribuídas em cinco blocos ao acaso. Os voos com a ARP (aeronave remotamente pilotada) e uma câmera RGB, foram realizados momentos antes do corte amostral, quando as gramíneas atingiram a altura de manejo pré-pastejo. As imagens obtidas foram alinhadas utilizando o software Agisoft Photoscan e processadas para a extração dos IVs, sendo eles: GLI (Green Leaf Index), ExG (Excess Green) e MPRI (Modified Photochemical Reflectance Index) e o índice vertical MDV (Modelo Digital de Vegetação). Após o voo, as amostras foram posteriormente pesadas e processadas para a análise morfológica e bromatológica. Os dados de produtividade e qualidade do pasto foram submetidos a análise estatística, submetidas ao teste de Tukey a 5% de significância. Os dados dos índices foram organizados por altura de voo (20 e 100 m) e período (chuvoso e seco). Na construção dos modelos preditivos foram utilizados 70% dos dados, dos quais, os demais 30% foram usados na etapa de validação. Esses modelos preditivos foram avaliados por métricas de avaliação da regressão. As cultivares Braúna e Camello apresentaram as maiores produções de massa seca total. No que diz respeito à produção de massa seca de folha, as cultivares Braúna e BRS Paiaguás alcançaram as maiores produções, registrando 1197 kg.ha<sup>-1</sup> e 1064 kg.ha<sup>-1</sup>, respectivamente. Ressalta-se que a Paiaguás se destaca pela composição de folhas verdes (65 g/kg) e pela relação folha/colmo (2,4). A cultivar Braúna apresentou a maior densidade de perfilhos por área (1212 perfilho.m<sup>2</sup>). A aplicação de fertilizantes não influenciou a produtividade das gramíneas, apenas densidade de perfilhos e teor de proteína bruta. Em relação aos modelos preditivos, o estudo registra R<sup>2</sup> de 0,60 para produtividade de massa de forragem e 0,79 para o teor de proteína bruta. O MPRI e o MDV correlacionaram satisfatoriamente com as variáveis do pasto, desta forma, os índices obtidos do sensor RGB tem aptidão para estimar a massa forrageira, o teor de matéria seca e proteína bruta de gramíneas forrageiras.

**Palavras-chave:** ARP, drone, gramíneas tropicais, índices de vegetação, massa de forragem.

---

\*Orientador: Márcio dos Santos Pedreira, Dr. UESB e Co-orientador: Odair Lacerda Lemos, Dr. UESB.

## ABSTRACT

Management aims to ensure the productivity and sustainability of animal production on pasture. To this end, accurate assessment of forage quantity and quality plays a crucial role, however, this practice is limited depending on the method used. In this context, the objective of the research was to verify the correlative potential of the indices generated from the RGB sensor with the pasture variables (quantity and quality). Four grasses of the genus *Urochloa* (*U. decumbens* cv. Basilisk, *U. brizantha* cv. Braúna, cv. BRS Paiaguás and *U. hybrid* cv. Camello) were evaluated under fertilization protocols (conventional fertilizer, controlled release fertilizer and control), distributed into five random blocks. The flights with the ARP (remotely piloted aircraft) and an RGB camera were carried out moments before the sample cut, when the grasses reached the pre-grazing management height. The images obtained were aligned using the Agisoft Photoscan software and processed to extract the IVs, namely: GLI (Green Leaf Index), ExG (Excess Green) and MPRI (Modified Photochemical Reflectance Index) and the vertical index MDV (Digital Model of Vegetation). After the flight, the samples were subsequently weighed and processed for morphological and bromatological analysis. The pasture productivity and quality data were subjected to statistical analysis, submitted to the Tukey test at 5% significance. The index data were organized by flight height (20 and 100 m) and period (rainy and dry). 70% of the data were used in the construction of the predictive models, of which the remaining 30% were used in the validation stage. These predictive models were evaluated using regression evaluation metrics. The Braúna and Camello cultivars presented the highest total dry mass production. With regard to dry leaf mass production, the Braúna and BRS Paiaguás cultivars achieved the highest productions, recording 1197 kg.ha<sup>-1</sup> and 1064 kg.ha<sup>-1</sup>, respectively. It is noteworthy that Paiaguás stands out for its composition of green leaves (65 g/kg) and the leaf/stalk ratio (2.4). The Braúna cultivar had the highest tiller density per area (1212 tillers.m<sup>2</sup>). The application of fertilizers did not influence grass productivity, only tiller density and crude protein content. Regarding predictive models, the study records R<sup>2</sup> of 0.60 for forage mass productivity and 0.79 for crude protein content. The MPRI and MDV correlated satisfactorily with pasture decay, thus, the indices obtained from the RGB sensor are capable of estimating forage mass, dry matter and crude protein content of forage grasses.

**Key-words:** ARP, drone, forage mass, vegetation indices, tropical grasses

## I – REFERENCIAL TEÓRICO

### 1. Introdução

A agropecuária brasileira constitui um importante setor econômico, contribuindo com cerca de 24,8% para o PIB nacional (Cepea, 2023). O Brasil é o terceiro maior produtor mundial de leite e o segundo maior produtor de carne bovina (FAO, 2022). A Associação Brasileira das Indústrias Exportadoras de Carne (Abiec, 2022), relatou que em 2021, a cadeia produtiva da pecuária de corte movimentou o setor em R\$ 913,1 bilhões, abatendo cerca de 39,14 milhões de cabeças bovinas.

Segundo a Embrapa (2022), 95% da carne bovina produzida no Brasil é alicerçada na alimentação a pasto, uma vez que, a produção animal sob pastejo é a forma mais barata de alimentação animal, concedendo maior competitividade agropecuária no cenário mundial. Do mesmo modo, a cadeia leiteira observa a produção a pasto como excelente forma de nutrir e reduzir os custos de produção, principalmente aqueles relacionados a alimentação.

Logo, os pastos são excelentes fontes para melhorar o desempenho produtivo da cadeia pecuária, quando bem manejados (Santos & Martuscello, 2022), havendo reposição de nutrientes e respeitando a capacidade de suporte, esses sistemas contribuem para elevar a competitividade brasileira ao otimizar a produção de forragem.

A otimização ocorre quando há o conhecimento sobre as características ecofisiológicas das gramíneas, das exigências em fertilidade do solo e do manejo do pasto na qual está inserida (Silva et al., 2015), tornando-se a produção animal a pasto cada vez mais potente em desenvolver produtiva e sustentavelmente.

Dentre as técnicas empregadas no manejo da pastagem, a determinação da massa de forragem (MF) é um ponto chave para o alcance da produtividade nesse sistema, podendo ser mensurada por métodos diretos e estimada pelos métodos indiretos. O método direto é o mais comumente utilizado (corte e pesagem de amostras) (Suyama et al., 2007), entretanto, devido suas limitações de baixa representatividade temporal e

espacial, em locais remotos e de difícil acesso ficam prejudicados (Wanchendorf et al., 2017).

Assim, os métodos não destrutivos, denominados métodos indiretos, pretendem atuar nos limites do método direto, melhorando a forma de coleta das informações da massa forrageira. Dentre esses métodos indiretos, o sensoriamento remoto (SM), vem a cada ano tornando-se uma ferramenta promissora para estimar a produtividade das plantas forrageiras (Morais et al., 2018), e compreender sua empregabilidade sob os pontos fortes e fracos dos sensores remotos são essenciais para a seleção de procedimentos adequados, a fim de garantir um instrumento capaz de estimar a quantidade e qualidade da biomassa forrageira.

## **2. Pastagens brasileiras**

As pastagens representam um dos maiores ecossistemas no Brasil, e dispõem de uma área total de 153,8 milhões de hectares (Athenagro, 2022), representando 70,6% da área territorial destinada à agropecuária brasileira. Entretanto, a taxa de lotação brasileira de 1,02 UA/ha (ABIEC, 2023), apresenta índice inferior a países como, Holanda (2,67 UA/ha), Irlanda (1,91 Ua/ha) e Nova Zelândia (1,26 UA/ha) (FAO, 2019).

As características qualitativas e quantitativas dessas pastagens interferem diretamente na expressão desses baixos índices, visto que, 52% dessas áreas de pastagens apresenta algum estágio de degradação (Embrapa, 2022), por serem manejadas inadequadamente, tanto pelo excesso de animais por área, quanto pela falta manutenção da biomassa vegetal, por meio do manejo do pastejo e ausência de reposição de nutrientes via solo.

Desta maneira, a degradação de pastagem envolve a perda gradativa da produção vegetal (kg/ha), conseqüentemente, da produtividade animal (UA/ha) (Mota Junior, 2020). Esse declínio na produtividade do pasto avança ao longo do tempo, podendo ser consequência de uma degradação agrícola (excesso de plantas daninhas) e/ou degradação biológica (deterioração do solo) (Dias-Filho, 2017).

Outro fator que pode causar a degradação das pastagens é a introdução no sistema produtivo de uma espécie forrageira inadequada, associada a incorreta formação e manutenção da pastagem, com manejo do pastejo e da pastagem inapropriadas

(Rodrigues, 2010). Logo, o conhecimento sobre as características morfológicas, fisiológicas, nutricionais e produtivas das gramíneas forrageiras, pretende evitar a degradação e assegurar uma produção econômica e sustentável.

As condições edafoclimáticas do Brasil favorecem o desenvolvimento das gramíneas forrageiras tropicais, com destaque para os gêneros *Urochloa*, *Megarthrusus* e *Pennisetum*. O país abriga uma rica diversidade dessas plantas, com aproximadamente 170 gêneros e 1500 espécies catalogadas (Fonseca & Martuscello, 2022).

Das áreas de pastagens no Brasil, 80% são dominadas pelo gênero *Urochloa*, também conhecido como *Brachiaria* (Embrapa, 2022). Destas, aproximadamente 51 milhões de hectares são ocupados pela *U. brizantha* cv. Marandu. É crucial garantir a oferta adequada de nutrientes essenciais para o crescimento, desenvolvimento e sobrevivência dessas plantas (Santos & Fonseca, 2016), impulsionando seu potencial produtivo e fortalecendo a competitividade da pecuária brasileira.

Segundo Valle (1991), a *Urochloa decumbens* foi a primeira espécie do gênero a ser introduzida no País em 1952, importando sementes da *Urochloa ruziziensis* e *Urochloa brizantha* em 1965. Foi observado a partir de 1970, um aumento nas áreas de pastagens cultivadas pelas espécies desse gênero, em virtude da boa adaptação aos solos ácidos e de baixa fertilidade, alto vigor de rebrota, persistência a intensidade e frequência de desfolha, bem como, excelente cobertura vegetal do solo (Alvim et al., 2002).

Em 1984, a Empresa Brasileira de Pesquisa Agropecuária lançou a *U. brizantha* cv. Marandu, fruto do programa de melhoramento genético, visando aumento na produtividade e qualidade, bem como, na resistência a pragas e doenças, produção de sementes de boa qualidade, uso eficiente de fertilizantes e adaptação a estresses edáficos e climáticos (Valle et al., 2008).

Desde então, a cada ano, diversos materiais (cultivares) de características morfofisiológicas distintas, são lançados no mercado, visando abranger, o equilíbrio produtivo e qualitativo, com capacidade de resistir às condições adversas (pragas, doenças e estresses edafoclimáticos), contribuindo para a diversificação das pastagens, sendo desta forma, fundamental conhecer seus atributos morfológicos e produtivos, nos mais diversos biomas e sistemas produtivos (Ferreira & Zanine, 2007), a fim de averiguar o potencial de utilização nas pastagens do Brasil.

### 3. Gramíneas do gênero *Urochloa*

De origem africana, essas gramíneas são capazes de crescer em uma ampla variedade de ecossistemas, desde a pântanos a regiões semidesérticas (Maass et al., 1996). Possui mais de 100 espécies (Fonseca & Martuscello, 2010), e de acordo Keller-Grein et al. (1996) sete espécies são comumente utilizadas como plantas forrageiras constituindo pastagens, sendo elas: *U. arrecta*, *U. brizantha*, *U. decumbens*, *U. dictyoneura*, *U. humidicola*, *U. mutica* e *U. ruziziensis*, são utilizadas como plantas forrageiras.

A *U. decumbens* cv. Basilisk, conhecida popularmente como capim decumbens ou braquiariinha, é uma das espécies mais difundidas no Brasil. Sua introdução ocorreu década de 50, adaptando-se as condições edafoclimáticas brasileiras, principalmente, a solos ácidos e de baixa fertilidade, bem como por seu rendimento forrageiro e resistência ao pastejo (Maass et al., 1996). Entretanto, essa espécie é altamente susceptível à cigarrinha das pastagens e hospedeira do fungo *Phitomyces chartarum*, que pode causar fotossensibilização nos animais que a ingere (Saturnino et al., 2010).

Valle et al. (2022) destacaram as principais características da *U. decumbens*, como o seu fácil estabelecimento, boa adaptação a solos ácidos e pobres, e a alta produtividade em sistema intensivo, na qual, apresentam uma produtividade média de 15 t/ha/ano MS (Pedreira et al., 2017), e um ganho médio diário (GMD) de 650 g/animal/dia (Vilela et al., 2020), variando conforme as condições de ambiente e manejo.

Com o advento da intensificação da atividade pecuária, houve a necessidade da obtenção de cultivares mais produtivas, dessa forma, em 1980 a Embrapa inicia o processo de melhoramento de gramíneas tropicais, visando o aumento da produtividade e da qualidade, resistência a pragas e doenças, produção de sementes e uso eficiente de fertilizantes, bem como a adaptação a estresses edafoclimáticos (Valle et al., 2008), com o objetivo de garantir a sustentabilidade biológica e econômica nos sistemas de produção, lançando em 1984 a cultivar *U. brizantha* cv. Marandu (Nunes et al., 1984)

Em 2013, a Embrapa lançou a *U. brizantha* cv. BRS Paiaguás, que apresenta crescimento cespitoso, folhas e colmos finos sem pilosidade, intenso perfilhamento basal, crescimento e produção de folhas no período seco, para solos de média fertilidade (Valle et al., 2022), entretanto, de baixa resistência à cigarrinha das pastagens. Além

disso, baixa estacionalidade entre o período das águas e o período seco, alto vigor, produção de sementes, boa relação de folha/colmo e elevado potencial de acúmulo de forragem com bom valor nutritivo, são outros fatores característicos dessa cultivar, e que contribuem para maiores ganhos de peso por animal (Euclides et al., 2016), podendo incrementar 1,7 UA/ha a mais no período seco, quando comparada com o BRS Piatã (Valle et al., 2013).

Outras cultivares do gênero da *Urochloa* foram lançadas ao longo dos anos por empresas privadas, como no caso da *U. brizantha* cv. Braúna, conhecida como MG-13, produzida pela empresa Matsuda®. Disponibilizadas no mercado em 2015, essa cultivar possui crescimento ereto, colmos finos e folhas finas e eretas (Matsuda, 2022), sendo recomendada para solos de média a alta fertilidade (Gomes, 2018), adapta-se a solos arenosos, e pode ser utilizada na forma de pastejo direto e fenação.

A produção média da *U. brizantha* cv. Braúna está em entorno de 8 a 12 t/h/ano de MS (Matsuda, 2022). Alguns estudos apresentam dados relevantes sobre os teores proteicos, variando entre 6,23% e 11,0% de proteína bruta (Santos, 2020), e demonstram boa resposta à adubação em doses de 150 kg N/ha (Muricy, 2021). Destaca-se ainda seu excelente perfilhamento (Borges, 2023), o qual depende do manejo e das condições estabelecidas.

No ano de 2021, uma parceria com Embrapa e CIAT (Centro Internacional para Agricultura Tropical), a Papalotla Group lançou no Brasil a *Urochloa híbrida* GP 3025 cv. Camello, uma híbrida apomítica (assexuada), resultante de cruzamentos entre *U. brizantha* com *U. decumbens* e *U. ruziziensis*. Caracterizada por possuir um crescimento decumbente, alto potencial de enraizamento e podendo atingir de 90 a 110 cm de altura em crescimento livre, considerada uma planta precoce, com alta tolerância a seca, requer naturalmente solos de média fertilidade (Papalotla Group, 2022).

O capim Camello é o único híbrido glabro selecionado por seus atributos de qualidade nutricional, produção forrageira e tolerância a seca (Chavarría & Altamirano, 2020), que de acordo com Pizarro et al. (2014), tem alta capacidade de rebrote e elevadas taxas de crescimento (117 kg MS/ha/dia), com alguns estudos reportando médias produtivas de 6 t/ha de massa seca (Flores et al., 2019).

A ampla diversidade característica de cada cultivar desse gênero, abrange alguns questionamentos, quanto ao desempenho dessas sob determinadas condições ambientais e de manejo da pastagem. De acordo com Braz et al. (2017), apesar das características

das gramíneas serem determinadas geneticamente, essas são resultantes de fatores como luminosidade, temperatura, precipitação pluviométrica e fertilidade do solo.

#### **4. Pastagens e seus nutrientes**

A capacidade produtiva de uma pastagem é resultante da quantidade de massa forrageira acumulada no tempo e do seu teor nutritivo. E para atingir a produtividade de sistemas produtivos a pasto torna-se necessário realizar um manejo que respeita a capacidade de suporte, densidade de lotação e frequência de desfolha (Combellas & Hodgson, 1979; Parsons & Penning, 1988). Dessa forma, desde a implantação da pastagem, com a escolha da espécie forrageira, manejo da pastagem e o manejo do pastejo são fundamentais para garantir a perenidade e oferta de alimento.

Em relação a espécie de gramínea forrageira, é básico conhecer suas necessidades nutritivas, o que é exigido pela planta, para atingir a produtividade e manter a perenidade, reduzindo, conseqüentemente, a degradação de pastagens (Santos & Fonseca, 2016), a fim de ofertar aqueles nutrientes em que o solo não disponibiliza e na qual a planta demanda para sua produção.

Santos & Fonseca (2016) apresentam os nutrientes exigidos pelas plantas, dividindo-os em orgânicos e inorgânicos, dos quais os orgânicos são: o carbono, oxigênio e o hidrogênio, que juntos constituem 96% da massa seca das plantas, e os 4% restantes são formados pelos nutrientes inorgânicos, sendo eles denominados macronutrientes: nitrogênio (N), potássio (K), cálcio (Ca), magnésio (Mg), fósforo (P) e enxofre (S) e os micronutrientes: cloro (Cl), ferro (Fe), boro (B), manganês (Mn), zinco (Zn), cobre (Cu), níquel (Ni) e molibdênio (Mo).

Desses nutrientes inorgânicos, os mais utilizados na adubação em pastagens, são o conjunto dos macrominerais: nitrogênio, fósforo e potássio (NPK). O fornecimento desses nutrientes tende a incrementar a produção de massa forrageira (Santos & Fonseca, 2016), minimizando assim, o efeito da sazonalidade na produção de massa de forragem por estarem diretamente ligados nos processos metabólicos da planta (Ramos et al., 2022a).

Segundo Taiz et al. (2017), o nitrogênio é constituinte das clorofilas, proteínas, aminoácidos, enzimas, dentre outros. O fósforo participa no armazenamento de energia e processo fotossintético; e o potássio está presente na regulação osmótica da folha. De

acordo com Monteiro (2013), o nitrogênio é considerado o elemento de maior necessidade quantitativa, por seu efeito direto na produtividade das plantas forrageiras, além de ser importante para a manutenção na qualidade do solo (Qin et al., 2023).

A disponibilidade de N do solo é entendida como uma interação complexa, entre fatores ambientais, reações fisiológicas, biológicas, vias de transformação, desnitrificação e mineralização (Guo et al., 2019), e seu efeito do N sobre as características morfofisiológicas nas gramíneas é específico de cada espécie, podendo ser observada nas maiores taxas de expansão de estolões e/ou perfilhos e limbo foliar (Cruz e Boval, 2000).

Conforme Ramos et al. (2022b), a falta ou baixa disponibilidade do nitrogênio pode bloquear o crescimento das plantas, por suas implicações nas funções vitais, como na fotossíntese, ao entender que há menor concentração de N na planta, atinge a constituição das clorofilas, principal estrutura para a captação da radiação luminosa e conversão em fotoassimilados, logo, para o crescimento das plantas (Qin et al., 2023).

O fósforo contribui diretamente para o enraizamento da planta e garante o vigor inicial da pastagem. De acordo com Monteiro (2013), o suprimento de fósforo acelera o crescimento inicial da parte aérea e das raízes, resultando em maior perfilhamento. Esse elemento representa cerca de 0,2% da massa seca da planta (Schachtman et al., 1998), constituindo proteínas e ácidos nucleicos, bem como a ativação enzimática e transferência de energia (Wang et al., 2017).

A produção da planta forrageira é atribuída às características morfogênicas e estruturais, sob a ação dos fatores ambientais (Lemaire & Chapman., 1996), destacando, a disponibilidade de nutrientes por meio da fertilização, que estimula o acúmulo da biomassa forrageira (Abreu et al., 2020; Bernardi et al., 2018; Lopes et al., 2017; Lopes et al., 2013).

O nitrogênio e o fósforo são considerados os macronutrientes que mais limitam o processo fotossintético (Fay et al., 2015), ao melhorar a fertilização no sistema produtivo, tende ser uma fonte de aumentar a lucratividade e reduzir as perdas de nitrogênio (Smith et al., 2018) e do fósforo (Somavilla et al., 2021) no ambiente.

