

UFRRJ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA AGRÍCOLA E AMBIENTAL

DISSERTAÇÃO

RELAÇÃO ENTRE ÍNDICES ESPECTRAIS OBTIDOS POR IMAGENS
DIGITAIS E ATRIBUTOS DE QUALIDADE DO TIFTON 85 (*Cynodon spp.*)

Jhiorranni Freitas Souza

2022



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA
E AMBIENTAL**

**RELAÇÃO ENTRE ÍNDICES ESPECTRAIS OBTIDOS POR IMAGENS
DIGITAIS E ATRIBUTOS DE QUALIDADE DO TIFTON 85 (*Cynodon spp.*)**

JHIORRANNI FREITAS SOUZA

Sob a Orientação do Professor
Anderson Gomide Costa

e Coorientação do Professor
Murilo Machado de Barros

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Engenharia Agrícola e Ambiental**, no Programa de Pós-Graduação em Engenharia Agrícola e Ambiental, Área de Concentração em Sistemas Agrícolas.

Seropédica, RJ
Agosto de 2022

“É permitida a cópia parcial ou total desta Dissertação, desde que seja citada a fonte.”

Universidade Federal Rural do Rio de Janeiro Biblioteca
Central / Seção de Processamento Técnico

Ficha catalográfica elaborada
com os dados fornecidos pelo(a) autor(a)

S719r Souza, Jhiorranni Freitas, 1992-
Relação entre índices espectrais obtidos por imagens
digitais e atributos de qualidade do Tifton-85
(Cynodon spp.) / Jhiorranni Freitas Souza. - Barra Mansa,
2022.
100 f.: il.

Orientador: Anderson Gomide Costa. Coorientador:
Murilo Machado de Barros. Dissertação(Mestrado). -
- Universidade Federal
Rural do Rio de Janeiro, Programa de Pós-graduação em
Engenharia Agrícola e Ambiental/Engenharia Agrícola e
Ambiental, 2022.

1. Análise de componentes principais. 2. Sensores ópticos.
3. Forrageiras. 4. Atributos bromatológicos.
I. Costa, Anderson Gomide, 11/07/1985-, orient. II. Barros,
Murilo Machado de, 06/09/1983-, coorient. III Universidade
Federal Rural do Rio de Janeiro. Programa de Pós-
graduação em Engenharia Agrícola e Ambiental/Engenharia
Agrícola e Ambiental. IV. Título.

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

UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA E
AMBIENTAL

JHIORRANNI FREITAS SOUZA

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Engenharia Agrícola e Ambiental**, no Programa de Pós-Graduação em Engenharia Agrícola e Ambiental, área de concentração Sistemas Agrícolas.

DISSERTAÇÃO APROVADA EM 25/08/2022.

Dr. Anderson Gomide Costa. (Orientador UFRRJ)

Dr. André Morais Moura. (UFRRJ)

Dra. Amelia Laísy do Nascimento (UFRPE)



Emitido em 25/08/2022

HOMOLOGAÇÃO DE DISSERTAÇÃO DE MESTRADO Nº 65/2022 - IT (12.28.01.27)

(Nº do Protocolo: NÃO PROTOCOLADO)

(Assinado digitalmente em 07/12/2022 13:02)

ANDERSON GOMIDE COSTA
COORDENADOR CURS/POS-GRADUACAO - TITULAR
PPGEAAMB (12.28.01.00.00.00.40)
Matrícula: ###619#5

(Assinado digitalmente em 30/11/2022 19:26)

ANDRE MORAIS MOURA
PROFESSOR DO MAGISTERIO SUPERIOR
DPA (12.28.01.00.00.00.63)
Matrícula: ###581#1

(Assinado digitalmente em 05/12/2022 09:26)

AMÉLIA LAÍSY DO NASCIMENTO
ASSINANTE EXTERNO
CPF: ###.###.674-##

Visualize o documento original em <https://sipac.ufrj.br/documentos/> informando seu número: **65**, ano: **2022**, tipo:
HOMOLOGAÇÃO DE DISSERTAÇÃO DE MESTRADO, data de emissão: **30/11/2022** e o código de
verificação: **3442ec3e62**

DEDICÁTORIA

Dedico este trabalho à minha mãe Helen, aos meus irmãos Lorranni e Andrew, à minha sobrinha Lara e minha avó Natalina (in memoriam), por me inspirarem a lutar pelos meus sonhos.

AGRADECIMENTOS

Agradeço à Deus e à minha avó Natalina Alves de Freitas (in memoriam), por terem me sustentado na fé ao longo de toda essa caminhada. Por iluminarem os dias mais difíceis da caminhada e me fortalecer com todo seu amor.

A minha mãe Helen Lúcia Alves de Freitas, por ser meu maior e mais bonito exemplo de amor, força e perseverança. Aos meus irmãos Lorranni Freitas Souza e Andrew de Freitas Souza, e minha sobrinha Lara Freitas do Nascimento, por todo amor e incentivo. Agradeço por compreenderem minha ausência durante todo o tempo que precisei estar distante.

Agradeço ao meu orientador Anderson Gomide Costa por não medir esforços para a execução deste trabalho, por toda paciência, ensinamento e compreensão durante esta caminhada. Por acreditar em meu potencial e ser presente em todas as fases deste projeto. A quem tenho profundo respeito e admiração.

Agradeço ao meu coorientador Murilo Machado de Barros e aos membros da banca de qualificação Amelia Laísy do Nascimento, Carlos Alberto Alves Varella e Marcus Vinícius de Oliveira, por contribuírem com a execução deste trabalho.

Aos meus amigos Flávio Campello e João Vitor Niella por me incentivarem, estarem ao meu lado em todos os momentos, por trazerem mais leveza aos os meus dias através da nossa amizade.

A minha equipe de pesquisa agradeço pela dedicação ao longo da execução e aquisição dos dados deste trabalho: Maurício, João Célio, Layana, Lucas, Isadora, Jade e Maria Clara. Vocês foram fundamentais para que as coletas em campo pudessem acontecer.

Agradeço à Fazenda FenoRio pelo apoio cooperativo em disponibilizar a área experimental, contribuir na execução e manutenção do experimento.

A toda equipe de profissionais do Laboratório do Departamento de Nutrição Animal e Pastagem do Instituto de Zootecnia, em especial ao Professor Vinícius Pimentel por toda orientação e esforços para contribuir com este trabalho. Agradeço por disponibilizarem o espaço, os equipamentos e os treinamentos para que eu pudesse executar as análises bromatológicas. Estendo meu agradecimento aos técnicos Felipe, Marcos e Evandro, e à discente e monitora Larissa, ambos pelo apoio, paciência e ensinamento.

Ao Laboratório de Processamento de Produtos Agrícolas – LABGERAR em nome da Professora Juliana Lobo Paes, por disponibilizar o espaço e os equipamentos necessários para a etapa de coleta dos dados.

Agradeço ao Programa de Pós-Graduação em Engenharia Agrícola e Ambiental - PGEEAMB e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pela oportunidade de aprendizado, aperfeiçoamento e incentivo à pesquisa.

RESUMO

SOUZA, Jhiorranni Freitas. **Relação entre índices espectrais obtidos por imagens digitais e atributos de qualidade do Tifton 85 (*Cynodon spp.*)**. 2022. 100f. Dissertação (Mestrado em Engenharia Agrícola e Ambiental, Sistemas Agrícolas). Instituto de Tecnologia, Departamento de Engenharia, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2022.