## 5. Fertilização em pastagens

Após a introdução de gramíneas tropicais, na década de 80, os sistemas produtivos a pasto iniciaram uma etapa importante na melhoria da produtividade forrageira. Com a implantação de espécies melhoradas, o uso de fertilizantes, principalmente, os nitrogenados aumentaram ao longo dos anos (Mckenzie et al., 2003) e tornaram-se indispensável na intensificação de pastagens, que objetiva em sustentar altas produtividades (Ho et al., 2013).

A intensificação de pastagens visa em aumentar a capacidade produtiva das gramíneas, ao ofertar um manejo que garanta uma rebrota vigorosa, tendo assim, a aplicação de fertilizantes como um dos principais meios. Iniciando pela adubação de fósforo (fosfatagem), que é comumente necessária no Brasil, visto que, os solos brasileiros normalmente detêm de baixos teores de fósforo (Monteiro, 2013), no entanto, para garantir a disponibilidade desse nutriente é essencial que o solo não esteja em situação de acidez, caso esteja, sua correção com calagem e/ou gessagem é fundamental.

Predominantemente, utiliza-se fertilizantes tratados com ácidos, para a oferta de P, dos quais o superfosfato simples (18%  $P_2O_5$ ) é um dos mais usados na implantação das pastagens brasileiras. No entanto, essa fonte tende a absorver amônia, oportunizando a utilização de fertilizantes fosfatados de baixa solubilidade (rocha fosfática), fonte alternativa para os fosfatos solúveis (Oliveira et al., 2015), mas, com uma capacidade de liberar fósforo ainda indefinida (Somavilla et al., 2021).

Dentre os fertilizantes disponíveis para reposição do nitrogênio, os mais comumente utilizados são o sulfato de amônio (21% N), nitrato de amônio (33% N) e a ureia (45% N), na qual, esse último possui maior potencial de conversão em composto amônia ( $NH_3$ ) que tende a ser volatilizada (Fonseca et al., 2022), principal forma de perda para o ambiente. Lembrando que, as plantas geralmente absorvem as formas de nitrato ( $NO_3^-$ ) e amônio ( $NH_4^+$ ) (Tian et al., 2021).

A perda de nitrogênio pode ainda ser dependente da quantidade de N disponível no tempo (Zhu et al., 2022), ou seja, uma maior quantidade de N disponível no solo do que a planta é capaz de absorver, leva a uma maior perda. Esses autores ainda afirmam que menos da metade do N da biomassa vegetal é provinda da fertilização, em que, a

maioria é evaporada ou lixiviada, e que o fertilizante N é a maior fonte de N para gramíneas forrageiras.

Por isso, diferentes tecnologias nos fertilizantes foram desenvolvidas, no intuito de aumentar a sua eficiência, como exemplo, o revestimento de fertilizantes, que objetiva a liberação controlada do nutriente (Cahill et al., 2010). A otimização da utilização desses fertilizantes revestidos depende do rendimento e da eficiência do uso, durante todo o período de crescimento da planta (Zhu et al., 2022).

Esses fertilizantes podem ser revestidos por material orgânico ou inorgânico. As encapsulações são possíveis com o uso enxofre, termoplásticos, acetato de etileno-vinila ou surfactantes que são degradados em uma velocidade especificada (Shahena et al., 2021), bem como os polímeros (Du et al., 2006), sendo biodegradáveis ou não biodegradáveis (Rajan et al., 2021).

A liberação controlada dos nutrientes por um período mais longo tende a aumentar a sua disponibilidade, reduzindo a degradação do solo provocada pelo uso de fertilizantes (Rajan et al., 2021), principalmente, os nitrogenados. De acordo com Dupas et al. (2016), o aumento da disponibilidade de N no solo resulta em maior quantidade e qualidade dos vegetais, principalmente se tratando de gramíneas tropicais (Murphy et al., 2010), além de reduzir o efeito de “queima” das plantas pelo uso excessivo de nitrogênio (Weerasinghae et al., 2016).

Segundo Rajan et al. (2021), esses fertilizantes podem ser denominados como fertilizantes de liberação lenta, sua liberação depende das condições edafoclimáticas, bem como, do teor de umidade e atividade biológica (Raban et al., 1997). Em relação aos fertilizantes de liberação controlada, esses podem obter uma taxa de liberação prevista no tempo, dentro de certos limites (Cartagena et al., 1993), visto que, na sua preparação são considerados esses fatores.

Os microrganismos e a umidade do solo são fatores importantes para a liberação dos nutrientes, em que, temperaturas menores que 10° C não há liberação e acima de 32° C a liberação torna-se excessiva (Rajan et al., 2021). Nesse sentido, na aplicação desses fertilizantes devem ser observadas as condições edafoclimáticas, a fim de evitar que eles tornem fontes inadequadas de nutrientes.

## 6. Métodos de avaliação das pastagens

Obter informações da pastagem como: suas características morfológicas, produtivas e nutritivas, sob o ambiente em que está inserida, auxilia no manejo adequado (Cruz et al., 2021), certificando que as tomadas de decisões sejam mais eficientes dentro sistema produtivo, principalmente, se tratando de pecuária baseada na alimentação a pasto.

Para alcançar as metas produtivas e sustentáveis é necessário avaliar o padrão de crescimento das plantas forrageiras, por meio da mensuração da massa de forragem (MF), de forma direta ou indireta. A mensuração da MF pelo método direto é conhecida por ser precisa (Borra-Serrano et al., 2019) e efetiva (Arruda et al., 2011), ao conhecer a quantidade da massa MF que é destruída de uma área conhecida.

A mensuração direta é conhecida por ser um método trabalhoso e demorado (Sanderson et al., 2001), com baixa representatividade temporal e espacial, limitadas as áreas remotas e de difícil acesso (Wanchendorf et al., 2017). Em que, os manejadores de pasto não conseguem realizar com a devida frequência, para a obtenção das informações de produtividade e qualidade da pastagem, admitindo uma gestão produtiva com lacunas, comprometendo a sua eficiência.

Na coleta, as amostras devem possuir uma quantidade mínima que seja representativa para que o método direto detenha de dados confiáveis (Huuskonem et al. 2013), e que sejam obtidas de áreas homogêneas. A colheita (corte) do material (amostras) pode ser realizada rente ao solo ou na altura de manejo do pasto, posteriormente, essas amostras são direcionadas ao laboratório, para a determinação do teor de matéria seca e dos teores nutritivos, a exemplo da proteína bruta.

Dessa forma, entende-se que a aplicação do método direto nos sistemas produtivos para avaliar as pastagens é complexo, devido suas etapas de execução. Com isso, os métodos indiretos foram lançados ao longo dos anos para atuar em suas fragilidades, viabilizando informações sobre o pasto de maneira mais rápida. Assim, Cruz et al. (2021) e Arruda et al. (2011), relatam alguns dos métodos indiretos existentes, sendo eles: rendimento visual comparativo, altura do horizonte do dossel (não comprimida), altura comprimida do dossel, sonda eletrônica, estimativa por modelos matemáticos, e de utilização mais atual, o uso de sensores ópticos através do sensoriamento remoto (SR).

Esses métodos foram desenvolvidos baseados na calibração pelo método direto e torna-se capazes de oferecer informações do pasto em menor tempo, com vantagens na representatividade temporal e espacial (Wanchendorf et al., 2017). Dentre eles, a altura do pasto é um dos principais métodos usados para auxiliar o manejo de forma eficiente (Santos & Martuscello, 2022), ao entender que nas alturas pré-determinadas, as gramíneas estarão em condições de fornecer uma massa forrageira adequada para suprir as necessidades dos animais a pasto.

Entretanto, para a obtenção das informações da altura é necessário que a coleta seja no local e que tenha uma quantidade de amostras representativas. Conforme Martins et al. (2020), a medição da altura do pasto auxilia no momento da entrada dos animais no piquete, mas, a literatura demonstra baixa exatidão para estimar a massa de forragem (Moterle et al., 2017).

Nesse sentido, pesquisas vêm utilizando informações do sensoriamento remoto para estimar a massa de forragem (Kumar et al., 2015), em razão da capacidade de coletar um grande volume de dados, permitindo maior agilidade e processamento de informações.

## **7. Sensoriamento remoto em pastagens**

O sensoriamento remoto é a obtenção de informações da superfície terrestre, por meio da radiação eletromagnética, através de imagens à distância, sendo adquiridas pelos sensores remotos (INPE, 2023), esses podendo ser sensores passivos, que utilizam a fonte natural (Sol), ou ativos de fontes artificiais (IBGE, 2023).

Os satélites ou aeronaves remotamente pilotada (ARP), esse último popularmente conhecido como drone, são equipamentos potenciais para o acoplamento de sensores remotos. À exemplo desses sensores temos o LiDAR, ultrassom, câmeras multiespectrais e RGB (vermelho, verde e azul), que são utilizados como ferramentas para a aquisição de informações não destrutivas da biomassa acima do solo (Deshpande et al., 2021; Wanchendorf et al., 2017; Moeckel et al., 2017; Wallace et al., 2017).

Nos drones são comumente acopladas as câmeras multiespectrais, hiperespectrais e RGB. Entretanto, o uso câmeras multiespectrais e/ou hiperespectrais é tido como dispendioso por seu alto custo, o que limita uma maior aplicabilidade na avaliação das pastagens, além de sua calibração espectral depender de um extenso

trabalho (Wancherdorf et al., 2017). Oposto a esses sensores, os sensores RGB obtêm informações (imagem RGB) a menor custo (Gruner et al., 2019), sendo mais acessível a sua implementação nos sistemas produtivos.

Uma imagem RGB provém da constituição e sobreposição da reflectância de três bandas conhecidas com red (vermelho), green (verde) e blue (azul), essa fragmentação da refletância de cada banda possuem a capacidade em extrair informações sobre a vegetação e o solo, permitindo a criação de índices de vegetação (IV) que tendem a serem utilizados como indicadores da produção de biomassa (Li et al., 2016; Junges et al., 2016; Borra-Serrano et al., 2019; Pezzopane et al., 2019; Moreira et al., 2019).

Ao longo dos anos, os IVs obtidos pelas combinações das bandas RGB apresentaram correlações com a biomassa acima do solo (BAS), sendo eles: o GLI – *Green Leaf Index* (índice de folhas verdes) (Louhaichi et al., 2001), o MPRI – *Modified Photochemical Reflectance* (Yang et al. (2008) e o ExG – *Excess of Green* (excesso de verde) (Woebbecke et al. 1995).

Em 2001, Louhaichi et al. avaliaram a correlação do GLI na cultura do trigo, observando sua aplicabilidade em pastagens temperadas (Acorsi et al., 2019) e tropicais (Freitas et al., 2022). Além do GLI, MPRI e ExG, Barbosa et al. (2019) verificam outros índices de vegetação, a exemplo do MGVI (Modified Green Red Vegetation) e RGVBI (Red Green Blue Vegetation Index) no monitoramento de gramíneas, expondo que os valores apresentados pelos IVs indicam presença de vegetação em determinada área.

Conforme Beding et al. (2015), essa capacidade dos sensores RGB em capturar a radiação eletromagnética refletida pelas plantas, estende a relacionar com a biomassa forrageira, em virtude dessas imagens, após o processamento do ortomosaico apresentarem informações de elevação, que geram os denominados modelos digitais de elevação (DEM), derivada da nuvem densa dos pontos 3D, em condições de resolução centimétricas (Tilly et al., 2014).

Nessa perspectiva, o potencial de imagens RGB apresentam resoluções centimétricas (Viljanen et al., 2018), melhora a resolução espacial de imagens providas dos satélites, que em média possui resoluções variando entre 5 e 100 metros (Borra-Serrano et al., 2019). Comportamento positivo, pois as imagens de satélites vêm sendo avaliadas no monitoramento de pastagens, apresentando modelos preditivos que variam entre 60% e 89% (Reis et al., 2020; Chen et al., 2021), ampliando a aplicabilidade das câmeras RGB acopladas em ARP.

Diversos estudos verificam a utilização de imagens RGB para construir modelos preditivos que estimam a massa forrageira. Em plantas forrageiras anuais temperadas Acorsi et al. (2019) alcançaram um  $R^2$  0,84; Gruner et al. (2019) em pastagens temperadas  $R^2$  entre 0,64 e 0,75; Adar et al. (2022) em pastagens no semiárido  $R^2$  0,50; Michez et al. (2019) em pastagens mistas  $R^2$  0,49; Freitas et al. (2022) em pastagem tropical  $R^2$  0,70.

Além de avaliar as informações quantitativas da biomassa acima do solo, algumas pesquisas relatam a correlação dos IVs RGB com a concentração de clorofila (Liang et al., 2022). Segundo Li et al. (2022), as informações de cor e textura baseados nos sensores RGB podem monitorar o status de nitrogênio na cultura do trigo. Nessa mesma perspectiva, Caturegli et al. (2014) relataram o potencial de obter informações sobre a qualidade, matéria seca, clorofila, carotenoides e teor de nitrogênio.

A utilização dos sensores remotos na agricultura de precisão está bem difundida para culturas como o milho, a soja, o trigo e o arroz. Todavia, para as gramíneas tropicais observa-se alguns estudos (Freitas et al., 2022; Pezzopane et al., 2019; Asprilla et al., 2019) utilizando imagens providas de ARP para estimar a produção da massa forragem em pastagens.

Desta forma, a fim de proporcionar melhorias no planejamento das atividades agrícolas, é necessário, compreender o uso dessa tecnologia, considerando os aspectos específicos da gramínea, do manejo empregado na pastagem, bem como, do local em que está inserida, pois são fatores fundamentais para a avaliação da disponibilidade de forragem (Silva et al., 2018). Haja visto, que a precisão da estimativa da biomassa acima do solo (massa de forragem) em pastagens está diretamente relacionada com a estação de crescimento das pastagens (Lussem et al., 2019).

## 8. Referências Bibliográficas

ABIEC – Associação Brasileira das Indústrias Exportadoras de Carnes. 2022. Disponível em < <https://www.abiec.com.br/>>. Acessado em 25 de março de 2023.

ABIEC – Associação Brasileira das Indústrias Exportadoras de Carnes. 2023. Disponível em < <https://www.abiec.com.br/publicacoes/beef-report-2023-capitulo-04/>> Acessado em novembro de 2023.

ABREU, M.J.I.; PAULA, P.R.P.; TAVARES, V.B.; CIDRINI, I.A.; NUNES, H.O.; EMILIANO, W.J.C.; COELHO, R.M.; NEIVA JÚNIOR, A.P.; TOMAZ, C.E.P. Morfogênese, características estruturais e acúmulo de forragem do *Megathyrus maximus* BRS Zuri submetido a adubação nitrogenada. **Boletim De Indústria Animal**, v.77, n.1, p.1-17. 2020. DOI: <https://doi.org/10.17523/bia.2020.v77.e1486>

ACORSI, M.G.; MIRANDA, F. D.A.; MARTELLO, M.; SMANIOTTO, D.A.; SARTOR, L. R. Estimating biomass of black oat using UAV-based RGB Imaging. **Agronomy**, v.9, n.7, 2019. Doi: <https://doi.org/10.3390/agronomy9070344>

ADAR, S.; STERNBERG, M.; PAZ-KAGAN, T.; HENKIN, Z.; DOVRAT, G.; ZAADY, E.; ARGAMAN, E. Estimation of aboveground biomass production using an unmanned aerial vehicle (UAV) and VEN $\mu$ S satellite imagery in Mediterranean and semiarid rangelands. **Remote Sensing Applications: Society and Environment**, v.26, 2022. Doi: <https://doi.org/10.1016/j.rsase.2022.100753>

ALVIM, M.J.; BOTREL, M.A.; XAVIER, D.F. As principais espécies de *Brachiaria* utilizadas no País. **Comunicado técnico 22 – EMBRAPA**, Juiz de Fora-MG, 2002.

ARRUDA, D. S. R.; CANTO, M. W.; JOBIM, C. C.; CARVALHO, P. C. F. Métodos de avaliação de massa de forragem em pastagens de capim-estrela submetidas a intensidades de pastejo. **Ciência Rural**, v. 41, p. 2004-2009. 2011.

ASPRILLA, W. P.; SIERRA, M. M.; MUÑOZ, M; C. Estimación de la calidad y cantidad de pasto kikuyo (*Cenchrus clandestinum* (Hochst. Ex Chiov. Morrone) usando imágenes multiespectrales. **Revista U.D.C.A Actualidad & Divulgación Científica**. v. 22. 2019

ATHENAGRO Consultoria. 2022. Disponível em < <https://athenagro.com.br/artigos/>>. Acessado em dezembro de 2023.

BARBOSA, B.D.S.; FERRAZ, G.A.S.; GONÇALVES, L.M.; MARIN, D.B.; MACIEL, D.T.; FERRAZ, P.F.P.; ROSSI, G. RGB vegetation indices applied to grass monitoring: a qualitative analysis. **Agronomy Research**, v; 17, n. 2, p. 349-357. 2019. Doi: <https://doi.org/10.15159/AR.19.119>

BENDIG, J., YU, K., AASEN, H., BOLTEN, A., BENNERTZ, S., BROSCHEIT, J., GNYP, M.L.; BARETH, G. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley.

**International Journal of Applied Earth Observation and Geoinformation**, v39, p.79–87. 2015. Doi: <https://doi.org/10.1016/j.jag.2015.02.012>

BERNARDI, A.W.L.; SILVA, D.B. Estudo metanalítico da resposta de gramíneas perenes de verão à adubação nitrogenada. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v.70, n.2, p.545-553. 2018. Doi: <https://doi.org/10.1590/1678-4162-9501>

BORGES, G.S. **Morfogênese e taxa de acúmulo de forragem dos capins braúna, cayana e sabiá submetidos ao diferimento**. (Dissertação de mestrado). Universidade Federal de Uberlândia, Uberlândia-MG, 2023.

BORRA-SERRANO, I.; SQAEF, T.; MUYPLE, H.; NUYTTENS, D.; VANGEYTE, J.; MERTENS, K.; SAEYS, W.; SOMERS, B.; RUIZ, I. R. E LOOTENS, P. Conopy heigt measurements and – nondestructive biomass estimation of Lolium perene swards using UAV imagery. **Grass and Forage Science**, v.74, p.356-369. 2019. Doi:<https://doi.org/10.1111/gfs.12439>

BRAZ, T.G.S.; MARTUSCELLO, J.A.; SANTOS; M.E.R.; PEREIRA, V.V. Análise de correlação parcial no estudo da morfogênese e do acúmulo de forragem de Panicum maximum cv.‘Tanzânia’. **Ciência Rural**, v. 4, n.9, 2017. DOI: <https://doi.org/10.1590/0103-8478cr20161058>

CAHILL, S.; OSMOND, D.; WEI, R.; HEINIGER, R. Evaluation of Alternative Nitrogen Fertilizers for Corn and Winter Wheat Production. **Agronomy Journal**, v. 102, n. 4, p. 1226–1236, 2010. Doi: <https://doi.org/10.2134/agronj2010.0095>

CARTAGENA, M.C.; DÍEZ LÓPEZ, J.A.; VALLEJO, A.; JIMÉNEZ, S. Evaluation and Classification of Coated Slow-Release Nitrogen Fertilizers by Means of Electroultrafiltration in na Integrated System, 1993.

CATUREGLI, L.; LULLI, F.; FOSCHI, L.; GUGLIELMINETTI, L.; BONARI, E.; VOLTERRANI, M. Monitoring turfgrass species and cultivars by spectral reflectance. **Europ. J. Hort. Scie**, v. 39, n. 3, p. 97-107. 2014.

CEPEA - **Centro de Estudos Avançados em Economia Aplicada** – Escola Superior Luiz de Queiros – Universidade de São Paulo (ESALQ-USP). 2023. Disponível em < <https://www.cepea.esalq.usp.br/br/calendario-2023.aspx>>. Acessado em novembro de 2023.

CHAVARRÍA, E.P.; ALTAMIRANO, H.J.R. **Potencial forrajero y nutritivo de los pastos híbridos: *Brachiaria híbrido* CIAT BR02/1752 cv. Cayman, *Brachiaria híbrido* CIAT BR02/1794 cv. Cobra y *Brachiaria híbrido* GP 3025 cv. Camello, período lluvioso, Finca Santa Rosa, Managua 2019**. (Tese de Doutorado) Universidad Nacional Agraria – Facultad de Ciencia Animal, Managua,Nicaragua, 2020.

COMBELLAS, J., HODGSON, J. Herbage intake and milk production by grazing dairy cows. 1. The effect of variation in herbage mass and daily herbage allowance in a short-term trial. **Grass Forage Science**, v. 34, p.209–214. 1979

CHEN, Y.; GUERSCHMAN, J.; SHENDRYK, Y.; HENRY, D.; HARRISON, M.T. Estimating Pasture Biomass Using Sentinel-2 Imagery and Machine Learning. **Remote Sensing**, v.13, n.4, 2021. Doi: <https://doi.org/10.3390/rs13040603>

CRUZ, N.T.; PIRES, A.J.V.; SOUSA, B.M.L.; JARDIM, R.R.; FRIES, D.D.; DIAS, D.L.S.; BONOMO, P.; RAMOS, B.L.P. Métodos de avaliação em pastagens com ou sem animais. **Pubvet**, v.15, n.12, p.1-18, 2021. Doi: <https://doi.org/10.31533/pubvet.v15n12a995.1-18>

CRUZ, P.; BOVAL, M. Effect of nitrogen on some morphogenetic traits of temperate and tropical perennial forage grasses. In: LEMAIRE, G. et al. (eds). *Grassland Ecophysiology and Grazing Ecology*, **CAB International, Wallingford**. p.151-167, 2000.