O comércio mundial de forragens apresenta expansão pela demanda de volumosos para suprir a alimentação dos animais, mercado este, cada vez mais exigente com relação à qualidade do produto. Em geral, a qualidade das forragem são realizadas por meio da avaliação de parâmetros físico-químicos, bromatológicos e energéticos, utilizando métodos destrutivos, onerosos e que demandam tempo em laboratório. A aplicação de tecnologia a partir da visão computacional pode ser uma alternativa aos métodos tradicionais, tornando o processo menos oneroso e permitindo obter parâmetros de forma não destrutiva, com resultados de forma instantânea. O presente trabalho tem como objetivo avaliar atributos de qualidade do capim Tifton 85 (*Cynodon spp.*) por meio de imagens digitais RGB e RGNIR, relacionando os índices colorimétricos com as análises bromatológicas da cultura. O experimento foi conduzido em área de produção comercial localizada na Universidade Federal Rural do Rio de Janeiro, no município de Seropédica, RJ. Os índices espectrais foram obtidos por meio de imagens digitais (na região espectral do visível e do infravermelho próximo) da cultivar Tifton 85 (*Cynodon spp.*) em diferentes idades de corte (14, 28, 42 e 56 dias) e níveis de adubação NPK(0, 100, 200 e 300 kg/ha). A análise de componentes principais foi aplicada para extração dos índices mais relevantes e correlacionados com as variáveis originais, por meio do critério dos componentes principais (PC) com poder explicativo de pelo menos 70% da variabilidade total dos dados. Os valores do PC1 gerados a partir dos coeficientes associados aos índices colorimétricos de maior correlação foram relacionados por meio de uma regressão quadrática simples com os atributos de qualidade, acúmulo de forragem, matéria mineral, proteína bruta, extrato etéreo, fibra em detergente neutro, carboidrato não fibroso e energia bruta. Predominantemente, a relação dos índices espectrais e os atributos de qualidade do capim Tifton 85, apresentaram capacidade explicativa da variância na PC1 acima de 70% para os cenários avaliados. A proteína bruta foi o parâmetro bromatológico que apresentou as maiores relações com os índices espectrais obtidos, tanto pelas imagens RGB (R^2 entre 0,61 e 0,94), quanto para as imagens RGNIR (R^2 entre 0,78 e 0,99) para todas as épocas de corte avaliadas. A matéria mineral apresentou maiores relações (R^2 entre 0,66 e 0,99) com as idades de corte de 14, 28 e 42 dias para as imagens RGNIR. A fibra em detergente neutro obteve R^2 entre 0,86 e 0,96 para as idades de corte de 14 e 28 dias, para as imagens RGB e RGNIR. O extrato etéreo e o carboidrato não fibroso se relacionaram melhor com os índices espectrais das imagens RGNIR. A energia bruta apresentou maior relação (R^2 entre 0,98 e 0,99) para as imagens RGNIR aos 14 e 28 dias. O acúmulo de forragem e sua taxa de acúmulo entre as datas de coleta, apresentaram maiores relações com as imagens RGNIR aos 28, 42 e 56 dias (R^2 entre 0,78 e 0,99), sendo estes períodos os mais indicados para geração de modelos de estimativa.

Palavras-chave: Análise de componentes principais; sensores ópticos; forrageiras; atributos bromatológicos.

ABSTRACT

SOUZA, Jhiorranni Freitas. **Relationship between spectral indexes obtained by digital images and quality attributes of Tifton 85 (cynodon spp.)**. 2022. 100p. Dissertation (Master in Agricultural and Environmental Engineering, Agricultural Systems). Institute of Technology, Engineering Department, Federal Rural University of Rio de Janeiro, Seropédica, RJ, 2022

The world trade in forages has expanded due to the demand for roughage to supply animal feed, a market that is increasingly demanding in terms of product quality. In general, the quality of the forages is carried out through the evaluation of physical-chemical, chemical and energetic parameters, using destructive, costly methods that demand time in the laboratory. The application of technology from computer vision can be an alternative to traditional methods, making the process less costly and allowing to obtain parameters in a non-destructive way, with results instantly. The present work aims to evaluate quality attributes of Tifton 85 grass (*Cynodon spp.*) through RGB and RGNIR digital images, relating the colorimetric indices with the bromatological analysis of the culture. The experiment was carried out in an agricultural production area located at the Federal Rural University of Rio de Janeiro, in the municipality of Seropédica, RJ. The spectral indices were obtained through digital images (in the visible and near infrared spectral region) of the cultivar Tifton 85 (*Cynodon spp.*) at different cutting ages (14, 28, 42 and 56 days) and fertilization levels 25/0/25 NPK(0, 100, 200 and 300 kg/ha), were submitted to a principal component analysis, to extract the most relevant indices and correlated with the original variables, through the principal components criterion (PC) with explanatory power of at least 70% of the total variability of the data. The PC1 values generated from the coefficients associated with the colorimetric indices of greater correlation were related by means of a simple quadratic regression with the bromatological attributes, to evaluate the productivity, mineral matter, crude protein, ether extract, neutral detergent fiber, carbohydrate non-fibrous and raw energy. Predominantly, the relationship between the spectral indices and the quality attributes of Tifton 85 grass showed an explanatory capacity of the variance in PC1 above 70% for the evaluated scenarios. Crude protein was the bromatological parameter that presented the highest relationships with the spectral indices obtained, both by RGB images (R^2 between 0.61 and 0.94) and RGNIR images (R^2 between 0.78 and 0.99) for all cutting times evaluated. Mineral matter showed higher ratios (R^2 between 0.66 and 0.99) with cut-off ages of 14, 28 and 42 days for RGNIR images. The neutral detergent fiber obtained R^2 between 0.86 and 0.96 for the cut-off ages of 14 and 28 days, for the RGB and RGNIR images. The ether extract and the non-fibrous carbohydrate were better related to the spectral indices of the RGNIR images. Gross energy showed the highest ratio (R^2 between 0.98 and 0.99) for RGNIR images at 14 and 28 days. The forage accumulation and its accumulation rate between the collection dates showed greater relationships with the RGNIR images at 28, 42 and 56 days (R^2 between 0.78 and 0.99), these periods being the most suitable for generating estimation models.

Keywords: Principal component analysis; optical sensors; foragers; bromatological attributes.

LISTA DE TABELAS

Tabela 1. Radiação (KJ/m ²) nas datas e horários de coletas das imagens RGB e RGNIR.....	39
Tabela 2. Índices espectrais calculados a partir das imagens na região do visível e infravermelho próximo.....	47
Tabela 3. Regressão linear para os parâmetros de qualidade para cada dosagem de adubação em função dos dias de avaliação.....	55
Tabela 4. Regressão Quadrática para os parâmetros de qualidade para cada dosagem de adubação em função dos dias de avaliação.....	55
Tabela 5. Análise descritiva dos dados dos índices espectrais das imagens RGB.....	58
Tabela 6. Análise descritiva dos dados dos índices espectrais das imagens RGNIR – Parte 1.....	59
Tabela 7. Análise descritiva dos dados dos índices espectrais das imagens RGNIR – Parte 2	60
Tabela 8. Porcentagem explicativa e porcentagem explicativa acumulada dos componentes principais gerados pelos índices RGB e RGNIR para cada dia avaliado.....	65
Tabela 9. Correlação entre os componentes principais de maior relevância e os índices espectrais RGB.....	66
Tabela 10. Correlação entre os componentes principais de maior relevância e os índices espectrais RGNIR.....	67
Tabela 11. Coeficientes gerados para o cálculo dos scores do componente principal 1 (CP1) para as imagens RGB.....	68
Tabela 12. Coeficientes gerados para o cálculo dos scores do componente principal 1 (CP1) para as imagens RGNIR.....	68
Tabela 13. Datas de coleta com maior relação entre os índices espectrais das imagens RGB e RGNIR, e os parâmetros de qualidade do capim Tifton 85.....	86