DESHPANDE, A.; RAZMJOOY, N.; ESTRELA, V. Introduction to Computational Intelligence and Super-Resolution. In *Computational Intelligence Methods for Super-Resolution in Image Processing Applications*; **Springer International Publishing**: Cham, Switzerland, p. 3–23. 2021.

DIAS-FILHO, M.B. Degradação de pastagens: o que é e como evitar. **Embrapa - publicações**, 2017.

DU, C.W.; ZHOU, J.M.; SHAVIV, A. Release characteristics of nutrients from polymercoated compound controlled release fertilizers, **J. Polym. Environ**, v. 14, n. 3. 2006

DUPAS, E.; BUZETTI, S.; RABÊLO, F.H.S.; SARTO, A.L.; CHENG, N.C.; TEIXEIRA FILHO, M.C.M.; GALINDO, F.S.; DINALLI, R.P.; GAZOLA, R.N. Nitrogen recovery, use efficiency, dry matter yield, and Chemical composition of palisade grass fertilized with nitrogen sources in the Cerrado biome. **Australian Journal of Crop Science**, v.10, n.9, p.1330-1338, 2016. Doi: DOI: 10.21475/ajcs.2016.10.09.p7854

EMBRAPA - Empresa Brasileira De Pesquisa Em Agropecuária. **Pastagens**. 2022. Acessado em 23 de março de 2023. Disponível em <<https://www.embrapa.br>>

EUCLIDES, V.P.B.; MONTAGNER, D.B.; BARBOSA, R.A.; VALLE, C.B.; NANTES, N.N. Animal performance and sward characteristics of two cultivars of *Urochloa brizantha* (BRS Paiaguás and BRS Piatã). **Revista Brasileira de Zootecnia**, v. 45, n.3, p.85-92, 2016. Doi: <https://doi.org/10.1590/S1806-92902016000300001>

FAO – **Organização das Nações Unidas para a Alimentação e a Agricultura**. 2022. Disponível em < <https://www.fao.org/brasil/publicacoes/pt/>>. Acessado em 24 de março de 2023.

FAO – **Organização das Nações Unidas para a Alimentação e a Agricultura**. 2019. Disponível em < <https://www.fao.org/brasil/publicacoes/pt/>>. Acessado em 24 de março de 2023.

FAY, P.A., PROBER, S.M., HARPOLE, W.S., KNOPS, J.M.H., BAKKER, J.D., BORER, E.T., LIND, E. M., MACDOUGALL, A.S., SEABLOOM, E.W., WRAGG, P.D., ADLER, P.B., BLUMENTHAL, D.M., BUCKLEY, Y.M., CHU, C., CLELAND, E.E., COLLINS, S.L., DAVIES, K.F., DU, G., FENG, X., FIRN, J., GRUNER, D.S., HAGENAH, N., HAUTIER, Y., HECKMAN, R.W., JIN, V.L., KIRKMAN, K.P., KLEIN, J., LADWIG, L.M., LI, Q., MCCULLEY, R.L., MELBOURNE, B.A., MITCHELL, C.E., MOORE, J.L., MORGAN, J.W., RISCH, A.C., SCHÜTZ, M., STEVENS, C.J., WEDIN, D.A., YANG, L.H. Grassland productivity limited by multiple nutrients. **Nature Plants** v.1, p.1–5. 2015. Doi: <https://doi.org/10.1038/nplants.2015.80>.

FERREIRA, D.J.; ZANINE, A.M. Importância da pastagem cultivada na produção da pecuária de corte brasileira. **Revista eletrônica de veterinária**, v.8, n.3, 2007.

FLORES, A.B.; GARRIDO, S.J.L.; RAMOS, V.H.V.; RAMÓN, R.R.; PIZARRO, E.A. Cinética del valor nutricional y digestibilidad en un híbrido de Urochloa (cv. camello) con tolerancia a sequía. **V Congreso Mundial de Ganadería Tropical**, México, 2019.

FONSECA, N.V.B.; CARDOSO, A.S.; BERÇA, A.S.; DORNELLAS, I.A.; ORGARATTO, F.; SILVA, M.L.C.; RUGGIERI, A.C.; REIS, R.A. Effect of different nitrogen fertilizers on nitrogen efficiency use in Nellore bulls grazing on Marandu palisade grass. **Livestock Science**, v.263, 2022. Doi: <https://doi.org/10.1016/j.livsci.2022.105012>

FONSECA, D.M.; MARTUSCELLO, J.A. **Plantas Forrageiras** (2ed.). Viçosa:Editora UFV, p.591, 2022.

FONSECA, D.M.; MARTUSCELLO, J.A. **Plantas Forrageiras** (1ed.). Viçosa:Editora UFV, p.537, 2010.

FREITAS, R.G.; PEREIRA, F.R.S.; REIS, A.A.; MAGALHÃES, P. S.G.; FIGUEIREDO, G.K.D.A.; AMARAL, L.R. Estimating pasture aboveground biomass under an integrated crop-livestock system based on spectral and texture measures derived from UAV images. **Computers and Electronics in Agriculture**, v.198, 2022. Doi: <https://doi.org/10.1016/j.compag.2022.107122>

GOMES, L.L.C. Informações sobre recentes cultivares de gramíneas forrageiras para produção de bovinos de corte. **Monografia (Especialização)** – Curso de Agronomia, Faculdade de Agronomia e Medicina Veterinária, Universidade de Brasília, Brasília, p.28, 2018.

GRUNER, E.; ASTOR, T.; WACHENDORF, M. Biomass prediction of heterogeneous temperate grasslands using the SfM approach based on UAV Imaging. **Agronomy**, v.9, n.2, 2019. Doi: <https://doi.org/10.3390/agronomy9020054>

GUO, X.L.; ZHENG, R.B., ZHANG, K. QIU, Y.P.; YUE, H.T. Transformation in relation to land use in the Napahai Wetland, Southwest China. **Journal Soil Science Plant Nutrition**, v. 19, pp. 92-97. 2019. Doi: 10.1007/s42729-019-0013-0

HO, C.K.M.; MALCOLM, B.; DOYLE, P.T. Potential impacts of negative associative effects between concentrate supplements, pasture and conserved forage for milk production and dairy farm profit. **Animal Production Science**. v.53, n.5, p.437-452. 2013. Doi: 10.1071/AN12140

HUUSKONEN, A.; HUHTANEN, P.; OKI-TOKOLA, E. The development of a model to predict feed intake by growing cattle. **Livestock**. 2013.

INPE – **Instituto Nacional de Pesquisa Espaciais**. 2023. Acessado em novembro de 2023. Disponível em [http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm#:~:text=Senso riamento%20remoto%20%C3%A9%20um%20termo,de%20aparelhos%20denominados %20sensores%20remotos.>](http://www3.inpe.br/unidades/cep/atividadescep/educasere/apostila.htm#:~:text=Senso%20riamento%20remoto%20%C3%A9%20um%20termo,de%20aparelhos%20denominados%20sensores%20remotos.>)

IBGE – **Instituto Brasileiro de Geografia e Estatísticas**. 2023. Acesso em novembro de 2023. Disponível em <https://www.ibge.gov.br/>>

JUNGES, A.; BREMM, C.; FONTANA, D. C.; OLIVEIRA, C. A. O.; SCHAPARINI, L. P.; CARVALHO, P. C. F. Temporal profiles of vegetation indices for characterizing grazing intensity of natural grasslands in Pampa biome. **Scientia Agrícola, Piracicaba**, v.73, n. 4, p. 332- 337, 2016. Doi: <https://doi.org/10.1590/0103-9016-2015-0213>

KELLER-GREIN, G.; MAASS, B.L.; HANSON, J. Natural variation in Brachiaria and existing germoplasma collections. In: Miles, J.W.; Maass,B.L.; Valle, C.B., ed. **Brachiaria: biology, agronomy, and improvement**. Cali: CIAT/Brasília: Embrapa-CNPGC, p.16-42, 1996.

KUMAR, L.; SINHA, P.; TAYLOR, S.; ALQURASHI, A.F. Review of the use of remote sensing for biomass estimation to support renewable energy generation. **Journal of Applied Remote Sensing**, v.9, n.1, 2015. Doi:<https://doi.org/10.1117/1.JRS.9.097696>

LEMAIRE, G.; CHAPMAN, D. Tissue fluxes in grazing plant communities. In: Hodgson, J. & Illius, A. W. (Eds.). **The ecology and management of grazing systems**. Wallingford: CAB International, p.3-36. 1996.

LI, R.; WANG, D.; ZHU, B.; LIU, T.; SUN, C.; ZHANG, Z. Estimation of nitrogen content in wheat using indices derived from RGB and thermal infrared Imaging. **Field Crops Research**, v.289, 2022. Doi: <https://doi.org/10.1016/j.fcr.2022.108735>

LI, F.; ZENG, Y.; LUO, J.; MA, R.; WU, B. Modeling grasslands aboveground biomass using a purê vegetation index. **Ecological Indicators**, v.62, p. 279-288, 2016. DOI: <https://doi.org/10.1016/j.ecolind.2015.11.005>.

LIANG, Y.; KOU W.; LAI, H.; WANG, J.; WANG, Q.; XU, W.; WANG, H.; LU, N. Improved estimation of aboveground biomass in rubber plantations by fusing spectral and textural information from UAV-based RGB imagery, **Ecological Indicators**, v.142. 2022. Doi: <https://doi.org/10.1016/j.ecolind.2022.109286>.

LOPES, C.M.; PACIULLO, D.S.C.; ARAÚJO, S.A.C.; MORENZ, M.J.F.; GOMIDE, C.A. M.; MAURÍCIO, R.M.; BRAZ, G.S. Plant morphology and herbage accumulation of signal grass with or without fertilization, under different light regimes. **Ciência Rural**, v.47, n.2. 2017. DOI: <https://doi.org/10.1590/0103-8478cr20160472>

LOPES, M. N., CÂNDIDO, M. J. D., POMPEU, R. C. F. F., SILVA, R. G., LOPES, J. W. B., FERNANDES, F. R. B., LACERDA, C. F.; BEZERRA, F. M. L. Fluxo de biomassa em capim-massai durante o estabelecimento e rebrotação com e sem adubação nitrogenada. **Revista Ceres**, v.60, n.3, p.363-371. 2013. Doi: <https://doi.org/10.1590/S0034-737X2013000300009>

LOUHAICHI, M.; BORMAN, M.M.; JOHNSON, D.E. Spatially located platform and aerial photography for documentation of grazing impacts on wheat. **Geocarto International**. V.16, p.65–70, 2001. Doi: <https://doi.org/10.1080/10106040108542184>

LUSSEM, U.; BOLTEN, A.; MENNE, J.; GNYP, M.L., SCHELLBERG, J., BARETH, G. Estimating biomass in temperate grassland with high resolution canopy surface models from UAV-based RGB images and vegetation indices. *Journal of Applied Remote Sensing*, v.13, n.3. 2019. Doi: 10.1117/1.JRS.13.034525

MATSUDA - **Grupo Matsuda**. 2022. Disponível em: <https://sementes.matsuda.com.br/br/produto/mg-13-brauna/>. Acesso em: 28 de março de 2023.

MAASS, B.L. Identifying and Naming Brachiaria Species. In: MILES, J.W.; Maass, B.L.; Do Valle, C.B. **Brachiaria: biology, agronomy, and improvement**. Colombia. 1996.

MARTINS, C. D. M., SCHMITT, D., DUCHINI, P. G., MIQUELOTO, T., & SBRISSIA, A. F. Defoliation intensity and leaf area index recovery in defoliated swards: implications for forage accumulation. **Scientia Agricola**, v.78, n.2, p.1–10. 2020. Doi: <https://doi.org/10.1590/1678-992x-2019-0095>.

MCKENZIE, F.R., JACOBS, J.L., KEARNEY, G. Long-term effects of multiple applications of nitrogen fertiliser on grazed dryland perennial ryegrass/white clover dairy pastures in south-west Victoria. 2. Growth rates, dry matter consumed, and nitrogen response efficiencies. **Australian Journal of Agricultural Research**, v. 54, p.471–476. 2003.

MOECKEL, T.; SAFARI, H.; REDDERSEN, B.; FRICKE, T.; WACHENDORF, M. Fusion of Ultrasonic and Spectral Sensor Data for Improving the Estimation of Biomass in Grasslands with Heterogeneous Sward Structure. **Remote Sensing**, v.9, n.1, p.98, 2017. Doi: <https://doi.org/10.3390/rs9010098>

MONTEIRO, F.A. Uso de corretivos agrícolas e fertilizantes. In: **Forragicultura: ciência, tecnologia e gestão dos recursos forrageiros**. Reis, R.A.; Bernardes, T.F.; Siqueira, G.R. Jaboticabal-SP, p.714, 2013.

MORAIS, L.F.; CARVALHO, C.A.B.; ANJOS, A.N.A.; VIEGAS, C.R.; SILVA, P.H.F. Avanços na avaliação de pastagens cultivadas com forrageiras tropicais no Brasil: Uma Revisão. **Revista Brasileira de Tecnologia Aplicada Nas Ciências Agrárias**, v.11, n.2, p.125–136. 2018. Doi: <https://doi.org/10.5935/PAeT.V11.N2.13>

MOREIRA, A.; BREMM, C.; FONTANA, D.C.; KUPLICH, T.M. Seasonal dynamics of vegetation indices as a criterion for grouping grassland typologies. **Scientia Agrícola**, v.76, n.1, p.24-32, 2019. DOI: <https://doi.org/10.1590/1678-992x-2017-0173>.

MOTERLE, P. H., ROCHA, M. G., PÖTTER, L., SICHONANY, M. J. O., AMARAL, L. G. A., SILVA, M. F., SALVADOR, P. R., VICENTE, J. M. Padrões de deslocamento de bezerras de corte recebendo suplemento em pastagem de azevém. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v.69, p.1021–1029. 2017. <https://doi.org/10.1590/1678-4162-9258>.

MOTA JUNIOR, E.R.; TRENTIN, C.B.; SILVA, I.S.; QUEIROZ, I.L.C.; TRENTIN, A.B. Monitoring of pasture degradation and incorporation of agricultural activities in the médio araguaia/MT microregions. **Revista Georaguaia**, v. 10, n. 2, p. 160-174. 2010.

MICHEZ, A.; LEJEUNE, P.; BAUWENS, S.; HERINAINA, A.A. L.; BLAISE, Y.; MUÑOZ, E.C.; LEBEAU, F.; BINDELLE, J. Mapping and Monitoring of Biomass and Grazing in Pasture with an Unmanned Aerial System. **Remote Sensing**, v.11, n.5, 2019. Doi: <https://doi.org/10.3390/rs11050473>

MURPHY, S.R.; LODGE, G.M.; MCCORMICK, L.H.; JOHNSON, I.R. Using growth and dry matter estimates to devise year-round forage systems for the North-West Slopes of New South Wales. In: **Proceeding of the 15th Australian Society of Agronomy**, Lincoln, New Zealand. 2010.

MURICY, J. F. **Adubação líquida e adubação convencional na fertilidade do solo e características agronômicas e morfofisiológicas do capim *Brachiaria brizantha* cv. Braúna**. Dissertação (Mestrado em produção de ruminantes) – Programa de Pós-graduação em Zootecnia, Universidade Estadual do Sudoeste da Bahia, Itapetinga - BA, p.41, 2021.

NUNES, S. G.; BOOCK, A.; PENTEADO, M. I. O.; GOMES, D. T. *Brachiaria brizantha* cv. Marandu. **Documentos Embrapa, Embrapa/CNPGC**, Campo Grande, n.21, 1984.

OLIVEIRA, L.B.; SOARES, E.M.; JOCHIMS, F.; TIECHER, T.; MARQUES, A.R.; KUINCHTNER, B.C.; RHEINHEIMER, D.S.; DE QUADROS, F.L.F. Long-term effects of phosphorus on dynamics of an overseeded natural grassland in Brazil. **Rangeland Ecology & Management**, v.68, p445–452. 2015. Doi: <https://doi.org/10.1016/j.rama.2015.07.012>.

PAPALOTLA GROUP - **Folheto da Brachiaria híbrida cv. Camello**. México, 2022.

PARSONS, A.J., PENNING, P.D. The effect of duration of regrowth on photosynthesis, leaf death and average rate of growth in a rotationally grazed sward. **Grass Forage Science**, v.43, p.15–27. 1988.

PEDREIRA, C.G.S.; BRAGA, G.J.; PORTELA, J.N. Herbage accumulation, plant-part composition and nutritive value on grazed signal grass (*Brachiaria decumbens*) pastures in response to stubble height and rest period based on canopy light interception. **Crop and Pasture Science**, v.68, n.1, p.62-73, 2017. Doi: <https://doi.org/10.1071/CP16333>

PEZZOPANE, J. R. M.; BERNARDI, A. C. C.; BOSI, C.; CRIPPA, P. H.; SANTOS, P. M.; NARDACHIONE, E. C. Assessment of Piatã palisadegrass forage mass in integrated livestock production systems using a proximal canopy reflectance sensor. **European Journal of Agronomy**, v.103, p. 130-139. 2019. Doi: 10.1016/j.eja.2018.12.005

PIZARRO, E.A.; RUÍZ R.R.; ÁVILA F.; LÓPEZ A.; REYES U.; GARCÍA J. A. **Informe anual**. Departamento de Investigación y Desarrollo. Grupo Papalotla. p.420, 2014.

QIN, W.; ZHAO, X.; YANG, F.; CHEN, J.; MO, Q.; CUI, CHEN, C.; HE, S.; LI, Z. Impact of fertilization and grazing on soil N and enzyme activities in a karst pasture ecosystem. **Geoderma**, v.437. 2023. Doi: <https://doi.org/10.1016/j.geoderma.2023.116578>

RABAN, S.; ZEIDEL, E.; SHAVIV, A. Release mechanisms controlled release fertilizers in practical use, in: J.J. MORTWEDT, A. SHAVIV (Eds.), Third Int. Dahlia Greidinger Sym. **On Fertilisation And the Environment**, p.287-295. 1997.

RAJAN, M.; SHAHENA, S.; CHANDRAN, V.; MATHEW, L. Controlled release of fertilizers- cocenpt, reality, and mechanism. In: LEWU, F.B.; VOLOVA, T.; THOMAS, S.; RAKHIMOL, K,R. **Controlled Release Fertilizers for Sustaninable Agriculture**, Academic Press. P. 41-56. 2021. Doi: <https://doi.org/10.1016/B978-0-12-819555-0.00003-0>

RAMOS, B.L.P.; PEDREIRA, M.S.; SANTOS, H.P.; CRUZ, N.T.; PEZENTI, E.; SILVA, A.S.; DIAVÃO, J.; MORENZ, M.J.F.; PITTA, B.S.L. FRIES, D.D. Forage production, morphogenetic and strutural componentes, and nutritional value of tropical grasses in the semiarid condition. **Semina: Ciências Agrárias**, v.43, n.6, p. 2499-2516. 2022a. Doi: 10.5433/1679-0359.2022v43n6p2499

RAMOS, B.L.P.; PEDREIRA, M.S.; CRUZ, N.T.; JARDIM, R.R.; SEIXAS, A.A.; SOUZA, A.S.; NASCIMENTO, L.M.G.; NUNES, J.J.; AMORIM, J.M.S.; EVANGELISTA, V.S.S. Developmental factors for forage plants and their responses under stress conditions. **Research, Society and Development**, v.11, n.14, 2022b. Doi: <http://dx.doi.org/10.33448/rsd-v11i14.35530>

REIS, A.A.; WERNER, J.P.S.; SILVA, B.C.; FIGUEIREDO, G.K.D.A.; ANTUNES, J.F.G.; ESQUERDO, J.C.D.M.; COUTINHO, A.C.; LAMPARELLI, R.A.C.; ROCHA, J.V.; MAGALHÃES, P.S.G. Monitoring Pasture Aboveground Biomass and Canopy Height in an Integrated Crop–Livestock System Using Textural Information from PlanetScope Imagery. **Remote Sensing**, v.12, n.6, 2020. Doi: <https://doi.org/10.3390/rs12162534>

RODRIGUES, H.V.M. **Fósforo e Calagem na Produtividade e Recuperação do Capim Marandu** (Dissertação de Graduação). 2010. Universidade Federal do Tocantins. Gurupi, TO, Brasil.

SANDERSON, M. A., ROTZ, C. A., FULTZ, S. W., RAYBURN, E. B. Estimating forage mass with a commercial capacitance meter, rising plate meter and pasture ruler. **Agronomy Journal**, v.93, p.1281-1286. 2001.

SANTOS, M.E.R.; MARTUSCELLO, J.A. **Seu dinheiro é capim: valorizando e manejando o pasto para gerar dinheiro**. Reino Editorial: São Paulo-SP, p.232, 2022.

SANTOS, W. B. S. **Calcário líquido e calcário convencional na correção da acidez do solo e nas características do Capim-Braúna** (Dissertação de mestrado). Universidade Estadual do Sudoeste da Bahia. Itapetinga-BA, 2020.

SANTOS M.E.R.; FONSECA, D.M. **Adução de Pastagens em Sistemas de Produção Animal**. Editora UFV: Viçosa-MG, p. 311. 2016.