LISTA DE FIGURAS

Figura 1. Representação de uma imagem monocromática e sua representação digital.....	23
Figura 2. Representação cúbica do sistema de cores RGB para construção de imagens coloridas.....	29
Figura 3. Reflectância das plantas no espectro eletromagnético.....	31
Figura 4. Diagrama esquemático da absorção e reflexão dos diferentes comprimentos de onda pela folha.....	31
Figura 5. Área experimental localizada na Fazenda FenoRio - UFRRJ.....	36
Figura 6. Delineamento experimental para aquisição das imagens.....	37
Figura 7. Nomenclatura utilizada no delineamento experimental para aquisição das imagens.	37
Figura 8. Dados meteorológicos entre o DCU (06 de dezembro de 2021) e o último dia de coleta (31/01/2022) registrados pela Estação Meteorológica Embrapa, localizada em Seropédica/RJ.....	38
Figura 9. A) Gabarito de coleta de 1m ² para coleta das amostras; B) Amostras para obtenção do acúmulo de forragem.....	40
Figura 10. A) Amostras de capim Tifton 85 úmidas pós pesagem; B) Amostras de capim Tifton 85 na estufa de ventilação forçada de ar.....	41
Figura 11. A) Amostras de capim Tifton-85 pesadas após secagem na estufa; B) Moinho Tipo Willey utilizado para moer as amostras de capim Tifton-85.....	41
Figura 12. A) Unidade experimental formada pela câmera e tripé; B) Controle e padronização da coleta das amostras com ajuste lateral e vertical.....	42
Figura 13. A) Amostra de imagem capturada com a câmera RGB aos 14 dias e dimensão de 5472x812 pixels; B) Amostra de imagem capturada com a câmera RGB aos 56 dias e dimensão de 5472x812 pixels; C) Amostra de imagem capturada com a câmera RGNIR aos 14 dias e dimensão de 4000x1460 pixels; D) Amostra de imagem capturada com a câmera RGNIR aos 56 dias e dimensão de 4000x1460 pixels.....	43
Figura 14. Interface gráfica do programa no Python para obtenção dos valores de RGB e RGNIR.....	44
Figura 15. Pasta contendo as imagens coletadas e a rotina computacional no Python.	44
Figura 16. Janela que apresenta a resposta do comando “Mostrar Nome” onde o	45

usuário é capaz de testar o nome da imagem	
Figura 17. Resultado do cálculo das funções em arquivo .txt contendo os valores médios de intensidade das imagens	46
Figura 18. Interface gráfica do arquivo .txt com os valores médios de intensidade calculados para as imagens RGB e RGNIR	46
Figura 19. Matéria Mineral (%MS) do capim Tifton 85 em função dos dias para cada tipo de adubação.	50
Figura 20. Proteína Bruta (%MS) do capim Tifton 85 em função dos dias para cada tipo de adubação.	50
Figura 21. Fibra em Detergente Neutro (%MS) do capim Tifton 85 em função dos dias para cada tipo de adubação.	52
Figura 22. Extrato Etéreo (%MS) do capim Tifton 85 em função dos dias para cada tipo de adubação.	52
Figura 23. Carboidratos não fibrosos (%MS) do capim Tifton 85 em função dos dias para cada tipo de adubação.	53
Figura 24. Energia Bruta (Kcal/kgMS) do capim Tifton 85 em função dos dias para cada tipo de adubação.	54
Figura 25. Acúmulo de forragem (kg.ha ⁻¹) do capim Tifton 85 aos 28, 42 e 56 dias após o DCU em função dos níveis de adubação	56
Figura 26. Taxa de Acúmulo de forragem (kg.ha ⁻¹ / dias) do capim Tifton 85 aos 28, 42 e 56 dias após o DCU em função dos níveis de adubação	57
Figura 27. Box plot dos índices espectrais PPR, NDGRI, GR e EVD obtidos pelas imagens RGB em função dos dias de coleta.	61
Figura 28. Box plot dos índices espectrais NDVIr, NDVIg, RNIR e GNIR obtidos pelas imagens RGNIR em função dos dias de coleta	63
Figura 29. Box plot dos índices espectrais EVI, RATIO, TVI e NRVI obtidos pelas imagens RGNIR em função dos dias de coleta.	65
Figura 30. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGB e os valores de proteína bruta das amostras de capim Tifton 85.	70
Figura 31. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGNIR e os valores de proteína bruta das amostras de capim Tifton 85.	71
Figura 32. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGB e os valores de matéria mineral das amostras de capim Tifton 85.	72
Figura 33. Relação entre os scores da PC1 dos índices colorimétricos das imagens	73

RGNIR e os valores de matéria mineral das amostras de capim Tifton 85.....	
Figura 34. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGB e os valores de fibra em detergente neutro das amostras de capim Tifton 85.....	74
Figura 35. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGNIR e os valores de fibra em detergente neutro das amostras de capim Tifton 85.....	75
Figura 36. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGB e os valores de extrato etéreo das amostras de capim Tifton 85.....	76
Figura 37. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGNIR e os valores de extrato etéreo das amostras de capim Tifton 85.....	77
Figura 38. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGB e os valores de carboidratos não fibrosos das amostras de capim Tifton 85.....	78
Figura 39. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGNIR e os valores de carboidratos não fibrosos das amostras de capim Tifton 85.....	79
Figura 40. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGB e os valores de energia bruta das amostras de capim Tifton 85.....	80
Figura 41. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGNIR e os valores de energia bruta das amostras de capim Tifton 85.....	81
Figura 42. Relação entre os scores da PC1 dos índices espectrais das imagens RGB e os valores de acúmulo de forragem das amostras de capim Tifton 85.....	82
Figura 43. Relação entre os scores da PC1 dos índices espectrais das imagens RGNIR e os valores de acúmulo de forragem das amostras de capim Tifton 85.....	83
Figura 44. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGB e os valores de taxa de acúmulo de forragem das amostras de capim Tifton 85.....	84
Figura 45. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGNIR e os valores de taxa de acúmulo de forragem das amostras de capim Tifton 85.....	85

SUMÁRIO

1 INTRODUÇÃO	12
2 REVISÃO DE LITERATURA	14
2.1 Produção de pastagens em regiões tropicais	14
2.2 Características nutricionais de forragem	14
2.3 Influência da adubação nitrogenada nas culturas forrageiras	18
2.4 Aspectos gerais da visão artificial.....	20
2.5 Processamento digital de imagens	22
2.5.1 Aquisição de imagens	22
2.5.2 Pré-processamento de imagens	23
2.5.3 Segmentação de imagens	24
2.5.4 Extração de características	24
2.5.5 Classificação e reconhecimento de padrões	24
2.6 Aplicação da visão computacional a partir de imagens digitais	25
2.7 Câmeras	25
2.8 Imagem digital	26
2.8.1 Espaço de cor RGB	28
2.8.2 Espaço do espectro NIR	29
2.9 Espaço eletromagnético e índices de vegetação	30
2.10 Análise de componentes principais aplicadas na avaliação de imagens digitais	33
3 MATERIAL E MÉTODOS	36
3.1 Caracterização da área experimental	36
3.2 Caracterização das condições ambientes durante o experimento	38
3.3 Obtenção do acúmulo de forragem em campo	39
3.4 Obtenção dos parâmetros qualidade do Tifton 85	40
3.5 Obtenção das imagens digitais	42
3.5.1 Aparato experimental	42
3.5.2 Processamento das imagens digitais e cálculo dos índices espectrais	43
3.6 Análise dos resultados	47
3.6.1 Análise dos dados obtidos pelos parâmetros de qualidade de forragem.....	47
3.6.2 Análise de componentes principais para avaliação dos índices espectrais	48
4 RESULTADOS E DISCUSSÃO	49

4.1 Parâmetros bromatológicos do capim Tifton 85	49
4.2 Acúmulo de forragem e taxa de acúmulo de forragem do capim Tifton 85	55
4.3 Avaliação dos índices espectrais a partir da análise de componentes principais	57
4.4 Avaliação da relação entre os índices espectrais e os parâmetros de qualidade por meio da ACP.....	65
4.5 Relação entre os índices espectrais e os parâmetros de qualidade em cada dia de análise	67
5 CONCLUSÃO	87
6. REFERÊNCIAS BIBLIOGRÁFICAS	87

1. INTRODUÇÃO

As inovações tecnológicas ampliam as possibilidades de aumento de produtividade das pastagens e vem tornando o setor agropecuário cada vez mais rentável. Mercado este, cada vez mais exigente, principalmente no que se refere à qualidade do produto (GONÇALVES et al., 2022). Atualmente o Brasil é destaque a nível mundial na produção de bovinos, com rebanho de 214 milhões de cabeças distribuídos, em sua grande maioria, nos 200 milhões de hectares de pastagens nativas e implantadas (ABIEC, 2019).