SATURNINO, K.C.; MARIANI, T.M.; FERREIRA, M.B.; BRUM, K. B.; FERNANDES, C.; E.S.; LEMOS. R.A.A. Experimental poisoning by *Brachiaria decumbens* in feedlot sheep. **Pesquisa Veterinária Brasileira**, v. 30, n. 3. 2012. Doi: <https://doi.org/10.1590/S0100-736X2010000300002>

SCHACHTMAN, D.P.; REID, R.J., AYLING, S.M. Phosphorus uptake by plants: from soil to cell. **Plant Physiology**, v.116, n.2, p.447–453. 1998. Doi:<https://doi.org/10.1104/pp.116.2.447>.

SHAHENA.S.; RAJAN, M.; CHANDRAN, V.; MATHEW, L. CONVENTIONAL METHODS OF FERTILIZER RELEASE. IN: LEWU, F.B.; VOLOVA, T.; THOMAS, S.; RAKHIMOL, K,R. Controlled Release Fertilizers for Sustainable Agriculture, **Academic Press**, p.1-24. 2021. Doi: <https://doi.org/10.1016/B978-0-12-819555-0.00001-7>

SILVA, P.H. F., ANJOS, A. N. A., VIEGAS, C. R., MORAIS, L. F., NEPOMUCENO, D. D., CARVALHO, C. L. F. Procedimentos para estimar massa de forragem, interceptação luminosa e índice de área foliar em pastos de capim-Tanzânia. **Archivos de Zootecnia**, v.67, n.259, p. 404–407, 2018. Doi: <https://doi.org/http://dx.doi.org/10.21071/az.v67i259.3797>

SILVA, S.C.; SBRISSIA, A.F.; PEREIRA, L.E.T. Ecophysiology of C 4 forage grasses—understanding plant growth for optimising their use and management. **Agriculture**, v. 5, n.3, p.1–28. 2015. Doi: <https://doi.org/10.3390/agriculture5030598>

SMITH, A.P.; CHRISTIE, K.M.; RAWNSLEY, R.P.; ECKARD, R.J. Fertiliser strategies for improving nitrogen use efficiency in grazed Dairy pastures. **Agricultural Systems**, v.165, p.274-282, 2018. Doi: <https://doi.org/10.1016/j.agsy.2018.06.017>

SOMAVILLA, A.; MARQUES, A.C.R.; CANER, L.; OLIVEIRA, L.B.; QUADROS, F.L.F.; CHABII, A.; TIECHER, T.; SANTOS, D.R. Phosphate fertilization and liming in a trial conducted over 21 years: A survey for greater forage production and Pampa pasture conservation, **European Journal of Agronomy**, v. 125,2021. Doi: <https://doi.org/10.1016/j.eja.2021.126259>.

SUYAMA, H.; BENES, S. E.; ROBINSON, P. H.; GETACHEW, G.; GRATTAN, S. R.; GRIEVE, C. M. Biomass yield and nutritional quality of forage species under long-term irrigation with saline-sodic drainage water: Field evaluation. **Animal Feed Science and Technology**, v.135, n.4, p.329–345. 2007. Doi: <https://doi.org/http://dx.doi.org/10.1016/j.anifeedsci.2006.08.010>

TAIZ, L., ZEIGER, E., MOLLER, I. M., MURPHY, A. **Fisiologia e Desenvolvimento Vegetal**. 6ª ed. Porto Alegre: Artmed, p.848, 2017.

TIAN, Y.; SUN, W.; SONG, M.; ZHAO, Y.; WEN, S.; CUI, Y.; LI, Z.; XU, X. Effects of grass-legume mixture on plant production and inorganic nitrogen acquisition. *Rhizosphere*, v. 20. 2020. Doi: <https://doi.org/10.1016/j.rhisph.2021.100447>

TILLY, N., HOFFMEISTER, D., CAO, Q., HUANG, S., LENZ-WIEDEMANN, V., MIAO, Y., BARETH, G. Multitemporal crop surface models: Accurate plant height measurement and biomass estimation with terrestrial laser scanning in paddy rice. **Journal of Applied Remote Sensing**, v.8, 2014. Doi: <https://doi.org/10.1117/1.JRS.8.083671>

VALLE, C.B. et al. Brachiaria In: Fonseca, D.M.; Martuscello, J.A. (ed.) **Plantas Forrageiras**. 2ed Viçosa:Editora UFV, p.23-76, 2022.

VALLE, C.B.; EUCLIDES, V.P.B.; MONTAGNER, D.B.; CALÉRIO, J.R.; FERNANDES, C.D.; MACEDO, M.C.M.; VERZIGNASSI, J.R.; MACHADO, L.A.Z. BRS Paiaguás: A new Brachiaria (*Urochloa*) cultivar for tropical pastures in Brazil. **Tropical Grasslands**, v.1, p.121-122, 2013. Doi: [https://doi.org/10.17138/tgft\(1\)121-122](https://doi.org/10.17138/tgft(1)121-122)

VALLE, C.B.; SIMIONI, C.; RESENDE, R.M.S.; JANK, L.; CHIARI, L. Melhoramento genético de Brachiaria. In: Resende, R.M.S.; Valle, C.B.; Jank, L. (Eds.) **Melhoramento de Forrageiras Tropicais**. 1ª ed. Campo Grande, Embrapa. p. 13-53. 2008.

VALLE, C. B. Avaliação de Germosplasma e Melhoramento genético de Braquiárias. In: PAULINO, V.T. et al. In: **Encontro para discussão sobre capins do gênero Brachiaria**, 2, 1991, Anais... Nova Odessa, Instituto de Zootecnia, p. 301-342, 1991.

VILELA, L.; MARTHA JR, G.B.; SOUSA, D.M.G. Efeito de adubação anual com nitrogênio e fósforo no desempenho produtivo de bovinos em recría e *Urochloa decumbens* cv. Basilisk. **Boletim de Pesquisa e Desenvolvimento** 361 – EMBRAPA, p.22, 2020.

VILJANEN, N.; HONKAVAARA, E.; NASI, R.; HAKALA, T.; NIEMELAINEN, O.; KAIVOSOJA, J. Novel Machine Learning Method for Estimating Biomass of Grass Swards Using a Photogrammetric Canopy Height Model, Images and Vegetation Indices Captured by a Drone. **Agriculture**, v.8, n.5, p. 70, 2018. Doi: <https://doi.org/10.3390/agriculture8050070>

WACHENDORF, M.; FRICKE, T.; MÖCKEL, T. Remote sensing as a tool to assess botanical composition, structure, quantity and quality of temperate grasslands. **Grass Forage Science**, v.73, n.1, p.1-14, 2017.

WALLACE, L.; HILLMAN, S.; REINKE, K.; HALLY, B.; KRITICOS, D. Non-destructive estimation of above-ground surface and near-surface biomass using 3D terrestrial remote sensing techniques. **Methods in Ecology and Evolution**, v. 8, n.11, p.1607-1616, 2017. Doi: <https://doi.org/10.1111/2041-210X.12759>

WANG, D.; LV, S.; JIANG, P.; LI, Y. Roles, regulation, and agricultural application of plant phosphate transporters. **Frontiers in Plant Science**, v.8, p.1–14. 2017. Doi: <https://doi.org/10.3389/fpls.2017.00817>.

WEERASINGHAIE, P.; PRAPAGAR, K.; DHARMASENA, K.M.C. Nitrogen Release Patterns of Urea and Nano Urea Fertilizer Under Two Contrasting Soil Moisture Regimes. **IJAFFP**, v.4, p. 10-17. 2016.

WOEBBECKE, D.M., MEYER, G.E., VON BARGEN, K.& MORTENSEN, D.A. Color indices for weed identification under various soil, residue, and lighting conditions. **Transactions of the ASAE**, v. 38, n.1, p.259–269. 1995.

YANG, Z.; WILLIS, P.; MUELLER, R. Impact of band-ratio enhanced AWIFS image to crop classification accuracy. **Pecora**, v. 17, p.18–20. 2008.

ZHU, Y.; ZHENG, W.; MONACO, T.; NAERKECI, LI, S. Effects of Aboveground Community Structure and Belowground Root Morphological Characteristics on Nitrogen Use Efficiency of Mixed-Perennial Legume-Grass Pastures. **Rangeland Ecology & Management**, v.83, p.59-68, 2022. Doi: <https://doi.org/10.1016/j.rama.2022.03.004>.

## II – OBJETIVO

### 2.1 OBJETIVO GERAL

Verificar o potencial correlativo dos índices gerados a partir do sensor RGB com as variáveis do pasto, para estimar a massa de forragem e a composição química de gramíneas forrageiras.

### 2.2 OBJETIVOS ESPECÍFICOS

- ✓ Determinar a produção de massa verde e seca das gramíneas em função das diferentes fontes de fertilizantes;
- ✓ Determinar a produção dos componentes morfológicos das gramíneas em função das diferentes fontes de fertilizantes;
- ✓ Determinar o teor de matéria seca e proteína bruta das gramíneas em função das diferentes fontes de fertilizantes;
- ✓ Mensurar o índice GLI (Green Leaf Index), ExG (Excess Green) e MPRI (Modified Photochemical Reflectance Index) das gramíneas em função das diferentes fontes de fertilizantes;
- ✓ Extrair o modelo digital de vegetação (MDV) das gramíneas em função das diferentes fontes de fertilizantes;
- ✓ Correlacionar as variáveis do pasto com os índices de vegetação;
- ✓ Analisar os modelos preditivos para estimar a produção e a qualidade da massa forrageira da pastagem;

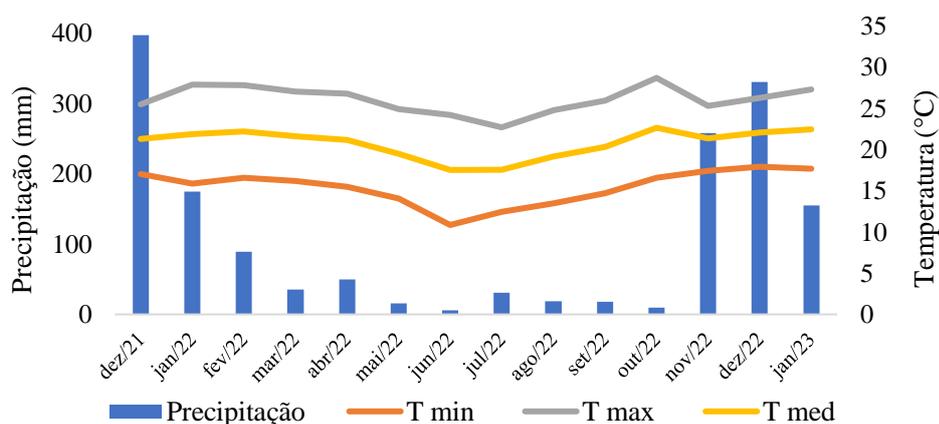
- ✓ Mensurar o desempenho dos modelos preditivos da produção e do teor de matéria seca e proteína bruta da massa forrageira da pastagem;

### III – MATERIAL E MÉTODOS

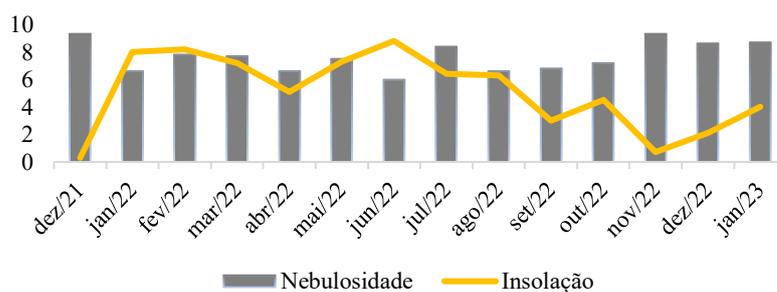
#### 3.1 Área experimental e caracterização do clima

O experimento foi conduzido entre dezembro de 2021 a janeiro de 2023, no campo experimental de Forragicultura e Pastagens da Universidade Estadual do Sudoeste da Bahia (UESB; Vitória da Conquista – BA) ( $14^{\circ}52'58.66''$  S; $40^{\circ}47'33.839''$  W; 892 m de altitude). Segundo Köppen, o clima da região é classificado como tropical de altitude, com chuvas no verão e seca no inverno (tipo Cwb).

A figura 1, mostra a precipitação pluviométrica e a temperatura durante o período experimental, e na figura 2 os índices de nebulosidade e insolação obtidos pela Estação Meteorológica de Vitória da Conquista, localizada na Universidade Estadual do Sudoeste da Bahia (UESB) INMET (2023).



**Figura 1.** Precipitação pluviométrica, temperatura mínima (T min), temperatura máxima (T max) e temperatura média (T med) de dezembro de 2021 a janeiro de 2023



**Figura 2.** Nebulosidade (na escala, 0 a 10, onde 0 não tem nuvens e 10 totalidade encoberta) e insolação (quantidade de horas que o disco solar é visível) de dezembro de 2021 a janeiro de 2023.

### 3.2 Característica físico-química do solo

O solo é classificado como Latossolo Vermelho Amarelo (Embrapa & Sudene, 1973). Para determinação da composição físico-química do solo, realizou-se a coleta de 25 pontos amostrais da área experimental de forma aleatória. Em cada ponto, utilizou-se um trado tipo sonda de aço inoxidável, com ponteira de aço carbono (Soloteste<sup>®</sup>, Bela Vista, SP, Brasil), para a retirada do solo na camada 0 – 20 cm. Após a amostragem dos 25 pontos, realizou-se a homogeneização dessas amostras, recolhendo alíquota de 200 g de solo para a obtenção de uma amostra composta, na qual foi destinada ao laboratório para análise.

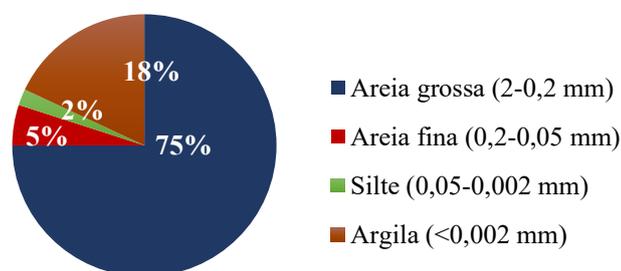
A determinação do pH do solo em H<sub>2</sub>O foi realizado por meio de três leituras utilizando pHmetro digital de bancada (Tecnapon mPA-210, Piracicaba, SP, Brasil). A concentração de P, K e Na foi determinada por meio da metodologia de Mehlich (1984); o Ca, Mg e Al foram mensurados por KCl a 1N e hidrogênio (H) por solução de CaCl<sub>2</sub> 0,01M e solução tampão SMP (Shoe-Maker, McLean & Prat) (Shoemaker et al., 1961) (Tabela 1).

**Tabela 1.** Análise química do solo

pH (H <sub>2</sub> O)	mg/dm <sup>3</sup>		Cmol <sub>c</sub> /dm <sup>3</sup> de solo							% mg/dm <sup>3</sup>		
	P	K <sup>+</sup>	Ca <sup>2+</sup>	Mg <sup>2+</sup>	Al <sup>3+</sup>	H <sup>+</sup>	Na <sup>+</sup>	SB <sup>1</sup>	t <sup>2</sup>	T <sup>3</sup>	V <sup>4</sup>	MO.
5,7	8	0,49	1,5	0,8	0,1	1,7	-	2,8	2,9	4,6	61	10

P: fósforo; K: potássio; Ca: Cálcio; Mg: Magnésio; Al: Alumínio; H: Hidrogênio; Na: Sódio; SB: Soma de Bases Trocáveis; t: Capacidade de troca de cátions efetiva; T: capacidade de troca de cátions a pH 7,0; V: Saturação de Bases; MO: Matéria Orgânica.

<sup>1</sup>SB = Ca<sup>2+</sup> + K<sup>+</sup> + Mg<sup>2+</sup> + Na<sup>+</sup>; <sup>2</sup>t = SB + Al<sup>3+</sup>; <sup>3</sup>T = t + H<sup>+</sup>; <sup>4</sup>V = (SB/T) × 100.



**Figura 3.** Composição granulométrica do solo.

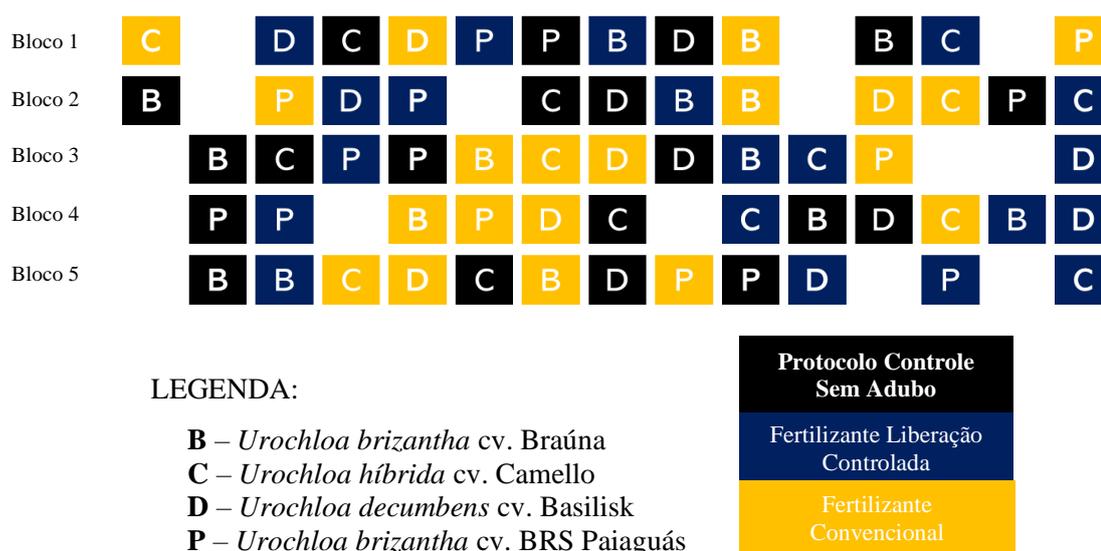
Desta forma, o solo apresenta uma acidez média apresentada pelo pH (5,7), um teor de fósforo (P) baixo, ao correlacionar o teor de 8 mg/dm<sup>3</sup> com 18% de teor de argila, indicado um solo de textura franco arenosa (Figura 3). Cálcio (Ca), Magnésio

(Mg) trocáveis médios e uma CTC pH 7 (T) média. A saturação por bases (V) acima de 61% é retratada como boa. Uma classificação muito boa para o teor de Matéria Orgânica (MO) a 10% e para o teor de potássio (K), conforme a Comissão de Fertilidade do Solo do Estado de Minas Gerais (CFSEMG,1999).

### 3.3 Delineamento experimental e implantação dos tratamentos

O estudo foi delineado em blocos casualizados em esquema fatorial, sendo quatro gramíneas e três protocolos de fertilização. As gramíneas foram: *U. brizantha* cv. Braúna, *U. brizantha* cv. BRS Paiaguás; *U. decumbens* cv. Basilisk e *U. híbrida* cv. Camello. Os protocolos como fonte de fertilizantes, foram: sem fertilizante [controle (CTRL)], fertilizante convencional (FC), e fertilizante com fonte de liberação controlada (LC).

Destarte, o estudo possuía doze tratamentos a serem avaliados, que foram distribuídos em blocos casualizados com cinco repetições, em parcelas de 64 m<sup>2</sup> (8 x 8 m), com espaçamento de 1 metro entre blocos, apresentando 55 parcelas, conforme a figura 4.



**Figura 4.** Croqui da área experimental, representação da distribuição dos tratamentos nos blocos

A fonte de fertilizante convencional (FC) foi composto por ureia agrícola (45% de N), superfosfato simples (18% de P<sub>2</sub>O<sub>5</sub>; 16% de Ca e 10% de S) e cloreto de potássio (58% de K<sub>2</sub>O).

A fonte de fertilizante de liberação controlada (LC) constituído pelos fertilizantes Top-phos 328 master (3% de N e 28% de  $P_2O_5$ ; traços de ácido sulfúrico) e Sulfammo Meta 21 (21% de N; 2% de  $P_2O_5$  ; 9% de  $K_2O_5$ ; 4% de Ca; 10% de S; 1% de Mg; 0,2% de B; 0,2 % de Mn; 0,2% de Zn; 0,1% de Cu, ácido sulfúrico 1 a 3%; traços de sulfato de cálcio e ácido sulfúrico) (Timac Agro<sup>®</sup>, Porto Alegre, RS, Brasil).

As gramíneas foram semeadas no dia 3 de dezembro de 2021, em parcelas distribuídas em delineamento de blocos casualizados com cinco repetições em cada tratamento, em parcelas de 64 m<sup>2</sup> (8 x 8 m), com 1 metro de espaçamento entre os blocos (repetições), conforme apresentado na figura 4.

A aplicação dos fertilizantes foi determinada com base nos resultados da análise físico-química das amostras do solo, conforme as recomendações da Comissão de Fertilidade do solo do Estado de Minas Gerais (CFSEMG, 1999; Santos et al., 2010). A dosagem recomendada para as fontes de NPK [Nitrogênio (N), fósforo (P) e potássio (K)] foi de 128 kg ha<sup>-1</sup> de N, 30 kg ha<sup>-1</sup> de  $P_2O_5$  e 4,5 kg ha<sup>-1</sup> de  $K_2O$ .

No momento da semeadura realizou-se a aplicação dos adubos para atingir a exigência do solo em P, ou seja, nas parcelas identificadas pelos tratamentos de fertilizante convencional, o superfosfato simples; e nas parcelas pertencentes aos tratamentos dos fertilizantes de liberação controlada, o Top-phos 328 master.

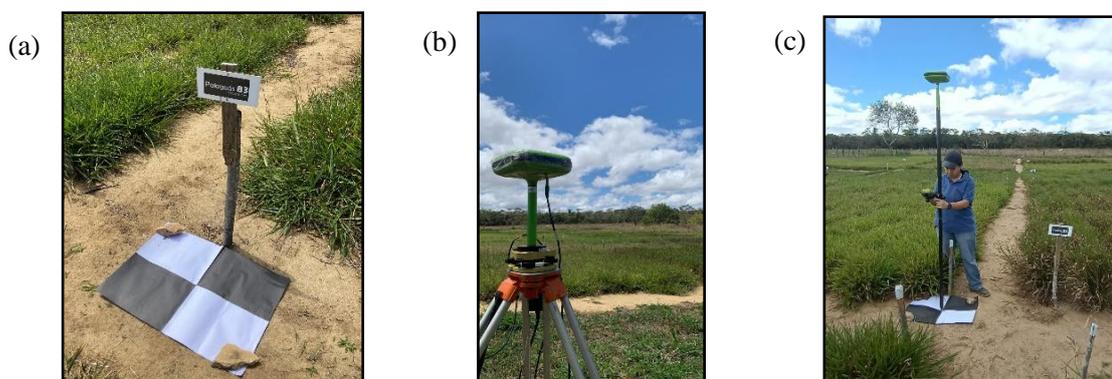
O fornecimento dos fertilizantes para atender as exigências de N e K, foram realizadas quando as plantas apresentaram 70% da cobertura vegetal no solo CFSEMG (1999). No caso do nitrogênio, sua aplicação foi subdividida em três momentos, sendo eles: após a semeadura, quando as plantas apresentaram 70% da cobertura vegetal do solo (50 kg N ha<sup>-1</sup>), após a primeira colheita (50 kg N ha<sup>-1</sup>) e na quinta colheita (28 kg N ha<sup>-1</sup>). A aplicação do N na quinta colheita teve como objetivo impulsionar o crescimento das plantas, visto que, essas gramíneas atravessaram um período de quase seis meses sem condições de temperatura e precipitação pluviométrica adequadas para desenvolvimento.

Deste modo, nos tratamentos de FC foram aplicados 284,5 kg ha<sup>-1</sup> de ureia (45% de N), 166,7 kg ha<sup>-1</sup> supersimples (18% de  $P_2O_5$ ) e 7,7 kg ha<sup>-1</sup> de cloreto de potássio (58% de  $K_2O$ ). Enquanto, nos tratamentos com os fertilizantes LL foram aplicados 595,3 kg ha<sup>-1</sup> do Sulfammo Meta 21 (21% de N) e 100 kg ha<sup>-1</sup> do Top-Phos 328 master (28% de  $P_2O_5$  e 9% de  $K_2O$ ). As dosagens dos fertilizantes são diferentes por conta da

composição de cada produto, mas, a exigência dos nutrientes NPK foram fixos, baseadas nas análises físico-química do solo, conforme descrito anteriormente.

### 3.4 Aquisição das imagens RGB

Foi realizado o georreferenciamento da área experimental, na qual, foram distribuídos dez pontos de controle (PC) (Figura 5a), fixados na base das estacas das parcelas para a obtenção das coordenadas geográficas. As coordenadas dos pontos de controle foram medidas por meio de um equipamento geodésico com receptor de RTK (Figura 5b). Além disso, para cada vértice (torno) de cada parcela foi registrada uma coordenada geográfica (Figura 5c), para auxiliar na demarcação das parcelas no processamento com softwares.



**Figura 5.** Ponto de controle (a), equipamento RTK (b), mensuração do ponto de controle (c).

As imagens foram obtidas por um sensor RGB acoplado em aeronave remotamente pilotada (ARP). Um quadricóptero DJI Phantom 4 Advanced, com câmera de sensor semicondutor de óxido de metal complementar (CMOS) de 20 megapixel, montado em um gimbal (Figura 6). Possuindo as configurações de distância focal 9 mm e abertura máxima de 2.97. O receptor GNSS (sistema global de navegação por satélite) incorporado, juntamente com um sistema de controle de navegação, permite missões de voos autônomas usando planos de voo pré-carregados.



**Figura 6.** Detalhamento do equipamento

As missões de captura de imagem foram determinadas conforme a altura de manejo de cada cultivar avaliada, sendo elas: 50 cm para Braúna, 40 cm para Camello e 30 cm para Basilisk e BRS Paiaguás (Fonseca & Martuscello, 2022; Papalotla, 2022), em que a altura do resíduo (corte) foi estabelecido em 50% da altura inicialmente estabelecida. Mensuradas com régua graduada em centímetros, em 10 pontos amostras dentro da área útil de cada parcela. No total, foram realizadas quatro missões em: fevereiro, setembro e novembro de 2022 e janeiro de 2023; nos quais foram organizadas em período seco e período chuvoso.

Cada missão realizada foi planejada utilizando o software DroneDeploy (DroneDeploy Inc., San Francisco, CA, EUA) em um smartphone e carregada na controladora do ARP, cobrindo 8.000 m<sup>2</sup>, de forma autônoma a 20 e 100 metros acima do nível do solo, configurados a capturar imagens com 80% de sobreposição lateral e frontal, com a orientação da câmera a 90°. Foram realizadas entre 10 e 12 horas da manhã, sob a observância de baixa incidência de nuvens, ventos e sombreamento.

A Tabela 2, expressa as características dos itens gerados a partir das configurações estabelecidas no plano de voo, bem como, dos produtos gerados após o processamento das imagens, conforme a altura de voo.

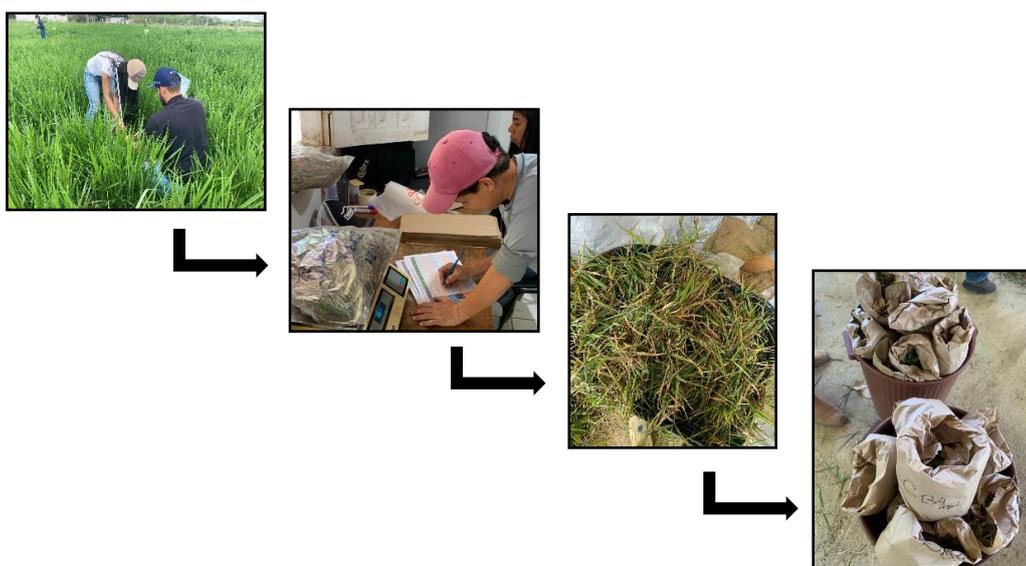
**Tabela 2.** Características dos produtos, a partir das configurações estabelecidas de voo

	QF <sup>1</sup>	TMV <sup>1</sup> minutos	GR <sup>2</sup> cm/pix	EMT <sup>2</sup> cm
20 m	340	20	0,52	3,15
100 m	25	7	2,68	9,99

<sup>1</sup>Produtos obtidos do plano de voo; <sup>2</sup>Produtos obtidos pelo processamento das imagens; QF: quantidade de fotos; TMV: tempo médio do voo; GR: resolução terrestre; EMT: erro médio total (leste, norte e altitude).

### 3.5 Amostragem da massa de forragem

A amostragem ocorreu após a captura da imagem. Foram colhidas duas amostras por parcela, coletado de forma aleatória uma moldura quadrada de 1 m<sup>2</sup> sobre a área útil da parcela (48 m<sup>2</sup>), respeitando a altura de resíduo de cada gramínea, posteriormente pesadas frescas, homogêneas e retiradas duas de aproximadamente 300 g cada, uma destinada a secagem do material total e outra para o fracionamento dos componentes morfológicos (figura 7), em estufa com ar de circulação forçada a 55°C.



**Figura 7.** Etapas da avaliação da massa de forragem: corte, pesagem, homogeneização e separação das alíquotas. Fonte: Ramos, 2023

### 3.6 Mensuração das características do pasto

Após a retirada do material para determinação da massa de forragem, foi determinada a densidade populacional de perfilhos (DPP), em cada parcela, utilizando um quadro menor de 0,04 m<sup>2</sup>, sob a área cortada para mensuração e realizando a contagem dos perfilhos vivos, conforme Paciullo et al. (2021).

A produtividade da massa seca (PMS) do pasto foi mensurada com base nas duas amostragens em cada parcela, sob a representação dos valores de peso da amostra e área amostrada. A taxa de acúmulo (kg MS ha<sup>-1</sup> dia<sup>-1</sup>) foi calculada dividindo a produção de massa seca (PMS) no ciclo pelo número de dias de rebrota. A eficiência do uso da água (EUA) foi estimada dividindo-se a massa de forragem pela quantidade de chuva acumulada durante o ciclo até o momento do corte (Souza et al., 2016).

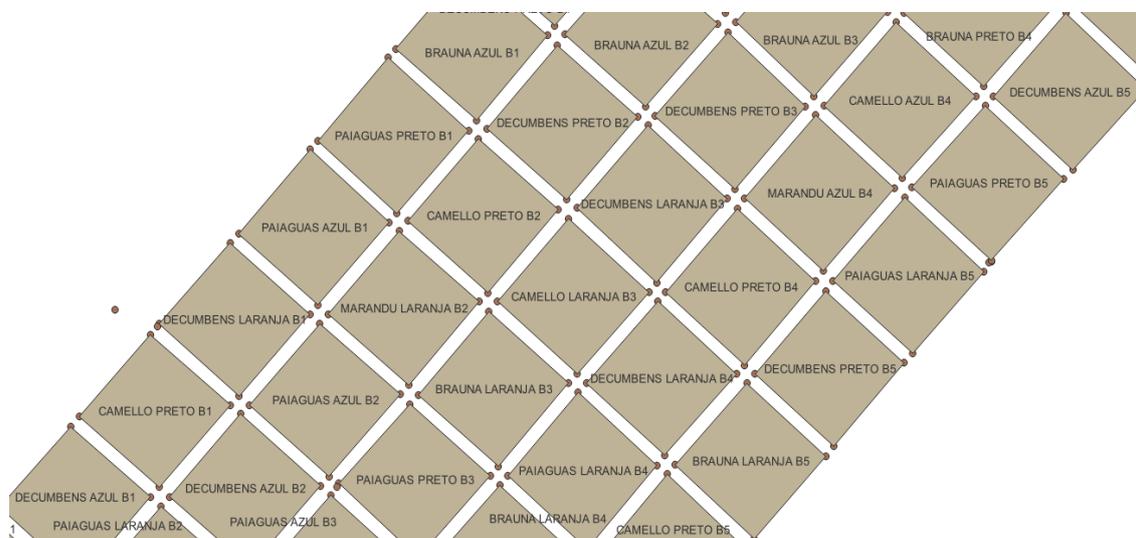
A relação folha:colmo (F/C) foi determinada fracionando os diferentes componentes morfológicos em folha, colmo + bainha, senescente e inflorescência, posteriormente, as amostras foram secas em estufa de ar forçado a 55 °C e moídas (Wiley mil; A. H. Thoma, Philadelphia, PA, USA) em peneira de 1 mm para as análises químico-bromatológicas.

Os teores de matéria seca [(MS) método 942.05)] e proteína bruta [(PB) método 990.03] e cinzas [(MM) método 942.05)] foram determinados de acordo com a AOAC International (2012) .

### 3.6 Processamento das imagens e análise de dados

Os conjuntos de dados das imagens RGB foram processados no software de fotogrametria Agisoft PhotoScan (v. 1.5.1, Agisoft LLC, São Petersburgo, Rússia). O software apresenta o algoritmo Structure from Motion (SfM) para costurar e estimar uma nuvem de pontos 3D a partir de imagens sobrepostas (Verhoeven, 2011). O fluxo de trabalho no software foi implementado de acordo com Schirrmann et al. (2016) e ajustado, constituindo-se nas seguintes etapas: importação das coordenadas dos pontos de controle, importação das imagens, calibração da câmera, conversão e configuração das coordenadas geográficas, análise das imagens, alinhamento das imagens resultando em uma nuvem esparsa, ajuste das imagens usando os PC, construção da nuvem densa de pontos, classificação dos pontos de solo; construção do modelo digital de superfície (MDS) e modelo digital do terreno (MDT) e ortomosaico.

Para a obtenção dos índices vegetativos utilizou-se o ortomosaico, e para o índice vertical o MDS e MDT, processados no software Quantum Gis. O processo foi iniciado com construção das camadas (shapefile) de identificação dos tratamentos em estudo, criadas a partir dos pontos geográficos de cada vértice na parcela (Figura 8).



**Figura 8.** Pontos geográficos ligados nos vértices para a delimitação de cada parcela experimental.

A extração dos dados do índice vertical MDV, utilizou-se as camadas MDS e MDT, empregando a seguinte equação:

$$MDV = MDS - MDT$$

Para a obtenção dos índices de vegetação utilizando as camadas RGB, utilizou-se o ortomosaico, em que:

O Green Leaf Index (GLI) (Louhaichi et al., 2001), conhecido também por índice de folha verde, utiliza as bandas RBG (Red, Blue e Green), foi mensurado por meio da equação:

$$GLI = \frac{(2 * G) - R - B}{(2 * G) + R + B}$$

O índice Modified Photochemical Reflectance Index (MPRI) (Yang et al., 2008), também conhecido como índice de reflectância fotoquímico modificado, utiliza as bandas RG (Red e Green), foi mensurado por meio da equação:

$$MPRI = \frac{R - G}{R + G}$$

O índice Excess Green (ExG) (Woebbecke et al., 1995), conhecido como Excesso de Verde, utiliza as bandas RGB (Red, Green, Blue), foi mensurado por meio da equação:

$$ExG = \left( \frac{2 * (G)}{R + G + B} \right) - \left( \frac{R}{R + G + B} \right) - \left( \frac{B}{R + G + B} \right)$$

Os valores obtidos para cada índice foram extraídos pela média da parcela em uma camada (shapefile). Os dados numéricos de MDV, GLI, MPRI, ExG, para cada tratamento foi obtido por meio do processamento da estatística zonais, com o auxílio da camada de identificação de cada tratamento, extraído no formato \*.xlsx, para as análises dos dados.

### 3.7 Análise estatística

Em primeiro momento, os tratamentos foram analisados conforme a observar a interação entre gramíneas e fertilização no decorrer de um ciclo produtivo (um ano), um fatorial 3 (protocolos) x 4 (gramíneas). A normalidade dos resíduos (Shapiro-Wilk;  $P > 0,05$ ) e homogeneidade das variâncias foram avaliadas antes do ajuste do modelo (Lilliefors test;  $P > 0.05$ ). As variáveis que não obedeceram a estes critérios foram transformadas utilizando o procedimento Box-Cox (Box & Cox, 1964). Os dados foram analisados usando o PROC MIXED do SAS versão 9.3 (SAS/STAT, SAS Institute Inc., Cary, NC, USA). O modelo considerou como efeito fixo a gramínea, o protocolo de fertilização e a interação entre gramínea e protocolo de fertilização e como efeito aleatório o bloco. O procedimento Kenward-Roger foi utilizado para determinar o grau de liberdade do denominador para testar os efeitos fixos. As médias dos mínimos quadrados de gramínea e protocolo de fertilização foram comparadas usando o teste de Tukey considerando  $P \leq 0,05$ .

Em relação a construção dos modelos preditivos, os dados foram organizados em dois períodos, sendo representados: em período seco, que correspondeu aos meses de abril a agosto de 2022; e o período chuvoso, novembro de 2022 a janeiro de 2023, além disso, conforme as alturas de voo do ARP: 20 e 100 metros da altura do dossel.

As variáveis foram agrupadas, independentemente dos tratamentos (cultivares e fertilizantes), em variáveis do pasto: produção de massa verde (PMV), produção de massa seca (PMS), teor de matéria seca (MS), proteína (PB); e variáveis dos índices de vegetação: GLI, MPRI, ExG; e do índice vertical: modelo digital da vegetação (MDV). Todas foram submetidas a uma análise de correlação de Pearson, a 1% de significância.

Para a construção dos modelos preditivos foi usado (aleatoriamente) 70% do banco de dados de cada período, submetendo esses dados a uma regressão linear múltipla pelo método stepwise (por passo), no software SPSS (Statistical Package for the Social Science). Os demais 30% dos dados foram utilizados para a validação dos modelos preditivos por meio da técnica da validação cruzada (Cross-validation), e o desempenho dos modelos foram avaliados pelas métricas de avaliação da regressão, sendo elas:

- Erro Médio Absoluto (MAE):

$$MAE = \frac{1}{n} \sum (O - P)$$

Em que:

$n$  é a quantidade de observações

$O$  é valor real observado

$P$  é o valor predito

Logo, o MAE é a média das distâncias entre os valores reais e preditos, com valor mínimo de 0.

- Raiz do Erro Quadrático Médio (RMSE):

$$RMSE = \sqrt{\frac{\sum (O - P)^2}{n}}$$

Em que:

$n$  é a quantidade de observações

$O$  é valor real observado

$P$  é o valor predito

Logo, o RMSE é uma medida do desvio médio entre os dados observados e os preditos, quanto menor os seus valores, melhor será considerado os modelos.

- Coeficiente de Eficiência (E):

$$E = 1 - \left( \frac{\sum (O_i - P_i)^2}{\sum (O_i - O_m)^2} \right)$$

Em que:

$O_i$  é o valor observado

$P_i$  é o valor predito

$O_m$  é a média dos valores observados

O coeficiente de eficiência (E) foi proposto por Nash e Sutcliffe (1970), para avaliar a concordância entre o modelo e as observações. Conforme Liew et al., (2007), a E pode ser interpretada da seguinte maneira:  $E > 0,75$  indicam boa performance, valores entre 0,75 e 0,36 considerados satisfatórios e  $E < 0,36$  considerados insatisfatórios.

- Índice de Concordância de Willmott ( $C_w$ ):

$$C_w = 1 - \frac{\sum(O_i - P_i)^2}{\sum(O_i - O_m)^2 + \sum(P_i - O_m)^2}$$

$O_i$  são os valores observados

$P_i$  são os valores previstos pelo modelo;

$O_m$  é a média dos valores observados.

Esse índice varia de 0 a 1. Quanto mais próximo o  $C_w$  estiver de 1, melhor a concordância entre os valores observados e as previsões do modelo. Para avaliar o desempenho classificou-se os resultados em: alta ( $>0,7$ ), médio (0,5 e 0,7) e baixo ( $<0,5$ ).

## IV – RESULTADOS

### 4.1 Gramíneas x Fertilização: características do pasto

Não houve interação significativa entre gramínea e protocolo de fertilização para nenhuma das variáveis ( $P > 0,05$ ). Assim, os resultados e a discussão foram analisados separadamente, para gramínea e para os protocolos (fonte de fertilizantes) de fertilização.

A produção e acúmulo de MS difere entre as gramíneas ( $P < 0,05$ ; Tabela 3). O capim Braúna se destaca pela alta PMST ( $P > 0,05$ ), atingindo  $2271 \text{ kg ha}^{-1}$ . Esse valor representa um acréscimo de 15,98%, 29,03% e 36,23% perante os capins Camello, Basilisk e BRS Paiaguás, respectivamente. No entanto, não houve diferença significativa na PMST entre o capim Braúna e o capim Camello (Tabela 3), que registrou  $1958 \text{ kg ha}^{-1}$ .

**Tabela 3.** Produtividade da massa seca forrageira total e dos componentes morfológicos de gramíneas do gênero *Urochloa*.

Item <sup>1</sup>	Basilisk	Braúna	Camello	BRS	SEM <sup>2</sup>	P-valor
				Paiaguás		
PMST kg ha <sup>-1</sup>	1760 <sup>b</sup>	2271 <sup>a</sup>	1958 <sup>ab</sup>	1667 <sup>b</sup>	112,0	<0,01
Folha kg ha <sup>-1</sup>	934 <sup>b</sup>	1197 <sup>a</sup>	913 <sup>b</sup>	1064 <sup>ab</sup>	65,4	<0,01
Colmo kg ha <sup>-1</sup>	831 <sup>a</sup>	1015 <sup>a</sup>	1086 <sup>a</sup>	625 <sup>b</sup>	87,2	<0,01
Senescente kg ha <sup>-1</sup>	72,1 <sup>b</sup>	167,5 <sup>a</sup>	103,6 <sup>ab</sup>	60,2 <sup>b</sup>	25,32	0,01

<sup>1</sup>Item: PMST: produção de massa seca total; Folha: produção de massa seca da folha; Colmo: produção de massa seca do colmo; Material morto: produção de massa seca senescente. <sup>2</sup>SEM = erro padrão da média. Médias seguidas pela mesma letra na linha não diferem pelo teste de Tukey ( $P < 0,05$ ).