O potencial produtivo das pastagens no Brasil é elevado, principalmente por se tratar de um país de clima tropical. O mercado de forrageiras no Brasil movimentava mais de R\$ 1,4 bilhão ao ano, sendo que as gramíneas forrageiras tropicais representam a maior parte desse mercado (USDA, 2022). Em 2021, o país atingiu cerca de 35,5 milhões de toneladas de leite (EMBRAPA, 2022). Já com relação a produção de carne bovina, o Brasil deve produzir em torno de 8,398 milhões de toneladas em 2022, com aumento de 7,42% em relação ao volume estimado para este ano (SNA, 2022).

Entre as forrageiras tropicais, o gênero *Cynodon* tem sido muito utilizado no processo de intensificação da produção pecuária devido seu alto valor nutritivo, produção de biomassa, rápida produção de feno e boa tolerância à seca (SOUZA et al. 2020). Sendo as pastagens a principal fonte da alimentação animal, o capim Tifton 85 (*nome científico*) foi desenvolvido para atingir altos níveis de produtividade e qualidade forrageira. O capim Tifton 85 é considerado o melhor híbrido da coleção, com boa adaptação às condições tropicais e subtropicais (HERZOG et al., 2021; NERES et al., 2021).

As áreas de automação e mecanização têm gerado soluções para a escassez e restrição na disponibilidade de mão de obra (SCHMIDT, 2019). O uso de equipamentos automatizados e a inserção de tecnologias digital, vem possibilitando o aumento da produção e da eficiência dos recursos utilizados pela agricultura, reduzindo a necessidade de expansão de novas áreas para lavouras e melhorando a qualidade final dos produtos agrícolas (DE QUEIROZ et al., 2022). Com o avanço de tecnologias associadas a agricultura 4.0, a correção nutricional, adubação, irrigação, controle fitossanitário, por exemplo, podem ser realizadas em tempo real e transmitidas instantaneamente (COSTA et al., 2021).

Neste contexto, técnicas derivadas da instrumentação ótica vêm sendo aplicadas como alternativas de monitoramento em diversos processos agrícolas. O monitoramento dos parâmetros de qualidade de forragens por métodos laboratoriais tradicionais muitas vezes são onerosos, requerem análises demoradas e mão-de-obra técnica qualificada como por

exemplo a obtenção de valores de matéria seca e matéria orgânica conforme Souza (2020), proteína bruta (SERAFIM et al., 2021), extrato etéreo (BUENO et al., 2017) e fibra em detergente neutro (MILLER et al., 2021). Desta forma, visão computacional pode se apresentar como alternativa rápida e não destrutiva a essas análises.

A utilização de imagens digitais para avaliar parâmetros de qualidade de produtos agrícolas, em específico nas culturas forrageiras, a partir das bandas do vermelho, verde e azul (RGB - do inglês Red, Green, Blue) e infravermelho próximo (NIR), vêm sendo utilizadas por vários pesquisadores. Silva (2016) discriminou níveis de nitrogênio aplicados em pastagens de Tifton 85 utilizando imagens nas bandas RGB e NIR; Rossiello et al., (2015) verificaram que a adubação nitrogenada no Tifton 85 teve influência no índice de cobertura verde (ICV) obtido com o uso de imagens RGB, concluindo que o índice avaliado pôde ser um indicador de produtividade do capim; Mancin (2019) desenvolveu um software de processamento digital de imagens para análise nutricional de nitrogênio em *Brachiaria brizantha* cv. Xaraés; e Simões et al., (2015) que compararam área foliar verde e massa seca da parte aérea do Tifton 85 (*Cynodon* spp.) obtida por imagens digitais nas bandas RGB e NIR, com indicadores obtidos por métodos diretos.

Os estudos demonstrando o uso de imagens digitais para a mensuração de acúmulo e forragem, nível de clorofila, índice de área foliar, e outros, vêm sendo bastante utilizado, e desta forma, os parâmetros físico-químicos, bromatológicos e energéticos da cultura também devem ser avaliados.

Outros atributos de qualidade, como a matéria seca, matéria mineral, proteína bruta, extrato etéreo, fibra em detergente neutro, entre outros, também devem ser avaliados com o intuito de propor tecnologias alternativas e complementares às técnicas laboratoriais. Tecnologias alternativas baseadas no uso de imagens digitais possibilitam mensurações instantâneas no local, são implementadas com baixo custo e podem facilitar a percepção do produtor ainda em campo, sobre a qualidade nutricional da forragem produzida.