O capim Braúna apresentou maior produção de Folha ( $1197 \text{ kg ha}^{-1}$  de MS de folha), não diferindo da BRS Paiaguás ( $1064 \text{ kg ha}^{-1}$  de MS de Folha) ( $P > 0,05$ ; Tabela 3). Os demais capins (Basilisk e Camello) obtiveram produção de folha inferior a 1000

kg ha<sup>-1</sup> (Tabela 3), não diferindo entre si, inclusive da cv. BRS Paiaguás ( $P > 0,05$ ; Tabela 3).

As maiores produções de colmo foram registradas pelas cultivares Camello e Braúna (Tabela 3). A menor produção de colmo foi observada pela cultivar BRS Paiaguás, diferindo ( $P < 0,05$ ) das demais cultivares, em que, a quantidade de colmo por hectare foi inferior em 42,45%, 38,42% e 24,79% para os capins Camello, Braúna e Basilisk, respectivamente.

As gramíneas apresentaram diferenças na composição morfológica ( $P < 0,05$ ; Tabela 4), em que, a BRS Paiaguás foi a cultivar que apresentou a maior proporção de folhas e a menor de colmo, com 65 g/kg e 32,7% g/kg, respectivamente, o que contribuiu para uma maior relação F/C, 2,6, em comparação com as demais avaliadas (Tabela 4).

**Tabela 4.** Composição morfológica da massa verde, características estruturais e eficiência do uso de água de gramíneas do gênero *Urochloa*.

Item <sup>1</sup>	BRS				SEM <sup>2</sup>	P-valor
	Basilisk	Braúna	Camello	Paiaguás		
Folha g/kg	54,7 <sup>b</sup>	55,7 <sup>b</sup>	43,6 <sup>c</sup>	65,0 <sup>a</sup>	1,49	<0,01
Colmo g/kg	43,2 <sup>ab</sup>	40,2 <sup>b</sup>	45,7 <sup>a</sup>	32,7 <sup>c</sup>	1,43	<0,01
Inflorescência g/kg	3,1 <sup>b</sup>	3,4 <sup>b</sup>	8,7 <sup>a</sup>	2,4 <sup>b</sup>	0,59	<0,01
Senescente g/kg	4,5	5,3	4,5	4,0	0,96	0,85
F/C	1,5 <sup>b</sup>	1,6 <sup>b</sup>	1,2 <sup>c</sup>	2,6 <sup>a</sup>	0,17	<0,01
DPP Perfilho.m <sup>2</sup>	742 <sup>b</sup>	1212 <sup>a</sup>	745 <sup>b</sup>	663 <sup>b</sup>	26,1	<0,01
EUA kg de MS mm <sup>-1</sup>	16,7	22,9	22,2	17,4	2,38	0,14

<sup>1</sup>Item: F/C: relação folha colmo; DPP: densidade populacional de perfilhos; EUA: eficiência do uso de água. <sup>2</sup>SEM = erro padrão da média. Médias seguidas pela mesma letra na linha não diferem pelo teste de Tukey ( $P < 0,05$ ).

A cultivar Camello foi a forrageira que apresentou a maior proporção de colmo (45,7 g/kg) e inflorescência (8,7 g/kg), resultando na menor relação F/C, de 1,2, entre as cultivares (Tabela 4). Conseqüentemente, o componente folha foi o menor (43,6 g/kg) observado dentre as gramíneas.

O capim Braúna apresentou incrementos entre 63,34% e 82,80%, quando comparado com as cultivares Basilisk e BRS Paiaguás, respectivamente. Entretanto, essa quantidade de perfilhos não influenciou a eficiência do uso de água (EUA) entre as

gramíneas, que não diferiram ( $P > 0,05$ ; Tabela 4) e obtiveram uma conversão média de 19,8 kg de MS para cada mm de água disponível pela precipitação pluviométrica (Tabela 4).

O teor de MS, MM e PB diferiu ( $P < 0,05$ ) entre as gramíneas (Tabela 5). A *Urochloa brizantha* cv. Braúna apresentou maior teor de MS, com 306 g/kg, e de PB, com 131 g/kg, entre as cultivares. Em relação à matéria mineral, as cultivares Basilisk e Paiaguás apresentaram maior concentração, com 75 e 72 g/kg de MS, respectivamente. E as demais gramíneas apresentaram valores entre 262 e 283 g/kg de matéria seca em sua composição.

**Tabela 5.** Teor de matéria seca, matéria mineral e proteína bruta de gramíneas do gênero *Urochloa*.

Item, g	Basilisk	Braúna	Camello	BRS Paiaguás	SEM <sup>2</sup>	P-valor
MS g/kg	262 <sup>b</sup>	306 <sup>a</sup>	283 <sup>ab</sup>	265 <sup>b</sup>	8,8	<0,01
MM g/kg de MS	75 <sup>a</sup>	65 <sup>b</sup>	66 <sup>b</sup>	72 <sup>a</sup>	1,4	<0,01
PB g/kg de MS	118 <sup>b</sup>	131 <sup>a</sup>	108 <sup>b</sup>	114 <sup>b</sup>	3,2	0,01

<sup>1</sup>Item: MS: matéria seca; MM: matéria mineral; PB: proteína bruta. <sup>2</sup>SEM = erro padrão da média; médias seguidas pela mesma letra na linha não diferem pelo teste de Tukey ( $P < 0,05$ ).

O teor de PB para as gramíneas tropicais avaliadas apresentou entre 108 e 131 g/kg de PB na MS, em que, a cv. Braúna alcança o maior teor e a cv. Camello o menor valor, diferindo entre si ( $P < 0,05$ ) (Tabela 5). É importante destacar que o teor proteico da cultivar Braúna foi superior em 21,29% m 14,91 e 11,02%, respectivamente, em comparação com as cultivares Camello, Paiaguás e Basilisk.

A fertilização com diferentes fontes de liberação de N não influenciou a produção de PMST ( $P = 0,46$ ), bem como a produção MS de folha, colmo e material morto ( $P > 0,05$ ; Tabela 6). Os valores de PMST variaram em 1851 e 2007 kg ha<sup>-1</sup> e de 974 e 1062 kg ha<sup>-1</sup> da produção de folha.

**Tabela 6.** Produtividade da massa seca forrageira e dos componentes morfológicos em relação aos protocolos de fertilização.

Item <sup>1</sup>	CTRL <sup>2</sup>	FC <sup>3</sup>	LC <sup>4</sup>	SEM <sup>5</sup>	P-valor
PMST kg ha <sup>-1</sup>	2007	1851	1885	102,3	0,46
Folha kg ha <sup>-1</sup>	1045	974	1062	60,2	0,50
Colmo kg ha <sup>-1</sup>	867	873,4	930	78,1	0,98
Senescente kg ha <sup>-1</sup>	92,72	117	92,7	21,93	0,66

<sup>1</sup>Item: PMST: produção de MS total; Folha: produção de MS da folha; Colmo: produção de MS do colmo; Material morto: produção de MS de material morto; <sup>2</sup>CTRL= controle; <sup>3</sup>FC = fonte convencional; <sup>4</sup>LC = liberação controlada; <sup>5</sup>SEM = erro padrão da média. Médias seguidas pela mesma letra na linha não diferem pelo teste de Tukey ( $P < 0,05$ ).

A fertilização não influenciou ( $P > 0,05$ ) a composição morfológica, relação F/C e EUA (Tabela 7). Houve diferença apenas na DPP entre as fontes de fertilizantes ( $P < 0,05$ ), destacando-se a fonte convencional e de liberação controlada, que resultaram em um incremento de 11,62% e 6,70%, respectivamente, em relação ao controle.

**Tabela 7.** Composição morfológica da massa verde em relação aos protocolos de fertilização.

Item <sup>1</sup>	CTRL <sup>2</sup>	FC <sup>3</sup>	LG <sup>4</sup>	SEM <sup>5</sup>	P-valor
Folha g/kg	548	532	562	12,9	0,25
Colmo g/kg	404	409	401	12,3	0,89
Inflorescência g/kg	41	49	38	5,1	0,32
Senescente g/kg	40	52	45	8,3	0,61
F/C	1,8	1,6	1,8	0,15	0,56
DPP Perfilho.m <sup>2</sup>	792 <sup>b</sup>	884 <sup>a</sup>	845 <sup>ab</sup>	22,7	0,01
EUA kg MS mm	19,9	19,9	19,5	2,06	0,98

<sup>1</sup>Item: F/C: relação folha colmo; DPP: densidade populacional de perfilhos; EUA: eficiência do uso de água. <sup>2</sup>CTRL= controle; <sup>3</sup>FC = fonte convencional; <sup>4</sup>LC = liberação controlada; <sup>5</sup>SEM = erro padrão da média. Médias seguidas pela mesma letra na linha não diferem pelo teste de Tukey ( $P < 0,05$ ).

Houve diferença significativa somente para o teor de PB ( $P < 0,05$ ; Tabela 8), observado um incremento de 9% quando há aplicação de fertilizantes, independentemente da fonte do fertilizante (Tabela 8).

**Tabela 8.** Composição dos protocolos de fertilização

Item <sup>1</sup> g	CTRL <sup>2</sup>	FC <sup>3</sup>	LC <sup>4</sup>	SEM <sup>5</sup>	<i>P</i> -valor
MS g/kg	287,0	273,0	275,0	7,6	0,35
MM g/kg de MS	69,5	68,9	69,3	1,2	0,92
PB g/kg de MS	111,0 <sup>b</sup>	121,0 <sup>a</sup>	121,0 <sup>a</sup>	2,8	<0,01

<sup>1</sup>Item: MS: matéria seca; MM: matéria mineral; PB: proteína bruta. <sup>2</sup>CTRL= controle; <sup>3</sup>FC = fonte convencional; <sup>4</sup>LC = liberação controlada; <sup>5</sup>SEM = erro padrão da média. Médias seguidas pela mesma letra na linha não diferem pelo teste de Tukey ( $P < 0,05$ ).

Os teores de MS e MM não diferiram ( $P > 0,05$ ; Tabela 8) referente aos protocolos aplicados. O teor de MS apresenta entre 273 e 287 g/kg e o teor de MM valores entre 68,9 e 69,5 g/kg, ou seja, diferença de 14 e 0,6 g/kg para MS e MM, respectivamente.

## 4.2 Correlações: característica do pasto x índices vegetativos

### 4.2.1 Período Seco

As correlações foram significativas no período seco para as variáveis do pasto e dos índices de vegetação. Apresentando correlações fortes positivas ( $>0,70$ ) (Figura 7) para o índice vertical MDV perante a PMV e PMS, independentemente da altura de voo. O MDV ainda correlaciona positiva e significativamente com a MS (0,69 a 20 metros e 0,51 a 100 metros), e com a PB negativamente (-0,49) a 100 metros (Figura 7).

Período seco: **20 m**

<b>MDV</b>	<b>0,70*</b>	<b>0,74*</b>	<b>0,69*</b>	-0,25
<b>GLI</b>	0,18	0,11	-0,18	<b>-0,43*</b>
<b>MPRI</b>	-0,08	-0,15	<b>-0,41*</b>	-0,21
<b>ExG</b>	0,18	0,11	-0,18	<b>-0,43*</b>
<b>PMV</b>	<b>PMS</b>	<b>MS</b>	<b>PB</b>	

Período seco: **100 m**

<b>MDV</b>	<b>0,79*</b>	<b>0,77*</b>	<b>0,51*</b>	<b>-0,49*</b>
<b>GLI</b>	0,10	0,03	-0,20	<b>-0,40*</b>
<b>MPRI</b>	-0,11	-0,18	<b>-0,41*</b>	-0,19
<b>ExG</b>	0,10	0,03	-0,23	<b>-0,40*</b>
<b>PMV</b>	<b>PMS</b>	<b>MS</b>	<b>PB</b>	

Legenda:

0,99 a 0,70	Forte Positiva
0,69 a 0,40	Média Positiva
0,39 a 0,10	Fraca Positiva
0,09 a -0,09	Insignificativa
-0,39 a -0,10	Forte Negativa
-0,69 a -0,40	Média Negativa
-0,99 a -0,70	Fraca Negativa

\* Correlação é significativa a 1%.

PMV: produção de massa verde; PMS: produção de massa seca; MS: teor de matéria seca; PB: teor de proteína bruta; MDV: modelo digital da vegetação; GLI: Green Leaf Index; MPRI: Modified Photochemical Reflectance Index; ExG: Excess Green.

**Figura 9.** Correlações de Pearson entre as variáveis do pasto e os índices de vegetação, do período seco a 20 e 100 metros de altura do voo.

Os IV's GLI e ExG tem correlações significativas com a PB, para as duas alturas de voo. Com relação ao MPRI há correlação significativa negativa com teor de MS (-0,41), valores esses iguais, tanto a 20 metros quanto a 100 metros (Figura 7). De maneira geral, os IV's obtidos pela composição das bandas RGB (GLI, ExG e MPRI) apresentaram correlações insignificantes para as variáveis produtivas (PMV e PMS) (Tabela 7).

#### 4.2.2 Período Chuvoso

O período chuvoso apresenta correlações significativas para todos os IV's. As variáveis produtivas (PMV e PMS) apresentaram correlações médias significativas com MDV a 100 metros (0,56 e 0,40, respectivamente), e apenas o ExG para PMV (0,42) a 20 metros (Figura 8), as demais correlações são apresentadas como fracas significativas com os demais IV's perante a PMV.

Período chuvoso: **20 metros**

<b>MDV</b>	0,08	-0,12	-0,59*	0,68*
<b>GLI</b>	0,34*	0,14	-0,45*	0,43*
<b>MPRI</b>	0,35*	0,13	-0,57*	0,59*
<b>ExG</b>	0,42*	0,23*	-0,39*	0,35*
	<b>PMV</b>	<b>PMS</b>	<b>MS</b>	<b>PB</b>

Período chuvoso: **100 metros**

<b>MDV</b>	0,56*	0,40*	-0,29*	0,35*
<b>GLI</b>	0,30*	0,06	-0,61*	0,53*
<b>MPRI</b>	0,23*	-0,04	-0,72*	0,74*
<b>ExG</b>	0,29*	0,04	-0,63*	0,56*
	<b>PMV</b>	<b>PMS</b>	<b>MS</b>	<b>PB</b>

## Legenda:

0,99 a 0,70	Forte Positiva
0,69 a 0,40	Média Positiva
0,39 a 0,10	Fraca Positiva
0,09 a -0,09	Insignificativa
-0,39 a -0,10	Forte Negativa
-0,69 a -0,40	Média Negativa
-0,99 a -0,70	Fraca Negativa

\* Correlação é significativa a 1%.

PMV: produção de massa verde; PMS: produção de massa seca; MS: teor de matéria seca; PB: teor de proteína bruta; MDV: modelo digital da vegetação; GLI: Green Leaf Index; MPRI: Modified Photochemical Reflectance Index; ExG: Excess Green.

**Figura 10.** Correlações de Pearson entre as variáveis do pasto e os índices de vegetação, do período chuvoso a 20 e 100 metros de altura do voo.

Em relação aos teores de MS e PB, há correlações significativas com todos os IV's (Figura 8). No entanto, a 20 metros, as correlações médias significativas são observadas no MDV, GLI e MPRI, de modo negativo para o teor MS e positivo para PB. Em relação a 100 metros de altura, o MPRI possui uma correlação forte significativa tanto para a MS quanto para a PB, apresentando os valores de -0,72 e 0,74, respectivamente, negativamente para MS e positivamente para a PB (Figura 8). Além desse índice, o GLI e o ExG obtêm correlação média significativa, para as duas variáveis qualitativas (MS e PB) (Figura 8).

De modo geral, o período seco apresenta maiores valores de correlações das variáveis produtivas (PMV e PMS), enquanto o período chuvoso apresenta maiores valores das correlações para as variáveis qualitativas (MS e PB) (Figura 7 e Figura 8). Devido a esse comportamento divergente em relações as diferentes combinações entres os IV's e as variáveis do pasto, os modelos preditivos foram organizados da mesma maneira, em períodos

### 4.3 Modelos preditivos

Diferentes modelos preditivos foram avaliados para a PMV, PMS, MS e PB, e somente os que apresentaram os maiores valores das correlações significativas foram selecionados. A tabela 9, apresenta as variáveis do pasto e seus respectivos índices de vegetação que compõem os modelos preditivos, ressaltando ainda, a forma de contribuição desse IV na construção desse modelo, de forma negativa (-) ou de forma positiva (+).

**Tabela 9.** Participação dos índices nos modelos de regressão linear obtido nos diferentes períodos e alturas de voo.

Altura de Voo	Variáveis do Pasto	Período seco		Período chuvoso	
		IV	R <sup>2</sup>	IV	R <sup>2</sup>
20 m	PMV	MDV + ExG	0,60	ExG - GLI	0,22
	PMS	MDV + ExG	0,61	ExG - MDV	0,13
	MS	MDV	0,47	-MPRI + ExG	0,46
	PB	-ExG + MPRI	0,36	MDV	0,46
100 m	PMV	MDV - GLI	0,67	MDV - MPRI	0,37
	PMS	MDV	0,60	MDV - MPRI	0,36
	MS	MDV-MPRI	0,49	MDV - MPRI	0,61
	PB			MPRI - GLI - MDV + ExG	0,79

IV: índice de vegetação; R<sup>2</sup>: coeficiente de determinação; PMV: produtividade de massa verde; PMS: produtividade de massa seca; MS: teor de matéria seca; PB: teor de proteína bruta

O MDV é o principal índice que integra os modelos preditivos desse estudo, por estar presente na maioria dos modelos alcançados. No período seco, os modelos produtivos (PMV e PMS) apresentaram  $R^2 > 0,60$  (Tabela 9), em que, além do MDV há a participação dos índices ExG a 20 metros, e do GLI a 100 metros. O modelo da PMV em conjunto com GLI apresenta um  $R^2=0,67$ , maior coeficiente alcançado nesse período. Além das variáveis produtivas, o MDV constitui os modelos para o teor de MS da massa de forragem, em ambas as alturas de voo, registrando um  $R^2$  entre 0,47 e 0,49.

No período seco, a 20 metros de altura, a regressão linear múltipla apresenta um modelo preditivo para o teor de PB, composto somente de IV's provindos das camadas RGB, o ExG e MPRI ( $R^2$  0,36), no entanto, a 100 metros não há modelo preditivo do teor de PB (Tabela 9). Destaca-se que esse modelo apresenta uma correlação negativa com ExG e positiva MPRI, nesse sentido, a concentração de PB comportam de maneira inversamente proporcional ao ExG e proporcional para MPRI.

Os modelos de PMV e PMS do período chuvoso apresentaram  $R^2=0,22$  (ExG – GLI)  $R^2=0,13$  (ExG – MDV), respectivamente, a 20 metros de altura (Tabela 9). Entretanto, os IV's provindos proveniente das imagens a 100 metros registram valores de  $R^2 = 0,37$  para PMV e  $0,36$  para PMS, sob a composição entre os índices MDV e MPRI (Tabela 9), um aumento de 68,2% e 176,9% do coeficiente de determinação ( $R^2$ ), respectivamente.

Em relação aos modelos qualitativos da massa forrageira, os teores de MS e PB, apresentam  $R^2=0,46$  (20 metros), com a participação de IV's RGB (MPRI e ExG) no modelo de MS, e somente o MDV integra o modelo de PB (Tabela 9). A 100 metros de altura de voo, o teor de MS apresenta um coeficiente de  $R^2=0,61$  e de  $R^2=0,79$  para o teor de PB. Tanto o MDV quanto o MPRI compõem os modelos dos dois modelos qualitativos, entretanto, apenas no modelo do teor de PB há a participação dos demais IV's do RGB (ExG e GLI) (Tabela 9), melhorando o  $R^2$  em 32,6% no teor de MS e 71,7%, respectivamente.

A tabela 10, apresenta as equações dos modelos preditivos e as métricas de avaliação dos modelos de regressão linear múltipla (MAE, E e  $C_w$ ) para os dois períodos e as duas alturas estudadas.

**Tabela 10.** Modelos preditivos das variáveis do pasto e métricas de validação dos modelos gerados por sensor RGB.

Modelos	MAE	RMSE	E	$C_w$
<u>Período seco: 20 metros</u>				
PMV = (MDV*31671,2) + (ExG*17653,1) - 1048,69	34	1326,8	0,68	0,89
PMS = (MDV*14945) + (ExG*6610) - 542,9	7,5	561,4	0,73	0,91
MS = (MDV*36,8) + 36,4	0,81	2,0	0,55	0,84
PB = (ExG*(-54,1)) + (MPRI*71,6) + 14,4	0,004	1,2	0,46	0,76
<u>Período seco: 100 metros</u>				
PMV = (MDV*92250,3) + (GLI*(-22336,2)) + 2470,2	264,7	1293,1	0,70	0,91
PMS = (MDV*37248,5) + 482,1	43,3	710,3	0,57	0,85
MS = (MDV*78) + (MPRI*(-70,4)) + 38,3	0,4	2,2	0,47	0,80
<u>Período chuvoso: 20 metros</u>				
PMV = (ExG*56217,8) + (GLI*(-47406,6)) - 2362,3	128,6	3063,6	0,26	0,65
PMS = (ExG*5564,1) + (MDV*(-3248,9)) + 419,8	112,5	757,6	0,18	0,57

$$\begin{aligned} \text{MS} &= (\text{MPRI}*(-81,2)) + (\text{ExG}*38,7) + 21,9 & 0,49 & 2,4 & 0,47 & 0,77 \\ \text{PB} &= (\text{MDV}*20,8) + 7,8 & 0,32 & 2,2 & 0,64 & 0,86 \end{aligned}$$

Período chuvoso: 100 metros

$$\begin{aligned} \text{PMV} &= (\text{MDV}*34874,5) + (\text{MPRI}*(-23226,6)) + 11377,6 & 390,1 & 2493,5 & 0,42 & 0,76 \\ \text{PMS} &= (\text{MDV}*9512,3) + (\text{MPRI}*(-11233,7)) + 3640,7 & 118,5 & 648,3 & 0,36 & 0,73 \\ \text{MS} &= (\text{MDV}*14,35) + (\text{MPRI}*(-54,30)) + 32,2 & 0,56 & 2,4 & 0,58 & 0,82 \\ \text{PB} &= (\text{MPRI}*85,3) + (\text{GLI}*((-309,4)) + (\text{MDV}*(-8,4)) + & 0,56 & 2,2 & 0,63 & 0,86 \\ & (\text{ExG}*148,3) + 18,1 \end{aligned}$$

PMV: produção de massa verde; PMS: produção massa seca; MS: massa seca; PB: proteína bruta; MAE: erro médio absoluto; RSME: raiz do erro quadrático médio; E: coeficiente de eficiência; Cw: índice de concordância de willmott.

Nenhum dos modelos apresentaram um coeficiente de eficiência (E) de boa performance ( $E > 0,75$ ). Todavia, diversos modelos foram considerados satisfatórios. O modelo preditivo para a PMS no período seco a 20 metros de altura apresenta o maior valor de coeficiente de eficiência (E) 0,73, seguido do modelo para PMV a 100 metros no mesmo período  $E=0,70$ , ambos satisfatórios (Tabela 10).

Os modelos preditivos para as variáveis produtivas entre os dois períodos, observa-se que o período seco apresenta E superior ao período chuvoso, na qual, esse período apresentaram E de 0,26 e 0,18 para PMV e PMS a 20 metros, insatisfatórios, e 0,42 e 0,36 a 100 metros (satisfatórios), respectivamente (Tabela 10). Para as variáveis de MS e PB o coeficiente de eficiência apresenta valores de 0,47 e 0,64 a 20 metros de altura, bem como um E de 0,58 e 0,63 a 100 metros de altura, ambas com eficiência satisfatórias, respectivamente.

## V - DISCUSSÃO

### 5.1 Gramíneas x Fertilização: produção e qualidade do pasto

A produção de MS variou entre as cultivares, com destaque para Braúna e BRS Paiaguás, que registraram a maior produção de massa seca de folhas. Euclides et al. (2016) comparando cultivares da espécie *Urochloa brizantha*, enfatizaram a capacidade produtiva da cv. BRS Paiaguás no período seco, ao observarem maior produção de massa seca de folha, e conseqüentemente, maior relação folha/colmo. Muniz et al. (2022), ao compararem o desempenho produtivo da BRS Paiaguás com o *Megartyshurs maximum* cv. BRS Tamani, observaram uma maior produção de forragem para a cultivar Paiaguás.

A maior produtividade da cultivar Braúna é reflexo direto da maior população de perfilhos por área (1212 perfilhos.m<sup>2</sup>). Esse comportamento pode ser elucidado pelo mecanismo de compensação dos perfilhos entre tamanho/densidade, em que, quanto maior a densidade populacional menor será o tamanho dos perfilhos (Sbrissia & Silva, 2008), característica essa estrutural diretamente ligada a produção de MS. Santos et al. (2017), reafirmam essa interação ao conceituar o perfilho como um indivíduo composto de colmo e folhas, e que seu conjunto em uma área contribui para o volume de massa total.

Policarpo et al. (2023) avaliando diferentes genótipos de *Urochloa*, observaram que a cultivar Braúna e a BRS Paiaguás não diferiram ( $P < 0,05$ ) para a produção de forragem e perfilhos por área. No entanto, nesse presente estudo, constata um aumento de 36,23% na produção de massa seca total, potencialmente pelas estruturas de perfilhos que agregam à massa forrageira, que conseqüentemente, incrementa a produtividade da biomassa forrageira (Yu et al., 2020), corroborando com o observado.

A maior produção de MS do capim Braúna em relação aos capins Basilisk e Paiaguás ( $P < 0,01$ ; Tabela 3), trata-se do maior potencial de crescimento das plantas que é atribuído a eficiência das folhas em converter a radiação solar fotossinteticamente ativa interceptada em fotoassimilados (Taiz et al., 2017), observada tanto na produção

de MS de folha, quanto na produção de MS de colmos, duas estruturas que compõem a biomassa da forrageira.

O capim BRS Paiaguás possui um excelente acúmulo dos componentes vegetais verdes, principalmente do componente folha no período seco (Do Valle et al., 2013), apresentando no estudo uma produção superior em 49,1%, 18,83% e 16,7% em relação aos capins Camello, Basilisk e Braúna, respectivamente. A maior quantidade de lâminas foliares beneficia não apenas a produtividade, mas também pode influenciar o valor nutritivo do pasto. Esse comportamento foi evidenciado por Ramos et al. (2022) ao compararem seis cultivares do gênero *Urochloa*.

Os capins Braúna e Camello obtiveram a maior MS de colmo, o que contribuiu para a produtividade da MS total. A maior participação do colmo implica diretamente na qualidade da massa de forragem, pois o menor valor nutritivo do pasto tende a ser influenciado pelo maior acúmulo desse componente (Barbero et al., 2021), comprometendo o consumo e desempenho dos animais, por obter quantidades relevantes componentes indigestíveis, como a lignina, reduzindo a digestibilidade da forragem (Miyamoto et al., 2020).

Sob a perspectiva ecofisiológicas, as gramíneas do presente estudo, conseguem converter em média 19,8 kg de MS para cada mm de água provinda da precipitação pluviométrica anual, não diferindo entre si ( $P < 0,05$ ). Silva et al. (2020), avaliando a EUA das cultivares Braúna, BRS Paiaguás e Piatã, do gênero *Urochloa*, sob o efeito da disponibilidade hídrica do solo, constataram que a Braúna alcança maior eficiência do uso da água.

A oscilação do teor de MS entre as gramíneas é influenciada por diversos fatores, podendo ser: idade planta, adubação, estação do ano, condição de solo e o clima (Fukumoto et al., 2010), nesse estudo, o capim Braúna e Camello apresentam os maiores teores de 306 e 283 g/kg para MS, os demais capins em 265 e 262 g/kg para a BRS Paiaguás e Basilisk, respectivamente.

A concentração de MS e PB estão associadas com as características estruturais do dossel forrageiro, essencialmente, pela presença das lâminas foliares (Silva et al., 2016) e em relação a quantidade de colmo. O capim Braúna apresentou maior concentração de PB, possivelmente, pelo maior acúmulo de MS de folha, apesar da relação F/C da BRS Paiaguás ser maior, entretanto, isso não potencializou a tal ponto de superar o capim Braúna na concentração de MS e PB.

Como relatado, o teor de PB está intimamente ligado as características morfológicas, basicamente, pela quantidade de lâminas foliares em relação ao colmo (Pontes et al., 2017). No presente estudo, a produtividade de folha por hectare impulsionou a expressão do teor proteico das gramíneas tropicais.

A fertilização com diferentes fontes de liberação de N não influenciou a produção de MS total e a produção de MS da folha, colmo e material morto, rendimento semelhante observado por (Gagnon et al., 2019), onde as fontes de fertilizantes nitrogenados não afetaram a produção anual de MS da forragem. Esses comportamentos podem ser explicados pela mineralização da MO do solo (Santos & Fonseca, 2016), pois conforme Zhu et al. (2022), até 38% da entrada de N no solo pode ser originada da MO.

Contudo, a fertilização impacta no perfilhamento (Bergoli et al., 2019), observando um aumento linear na densidade de perfilhos, conseqüentemente, da produção de biomassa vegetal conforme o incremento de N no solo (Paciullo et al., 2017). De modo que, no presente estudo, a fertilização de N, independentemente da fonte, promoveu maior densidade de perfilhos, com isso o aumento de perfilhos maximiza a produção por meio da fertilização (Du Toit, 2014), especialmente pelo teor de nitrogênio na planta (Zhong et al., 2002)

A fertilização nitrogenada aumenta o teor de PB na massa forrageira (Domingues et al., 2021). No presente estudo, o aumento da PB nas gramíneas com adubação nitrogenada é evidente, com o incremento de 8,26%. Esse comportamento é direcionado pela presença de lâminas foliares, em quantidade superior ao colmo, no estágio vegetativo, da mesma forma, com a quantidade de perfilhos jovens e vegetativos que contribuem para aumentar o valor nutritivo (Salvador et al., 2023), em virtude do aumento da disponibilidade de N no solo (Dupas et al., 2016).

A utilização de fertilizantes em pastagens tornou-se um fator essencial para sustentar e aumentar a produtividade das pastagens (Ho et al., 2013). No entanto, as características ambientais e de manejo influenciam na eficiência do uso de fertilizantes nitrogenados inorgânicos, na qual as características biológicas, físicas e químicas do solo interferem na disponibilidade do N (Guo et al., 2019).

Conforme Sun et al. (2008), a disponibilidade de água no solo, temperatura do ar e do solo interferem diretamente na resposta das gramíneas às adubações nitrogenadas, sendo difícil prever essa resposta do nitrogênio nas gramíneas devido a capacidade do solo em fornecer N e pela demanda das plantas serem diferentes para esse nutriente

(Salvador et al., 2023), além da complexa interação entre solo-ambiente-planta-manejo, visto que, no presente estudo a falta de efeito dos fertilizantes sobre a produtividade e características estruturais das gramíneas tropicais pode ter sido reflexo da ação das condições edafoclimáticas expostas sob o desempenho das fontes de fertilizantes, que no caso das fontes nitrogenadas a concentração da precipitação pluviométrica pode ter causado a lixiviação, reduzindo a disponibilidade de N para a planta.

Nesse sentido, as condições ambientais do período experimental caracterizadas pela constante nebulosidade e baixa insolação, além de alto volume de chuva em curto espaço de tempo, podem ter influenciado a falta de efeito da fertilização nitrogenada nas respostas produtivas. De acordo com Irving (2015), quando a quantidade de N aplicado não é limitante, a competição por luz torna-se mais importante para o desenvolvimento dos tecidos vegetais.

Salvador et al. (2023), avaliando o capim-marmelo (*Urochloa plantaginea* (Link) Hitch) sob a fertilização nitrogenada, na qual, considera o teor de nitrogênio (%) na biomassa de folha e colmo, em razão da quantidade ( $t\ ha^{-1}$ ) de biomassa de folha e colmo como um fator de avaliação nutritiva do nitrogênio, observaram que o capim responde de modo semelhante as condições sem aplicação de N e com aplicações até  $150\ kg\ ha^{-1}\ ano$ , atribuindo essa resposta à redução da luz diária (insolação), que resultou em menor expansão foliar.

Portanto, a não observação de diferenças produtivas entre as fontes de fertilizantes apresenta-se para além da constatação dos seus componentes e da forma de liberação para as plantas. Reforça que o manejo e as condições climáticas (radiação, temperatura, precipitação e nebulosidade) são fatores que atua intrinsecamente.

## **5.2 Estimativa das características do pasto através de sensor RGB**

Considerando as características produtivas e qualitativas do pasto, essas apresentaram fortes correlações (R) com os índices, registrando valores acima de 0,7, semelhantemente ao observado na cultura do trigo por Lu et al. (2019) ao correlacionar os IVs com a biomassa acima do solo (BAS).

Os índices vegetativos (ExG, GLI e MPRI) apresentaram maiores valores das correlações para a produção de massa verde (PMV) e a qualidade da pastagem (MS e PB), à medida que o índice vertical (MDV) obteve os maiores valores tanto para a

biomassa verde e seca, representada no presente estudo pelas produtividades da massa verde e seca (PMV e PMS) (Figura 9).

O modelo digital de vegetação (MDV) tem como característica a observância da biomassa sob o relevo do terreno. Em alguns estudos, (Silva, et al., 2020; Deminicis, 2015; Martins et al., 2021) apresentam esse índice vertical como modelo digital da superfície (MDS) correlacionando notadamente com a altura da planta e BAS. Uma vez que, a estimativa da BAS interceptada pelos sensores inclui além das estruturas de folhas, as hastes (caules) (Abbas et al., 2012), representando a produtividade das culturas agrícolas (Bendig et al., 2014).

Em relação aos IVs extraídos de cada camada RGB (ExG, GLI, MPRI), esses tendem um comportamento pela atuação da clorofila nos vegetais. Pois esses pigmentos presentes na planta, principalmente, na folha, absorvem a radiação das bandas azuis (B) e vermelhas (R) do espectro do visível, refletindo a banda verde (G) (Meer Van Der & Jong, 2001), possibilitando que o sensor RGB capture essas reações. Nesse sentido, IV-RGB derivadas das bandas vermelha e azul tendem estar associados com a concentração de clorofila (Li et al., 2022), e potencialmente com o teor de nitrogênio na planta (Simili et al., 2019)

Os modelos preditivos apresentaram diversas combinações entre os IVs nesse estudo (Tabela 9) semelhantemente encontrado em outros estudos com gramíneas (Bendig et al., 2014; Freitas et al., 2022; Lu et al., 2019), exibindo que essas combinações resultaram em modelos com melhor capacidade preditiva, principalmente, por integrar simultaneamente informações estruturais (índice textural) e da cobertura vegetal (camada RGB). Em virtude das informações insuficientes da estrutura da planta pelas refletâncias das camadas RGB (Chang & Shoshany, 2016). Os modelos de regressão linear para a estimativa das variáveis do pasto (Tabela 9) que alcançaram  $R^2 > 0,47$  (período seco), apresentaram em sua composição o MDV, ou seja, os valores extraídos desse índice contribuem de forma positiva, por estar baseado nas informações estruturais da vegetação. Nesse mesmo sentido, Zhang et al. (2022) utilizando imagens RGB, observaram melhor desempenho nos modelos que combinaram as características de textura obtidas por meio dos pixels.

Desta forma, a classificação de pixel a pixel para distinguir solo e vegetação, auxilia na extração do modelo digital de superfície (Raj et al., 2021), conseqüentemente, para o MDV, visto que esse é provindo da subtração dos valores de elevação da

superfície pelos valores da elevação do solo, podendo então serem considerados métricos. Por esse ângulo, e semelhante ao relatado por Lu et al. (2019) a combinação de IVs com valores métricos melhora os modelos de predição.

Os modelos da produtividade de massa no período seco apresentam  $R^2 > 0,60$  (Tabela 9), sendo superior ao encontrado por Grüner et al. (2019) ( $R^2$  0,43) ao avaliarem pastagens temperadas com sensor RGB a 20 metros de altura do voo alcançaram, o que no presente estudo alcança  $R^2$  de 0,67 (PMV) e 0,67 (PMS) a 100 metros de altura do voo. Entretanto, os modelos do período chuvoso apresentaram coeficiente de determinação ( $R^2$ ) inferior a 0,37, afetando diretamente no seu desempenho ao apresentarem RMSE maior do que o período seco, e menor eficiência (E) (Tabela 10).

A avaliação do desempenho dos modelos preditivos da produção de massa verde (PMV) registraram RMSE entre 2493,5 e 3063,6 kg ha<sup>-1</sup> (Tabela 10) no período chuvoso, sendo quase 1000 kg ha<sup>-1</sup> superior ao apresentado no modelo por Lu et al. (2019), entretanto, no período seco esses valores registraram em 1293,1 e 1326,8 kg ha<sup>-1</sup>, menor que o encontrado por esses autores para a cultura do trigo (1610,0 kg ha<sup>-1</sup>).

Essas limitações dos modelos de produtividade da massa no período chuvoso podem estar relacionadas com a captura da refletância do dossel vegetal, visto que, a saturação da refletância, com ênfase do verde, tende a ser potencializada pela maior cobertura vegetal, interferindo na composição dos índices de vegetação (Chang & Shoshany, 2016), o que consideravelmente ocorreu no presente estudo, pois no período chuvoso o dossel das plantas apresentaram maior cobertura vegetal e uma tonalidade verde nas folhas mais intensa do que o período seco.

Nesse sentido, entende-se que quanto maior o valor obtido pelo índice de vegetação (IV), sobretudo aqueles constituídos pelas camadas RGB, eventualmente haverá maior presença de vegetação na área. Conforme Barbosa et al. (2019), essa relação entre os IVs e a cobertura vegetal, provém da maior refletância da camada verde (Green) em virtude da maior quantidade de biomassa na área, como também é observado esse comportamento crescente do IV em relação ao rendimento do arroz por Yamaguchi et al. (2020).

O modelo preditivo com o maior  $R^2$  (0,61) para estimar o teor de matéria seca (MS) correlaciona tanto para o índice vertical (MDV) quanto o vegetativo (MPRI),

exposto no período chuvoso a 100 metros (Tabela 9), na qual, esse modelo apresenta uma eficiência (E) de 0,58 (Tabela 10) e um RMSE de 2,4 %.

O teor de matéria seca está intimamente ligado com a maturidade da planta (Stabile et al., 2010), ou seja, perante o crescimento (acúmulo de massa) da planta haverá tendência no aumento da concentração de matéria seca na planta. Pois, nesse processo, a planta tende a reduzir a concentração de compostos não estruturais, como pigmentos, lipídeos e nitrogênio. Comportamento que afeta reduzindo a eficiência fotossintética, potencialmente captura pelo IV MPRI, ao saber que o MPRI é um índice que informa as propriedades espectrais fotossinteticamente ativa na planta (Berger et al., 2019).

Desse modo, a participação dos IV-*RGB* nos modelos preditivos tende a ser correspondido pela presença do verde, conseqüentemente, remetendo a clorofila presente na folha, essa que absorve a energia luminosa na faixa de 680 e 700 nm (Streit et al., 2005) e se correlaciona com o teor de nitrogênio da planta (Santos et al., 2019), esse que é utilizado para estimar os teores proteicos das gramíneas tropicais, na qual, apresentaram correlações de 0,74 (Figura 9) entre MPRI e PB, resultado superior ao apresentado por Hunt et al. (2013) que alcançaram correlações satisfatórias de R 0,49, entre GLI e o teor de clorofila.

No presente estudo, as correlações entre os IVs organizaram em modelo preditivo com  $R^2$  0,79 para estimar a PB (Tabela 9), somente com IVs provindo de sensor RGB. Demais pesquisas utilizando imagens RGB encontraram valores de  $R^2$  semelhante na cultura do amendoim ( $R^2$  0,98) (Janani & Jebakumar, 2023), do arroz ( $R^2$  0,82) (Shi et al., 2021), e superior ao encontrados em pesquisas com milho ( $R^2$  0,47) (Lu et al., 2021). Bem como, pesquisas utilizando câmeras multiespectrais (Wei et al., 2019), ou imagens Sentinel combinadas com imagem do ARP (Pereira et al., 2022), apresentam  $R^2$  de 0,8 e 0,77, respectivamente, valores próximos ao alcançado pelo presente estudo.

O baixo desempenho ( $R^2 < 0,5$ ) dos modelos a 20 metros para estimar o teor de PB e MS, pode ser apontada pela ausência da faixa do infravermelho no sensor, na qual, é entendida como camada mais sensíveis em captar as características estruturais e nutritivas das plantas (Jin et al., 2021; Prey et al., 2018).

A performance (validação) dos modelos preditivos (Tabela 10) demonstram que o período seco apresenta menores RMSE comparando com o período chuvoso, e em

alguns modelos específicos relacionados a biomassa, a eficiência (E) tende ser maior. A exemplo, da produtividade da massa forrageira (PMV e PMS), apresentando E no período seco entre 0,57 e 0,73, superior ao do período chuvoso que registra entre 0,18 e 0,42. No entanto, o coeficiente de eficiência dos modelos preditivos no período chuvoso para o teor de MS e PB a 100 metros de altura, apresentam de 0,58 e 0,63, respectivamente, superior ao período seco na mesma condição de voo.

Conforme Varlet-Grancher et al. (1989) e Santos et al. (2011), os pigmentos foliares, o tamanho e ângulo das folhas, arranjo das plantas, bem como a espécie e práticas de manejo são característica que influenciam na eficiência da absorção de luz solar, por consequência, na reflectância das bandas RGB pelas plantas. Nesse sentido, o estudo apresenta modelos eficientes conforme ao período produtivo da pastagem e ao interesse da característica que necessita ser estimada, ao saber que as características ecofisiológicas interfere diretamente na capacidade refletiva dessas estruturas, consequentemente na performance do sensor óptico.

Além disso, a sensibilidade da precisão dos modelos está ligada a resolução espacial das imagens (Lu et al., 2019), podendo uma resolução mais baixa reduzir a precisão dos modelos. Segundo Zarco-Tejada et al. (2014), uma resolução de até 13,28 cm pixel tende a obter predições aceitáveis. No presente estudo as resoluções dos pixels são em média 5,1 mm e 2,6 cm e 5,1 mm para os voos a 20 metros e 100 metros de altura, respectivamente. Considerando que as informações desses pixels são capazes de distinguir em maior precisão solo e vegetação, e atribuindo essa qualidade na constituição IVs e desempenho dos modelos preditivos.

## VI - CONCLUSÃO

A cultivar Braúna apresenta maior produção de matéria seca total e densidade populacional de perfilhos. A cultivar BRS Paiaguás dispõe de maior proporção de folha verde, massa seca de folha, manifestando a melhor relação folha/colmo entre as gramíneas.

A fertilização da pastagem promove o aumento do perfilhamento e a concentração de proteína bruta, no entanto, a fonte de fertilizante não interfere na produção de matéria seca das gramíneas. Diante disso, a fonte dos fertilizantes não diverge conforme as condições desse estudo.

O MPRI e o MDV melhor correlacionaram com as variáveis do pasto, dependendo das condições do período (seco ou chuvoso). Os modelos preditivos exibiram combinações alternadas entre os índices para a produção de massa e concentração de MS e PB, sendo notável o MDV na maioria das composições dos modelos.

Ponderando as condições de voo (altura e tempo), baixa nebulosidade e luminosidade, processamento das imagens, qualidade dos produtos (cm/pixel) e desempenho dos modelos, indica o voo a 100 metros de altura de voo que possibilita a melhor dinâmica e condições para a utilização do sensor RGB como ferramenta para estimar a produção e qualidade de gramíneas forrageiras tropicais do gênero da *Urochloa*.

## VII – REFERÊNCIAS BIBLIOGRÁFICAS

ABBAS, A.; RATHJE, C. A.; WIENBRANDT, L.; SCHIMMLER, M. Dictionary Attack on TrueCrypt with RIVYERA S3-5000. 2012 IEEE 18th International Conference on Parallel and Distributed Systems. **Anais...** . p.93–100, 2012. IEEE.

AOAC. **Association Of Analytical Communities Official methods of analysis of the Association of Official Analytical Chemists**. 19<sup>o</sup> ed. USA, 2012.

BARBERO, R. P.; RIBEIRO, A. C. DE C.; MOURA, A. M.; et al. Production potential of beef cattle in tropical pastures: a review. **Ciência Animal Brasileira**, v. 22, 2021.

BARBOSA, B. D. S.; FERRAZ, G. A. S.; GONÇALVES, L. M.; et al. RGB vegetation indices applied to grass monitoring: a qualitative analysis. **Agronomy Research** , v. 17, n. 2, p. 349–357, 2019.

BENDIG, J.; BOLTEN, A.; BENNERTZ, S.; et al. Estimating Biomass of Barley Using Crop Surface Models (CSMs) Derived from UAV-Based RGB Imaging. **Remote Sensing**, v. 6, n. 11, p. 10395–10412, 2014.

BERGER, R.; SILVA, J. A. A. DA; FERREIRA, R. L. C.; CANDEIAS, A. L. B.; RUBILAR, R. Índices de vegetação para a estimativa do Índice de Área Foliar em plantios clonais de <i>Eucalyptus saligna</i> Smith. **Ciência Florestal**, v. 29, n. 2, p. 885–899, 2019.

BERGOLI, T. L.; ROCHA, M. G.; PÖTTER, L.; et al. Tillering dynamics of Alexandergrass pasture under nitrogen fertilization. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v. 71, n. 6, p. 2049–2056, 2019.

CFSEMG. **Comissão de Fertilidade do Solo do Estado de Minas Gerais** . 5<sup>a</sup> Aproximação ed. Viçosa, 1999.

CHANG, J.; SHOSHANY, M. Mediterranean shrublands biomass estimation using Sentinel-1 and Sentinel-2. 2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). **Anais...** . p.5300–5303, 2016. IEEE.

DEMINICIS, B. B. Novas tecnologias aplicadas na avaliação da produção e qualidade de forragens. **Ciências Agrárias: Tecnologias e Perspectivas**. p.247–256, 2015. Marechal Cândido Rondon: Universidade Estadual do Oeste do Paraná.

DOMINGUES, A. A.; SANTOS, A. J. M.; BACKES, C.; et al. NITROGEN FERTILIZATION OF PAIAGUÁS GRASS: PRODUCTION AND NUTRITION. **Revista de Agricultura Neotropical**, v. 8, n. 2, p. e5918, 2021.

DUPAS, E.; BUZETTI, S.; RABÊLO, F. H. S.; et al. Nitrogen recovery, use efficiency, dry matter yield, and chemical composition of palisade grass fertilized with nitrogen sources in the Cerrado biome. **Australian Journal of Crop Science**, v. 10, n. 9, p. 1330–1338, 2016.

EMBRAPA; SUDENE. Empresa Brasileira de Pesquisa Agropecuária e Superintendência do Desenvolvimento do Nordeste. Disponível em: <<http://solos.uep.cnps.embrapa.br/index.php?link=ba>>. 1973.

EUCLIDES, V. P. B.; MONTAGNER, D. B.; BARBOSA, R. A.; DO VALLE, C. B.; NANTES, N. N. Animal performance and sward characteristics of two cultivars of *Brachiaria brizantha* (BRS Paiaguás and BRS Piatã). **Revista Brasileira de Zootecnia**, v. 45, n. 3, p. 85–92, 2016.

FONSECA, D. M.; MARTUSCELLO, J. A. **Plantas Forrageiras**. 2<sup>o</sup> ed. 2022.

FREITAS, R. G.; PEREIRA, F. R. S.; DOS REIS, A. A.; et al. Estimating pasture aboveground biomass under an integrated crop-livestock system based on spectral and texture measures derived from UAV images. **Computers and Electronics in Agriculture**, v. 198, p. 107122, 2022.

FUKUMOTO, N. M.; DAMASCENO, J. C.; DERESZ, F.; et al. Produção e composição do leite, consumo de matéria seca e taxa de lotação em pastagens de gramíneas tropicais manejadas sob lotação rotacionada. , , n. 7, p. 1548–1557, 2010. Disponível em: <[www.sbz.org.br](http://www.sbz.org.br)>.

GAGNON, B.; ZIADI, N.; BÉLANGER, G.; TREMBLAY, G. F.; PARENT, G. Urea-Based Fertilizer as an Efficient Nitrogen Source in Perennial Cool-Grass Forage Production. **Agronomy Journal**, v. 111, n. 2, p. 867–880, 2019.

GRÜNER, E.; ASTOR, T.; WACHENDORF, M. Biomass Prediction of Heterogeneous Temperate Grasslands Using an SfM Approach Based on UAV Imaging. **Agronomy**, v. 9, n. 2, p. 54, 2019.

GUO, X.; CHEN, L.; ZHENG, R.; et al. Differences in Soil Nitrogen Availability and Transformation in Relation to Land Use in the Napahai Wetland, Southwest China. **Journal of Soil Science and Plant Nutrition**, v. 19, n. 1, p. 92–97, 2019.

HO, C. K. M.; MALCOLM, B.; DOYLE, P. T. Potential impacts of negative associative effects between concentrate supplements, pasture and conserved forage for milk production and dairy farm profit. **Animal Production Science**, v. 53, n. 5, p. 437, 2013. HUNT, E. R.; DORAISWAMY, P. C.; MCMURTREY, J. E.; et al. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 103–112, 2013.

INMET. Instituto Nacional de Meteorologia. Estações Automáticas. 2023.

IRVING, L. Carbon Assimilation, Biomass Partitioning and Productivity in Grasses. **Agriculture**, v. 5, n. 4, p. 1116–1134, 2015.

JANANI, M.; JEBAKUMAR, R. Detection and classification of groundnut leaf nutrient level extraction in RGB images. **Advances in Engineering Software**, v. 175, p. 103320, 2023.

JIN, X.; ZARCO-TEJADA, P. J.; SCHMIDHALTER, U.; et al. High-Throughput Estimation of Crop Traits: A Review of Ground and Aerial Phenotyping Platforms. **IEEE Geoscience and Remote Sensing Magazine**, v. 9, n. 1, p. 200–231, 2021.

LI, R.; WANG, D.; ZHU, B.; et al. Estimation of nitrogen content in wheat using indices derived from RGB and thermal infrared imaging. **Field Crops Research**, v. 289, p. 108735, 2022.

VAN LIEW, M. W.; VEITH, T. L.; BOSCH, D. D.; ARNOLD, J. G. Suitability of SWAT for the Conservation Effects Assessment Project: Comparison on USDA Agricultural Research Service Watersheds. **Journal of Hydrologic Engineering**, v. 12, n. 2, p. 173–189, 2007.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. **Geocarto International**, v. 16, n. 1, p. 65–70, 2001.

LU, J.; CHENG, D.; GENG, C.; et al. Combining plant height, canopy coverage and vegetation index from UAV-based RGB images to estimate leaf nitrogen concentration of summer maize. **Biosystems Engineering**, v. 202, p. 42–54, 2021.

LU, N.; ZHOU, J.; HAN, Z.; et al. Improved estimation of aboveground biomass in wheat from RGB imagery and point cloud data acquired with a low-cost unmanned aerial vehicle system. **Plant Methods**, v. 15, n. 1, p. 17, 2019.

MARTINS, C. D. M.; SCHMITT, D.; DUCHINI, P. G.; MIQUELOTO, T.; SBRISSIA, A. F. Defoliation intensity and leaf area index recovery in defoliated swards: implications for forage accumulation. **Scientia Agricola**, v. 78, n. 2, 2021.

MEER VAN DER, F.; JONG, S. **Imaging spectrometry: basic principles and prospective applications**. 2001.

MEHLICH, A. Mehlich 3 soil test extractant: A modification of Mehlich 2 extractant. **Communications in Soil Science and Plant Analysis**, v. 15, n. 12, p. 1409–1416, 1984.

MIYAMOTO, T.; TOBIMATSU, Y.; UMEZAWA, T. MYB-mediated regulation of lignin biosynthesis in grasses. **Current Plant Biology**, v. 24, p. 100174, 2020.

MUNIZ, M. P.; COSTA, K. A. DE P.; SEVERIANO, E. DA C.; et al. Production, forage quality and cattle performance in Paiaguas palisadegrass and Tamani grasses in

different forms of animal supplementation in crop-livestock integration. **Australian Journal of Crop Science**, , n. 16(03):2022, p. 381–388, 2022.

NASH, J. E.; SUTCLIFFE, J. V. River flow forecasting through conceptual models part I — A discussion of principles. **Journal of Hydrology**, v. 10, n. 3, p. 282–290, 1970.

PACIULLO, D. S. C.; FERNANDES, P. B.; CARVALHO, C. A. B.; et al. Pasture and animal production in silvopastoral and open pasture systems managed with crossbred dairy heifers. **Livestock Science**, v. 245, p. 104426, 2021.

PACIULLO, D. S. C.; GOMIDE, C. A. M.; CASTRO, C. R. T.; et al. Morphogenesis, biomass and nutritive value of *Panicum maximum* under different shade levels and fertilizer nitrogen rates. **Grass and Forage Science**, v. 72, n. 3, p. 590–600, 2017.

PAPALOTLA. Papalotla Semillas. Disponível em: <<http://grupopapalotla.com/producto-camello.html>>. Acesso em: 14/5/2023.

PEREIRA, F. R. DA S.; DE LIMA, J. P.; FREITAS, R. G.; et al. Nitrogen variability assessment of pasture fields under an integrated crop-livestock system using UAV, PlanetScope, and Sentinel-2 data. **Computers and Electronics in Agriculture**, v. 193, p. 106645, 2022.

POLICARPO, V. H. C.; COSTA, R. D. DA; NASCIMENTO, H. L. B.; et al. Root parameters and physical soil attributes with forage growth of Panicum and Urochloa grasses forage. **Evidência: Biociências, Saúde e Inovação**, 2023.

PONTES, L. DA S.; BALDISSERA, T. C.; GIOSTRI, A. F.; et al. Effects of nitrogen fertilization and cutting intensity on the agronomic performance of warm-season grasses. **Grass and Forage Science**, v. 72, n. 4, p. 663–675, 2017.

PREY, L.; VON BLOH, M.; SCHMIDHALTER, U. Evaluating RGB Imaging and Multispectral Active and Hyperspectral Passive Sensing for Assessing Early Plant Vigor in Winter Wheat. **Sensors**, v. 18, n. 9, p. 2931, 2018.

RAJ, R.; WALKER, J. P.; PINGALE, R.; et al. Leaf area index estimation using top-of-canopy airborne RGB images. **International Journal of Applied Earth Observation and Geoinformation**, v. 96, p. 102282, 2021.

RAMOS, B. L. P.; PEDREIRA, M. DOS S.; SANTOS, H. P.; et al. Forage production, morphogenetic and structural components, and nutritional value of tropical grasses in the semiarid condition. **Semina: Ciências Agrárias**, v. 43, n. 6, p. 2499–2516, 2022.

SALVADOR, P. R.; ROCHA, M. G. DA; MACHADO, JULIANA MEDIANEIRA; et al. Nitrogen nutrition index and morphogenesis in Alexandergrass of the Central Depression of Rio Grande do Sul. **Ciência Rural**, v. 53, n. 12, 2023.

SANTOS, M. E. R.; FONSECA, D. M. **Adubação de Pastagens em Sistemas de Produção Animal**. 1<sup>o</sup> ed. Viçosa-MG, 2016.

SANTOS, M. E. R.; SOUSA, B. M. DE L.; ROCHA, G. DE O.; et al. SWARD STRUCTURE AND TILLER CHARACTERISTICS IN PIATÃ GRASS PASTURES MANAGED WITH VARIABLE NITROGEN DOSES AND DEFERMENT PERIODS. **Ciência Animal Brasileira**, v. 18, p. 1–13, 2017.

SANTOS, N. L.; AZENHA, M. V.; SOUZA, F. H. M.; REIS, R. A.; RUGGIERI, A. C. Fatores ambientais e de manejo na qualidade de pastos tropicais. **Enciclopédia Biosfera**, v. 7, n. 13, p. 531–549, 2011.

SANTOS, P. L. F.; CASTILHO, R. M. M.; GAZOLA, R. P. D. Pigmentos fotossintéticos e sua correlação com nitrogênio e magnésio foliar em grama bermuda cultivada em substratos. **ACTA IGUAZU**, v. 8, n. 1, p. 92–101, 2019.

SANTOS, P. M.; PRIMAVESI, O. M.; BERNARDI, A. C. C. Adubação de Pastagens. In: A. V. Pires (Org.); **Bovinocultura de Corte**. v. 1, p.459–472, 2010. Piracicaba.

SBRISSIA, A. F.; SILVA, S. C. DA. Compensação tamanho/densidade populacional de perfilhos em pastos de capim-marandu. **Revista Brasileira de Zootecnia**, v. 37, n. 1, p. 35–47, 2008.

SCHIRRMANN, M.; GIEBEL, A.; GLEINIGER, F.; et al. Monitoring Agronomic Parameters of Winter Wheat Crops with Low-Cost UAV Imagery. **Remote Sensing**, v. 8, n. 9, p. 706, 2016.

SHI, P.; WANG, Y.; XU, J.; et al. Rice nitrogen nutrition estimation with RGB images and machine learning methods. **Computers and Electronics in Agriculture**, v. 180, p. 105860, 2021.

SHOEMAKER, H. E.; MCLEAN, E. O.; PRATT, P. F. Buffer Methods for Determining Lime Requirement of Soils With Appreciable Amounts of Extractable Aluminum. **Soil Science Society of America Journal**, v. 25, n. 4, p. 274–277, 1961.

SILVA, J. DE L.; RIBEIRO, K. G.; HERCULANO, B. N.; et al. MASSA DE FORRAGEM E CARACTERÍSTICAS ESTRUTURAIS E BROMATOLÓGICAS DE CULTIVARES DE *Brachiaria* E *Panicum*. **Ciência Animal Brasileira**, v. 17, n. 3, p. 342–348, 2016.

SILVA, M. V. DA; PANDORFI, H.; LOPES, P. M. O.; et al. Pilot monitoring of caatinga spatial-temporal dynamics through the action of agriculture and livestock in the brazilian semiarid. **Remote Sensing Applications: Society and Environment**, v. 19, p. 100353, 2020.

SIMILI, F. F.; BARBOSA, K. R. S.; AUGUSTO, J. G.; et al. Study of the chemical composition of *Urochloa brizantha* using the SPAD index, neural networks, multiple linear models, principal components and cluster analysis. **Animal Feed Science and Technology**, v. 258, p. 114307, 2019.

SOUZA, E. J.; CUNHA, F. F. DA; MAGALHÃES, F. F.; SILVA, T. R. DA; SANTOS, O. F. DA. EFICIÊNCIA DO USO DA ÁGUA PELO MILHO DOCE EM

DIFERENTES LÂMINAS DE IRRIGAÇÃO E ADUBAÇÃO NITROGENADA EM COBERTURA. **Revista Brasileira de Agricultura Irrigada**, v. 10, n. 4, p. 750–757, 2016.

STABILE, S. DOS S.; SALAZAR, D. R.; JANK, L.; RENNÓ, F. P.; SILVA, L. F. P. E. Características de produção e qualidade nutricional de genótipos de capim- colônia colhidos em três estádios de maturidade. **Revista Brasileira de Zootecnia**, v. 39, n. 7, p. 1418–1428, 2010.

STREIT, N. M.; CANTERLE, L. P.; CANTO, M. W. DO; HECKTHEUER, L. H. H. As clorofilas. **Ciência Rural**, v. 35, n. 3, p. 748–755, 2005.

SUN, X.; LUO, N.; LONGHURST, B.; LUO, J. Fertiliser Nitrogen and Factors Affecting Pasture Responses. **The Open Agriculture Journal**, v. 2, n. 1, p. 35–42, 2008.

TAIZ, L.; ZEIGER, E.; MOLLER, I. M.; MURPHY, A. **Fisiologia e Desenvolvimento Vegetal**. 2017.

DU TOIT, J. C. Growth and tiller production of *Themeda triandra* as affected by NPK fertilisation. **African Journal of Range & Forage Science**, v. 31, n. 3, p. 229–232, 2014.

DO VALLE, C. B.; EUCLIDES, V. P. B.; MONTAGNER, D. B.; et al. BRS Paiaguás: A new Brachiaria (*Urochloa*) cultivar for tropical pastures in Brazil. **Tropical Grasslands - Forrajes Tropicales**, v. 1, n. 1, p. 121, 2013.

VARLET-GRANCHER, C.; GOSSE, G.; CHARTIER, M.; et al. Mise au point : rayonnement solaire absorbé ou intercepté par un couvert végétal. **Agronomie**, v. 9, n. 5, p. 419–439, 1989.

VERHOEVEN, G. Taking computer vision aloft – archaeological three-dimensional reconstructions from aerial photographs with photostan. **Archaeological Prospection**, v. 18, n. 1, p. 67–73, 2011.

WEI, P.; XU, X.; ZHONGYUAN, L.; et al. Estimativa de sensoriamento remoto do conteúdo de nitrogênio nas folhas do milho de verão com base em imagens multiespectrais de UAV. **REVISTA DE ENGENHARIA AGRÍCOLA**, v. 35, n. 8, p. 126–133, 2019.

WOEBBECKE, D.M; MEYER; G. E.; VON BARGEN; K.; MORTENSEN, D. A. Color Indices for Weed Identification Under Various Soil, Residue, and Lighting Conditions. **Transactions of the ASAE**, v. 38, n. 1, p. 259–269, 1995.

YAMAGUCHI, T.; TANAKA, Y.; IMACHI, Y.; YAMASHITA, M.; KATSURA, K. Feasibility of Combining Deep Learning and RGB Images Obtained by Unmanned Aerial Vehicle for Leaf Area Index Estimation in Rice. **Remote Sensing**, v. 13, n. 1, p. 84, 2020.

YANG, Z.; WILLIS, P.; MUELLER, R. **Impact of band-ratio enhanced awifs image to crop classification accuracy.**2008.

YU, H.; YANG, J.; CUI, H.; et al. Effects of plant density on tillering in the weed grass *Aegilops tauschii* Coss. and its phytohormonal regulation. **Plant Physiology and Biochemistry**, v. 157, p. 70–78, 2020.

ZARCO-TEJADA, P. J.; DIAZ-VARELA, R.; ANGILERI, V.; LOUDJANI, P. Tree height quantification using very high resolution imagery acquired from an unmanned aerial vehicle (UAV) and automatic 3D photo-reconstruction methods. **European Journal of Agronomy**, v. 55, p. 89–99, 2014.

ZHANG, L.; YANG, L.; ZHOU, H.; et al. Carbon allocation patterns in forbs and grasses differ in responses to mowing and nitrogen fertilization in a temperate grassland. **Ecological Indicators**, v. 135, p. 108588, 2022.

ZHONG, X.; PRENG, S.; SHEEHY, J. E.; VISPERAS, R. M.; LIU, H. Relationship between tillering and leaf area index: quantifying critical leaf area index for tillering in rice. **The Journal of Agricultural Science**, v. 138, n. 3, p. 269–279, 2002.

ZHU, Y.; ZHENG, W.; MONACO, T.; NAERKEZI; LI, S. Effects of Aboveground Community Structure and Belowground Root Morphological Characteristics on Nitrogen Use Efficiency of Mixed-Perennial Legume-Grass Pastures. **Rangeland Ecology & Management**, v. 83, p. 59–68, 2022.