Assim, pesquisas que apresentem alternativas eficientes para análise não só de atributos biofísicos, mas também relacionados a qualidade nutricional do produto, como a aplicação de sistemas automatizados por visão artificial, se apresentam como uma área promissora para o desenvolvimento de tecnologias de baixo custo e aplicáveis às condições de manejo locais.

Este trabalho teve como objetivo geral avaliar atributos de qualidade do capim Tifton 85 (*Cynodon* spp.) por meio de imagens digitais RGB e RGNIR, relacionando os índices colorimétricos com os atributos físico-químicos e nutricionais da cultura. Como

objetivos específicos, este trabalho visou obter as características colorimétricas e atributos de qualidade (físico-químicos, bromatológicos e energéticos) do capim Tifton 85 em diferentes idades de corte e níveis de adubação na região do visível (RGB) e infravermelho próximo (NIR); calcular índices espectrais a partir destas características; avaliar a influência da adubação a partir dos índices espectrais; e utilizar modelos de regressão para avaliar a relação entre os índices espectrais e os atributos de qualidade do capim Tifton 85.

2. REVISÃO DE LITERATURA

2.1 Produção de pastagens em regiões tropicais

O clima tropical se estende por grande área do território brasileiro, possibilitando um potencial produtivo de pastagens no país. Entretanto, o crescimento e desenvolvimento da planta forrageira é variável ao longo do ano, apresentando baixa produtividade no inverno influenciada pelas baixas temperaturas, menores índices de radiação solar e precipitação (SANCHES et al., 2016).

A criação de rebanhos de elevado potencial produtivo e a intensificação dos sistemas de produção, tem provocado o aumento na demanda por alimentos de melhor qualidade e produzidos em grande quantidade (GOMES et al., 2021). Dentro deste cenário, as gramíneas forrageiras de clima tropical e subtropical se apresentam como uma alternativa bastante viável na alimentação animal, dado seu alto potencial de produção, baixo custo e resistência à seca e frio (BARROSO et al., 2021).

Entre as pastagens tropicais, o gênero *Cynodon* tem sido muito utilizado no processo de intensificação da produção de animais, devido seu elevado valor nutricional, resposta à adubação e flexibilidade de uso como pastagem, feno e silagem (AGUIRRE et al., 2014). Considerado como um híbrido de elevado potencial de produção de matéria seca e digestibilidade, o capim Tifton 85 (*Cynodon spp.*) foi desenvolvido por Burton et al. (1993), na Coastal Plain Experiment Station (USDA-University of Georgia), em Tifton, sul do Estado da Geórgia, oriundo do cruzamento de uma introdução sul-africana (PI 290884) com o capim Tifton 68 (SAUTER, 2019).

2.2 Características nutricionais de forragem

A composição química do capim Tifton 85 pode variar de acordo com o estágio fenológico da cultura e às condições de fertilidade, adubação, época do ano, temperatura e pluviosidade. Além disso, o seu estágio de desenvolvimento apresenta grande relação com a composição química e a qualidade das forrageiras (CARDOSO et al., 2020).

A composição química da forragem e sua digestibilidade, refere-se ao termo de valor nutritivo, enquanto a qualidade de uma planta forrageira é representada basicamente pela associação da composição bromatológica, da digestibilidade e do consumo voluntário, da forragem em questão (BLAXTER, 1956; PORFÍRIO, 2019). Dentre as características anatômicas que tem impacto sobre o valor nutritivo, destacam-se a proporção de tecidos e a espessura da parede celular. Tais características apresentam altas correlações com sua composição química, ou seja, os teores de fibra, de lignina e de proteína bruta (TESK, 2018).

Na determinação do valor nutricional de uma espécie forrageira, é necessária a realização de estudos que permitam avaliar de forma conjunta a composição química (matéria seca, matéria mineral, proteína bruta, extrato etéreo, fibra em detergente neutro, entre outros), a digestibilidade e constituintes secundários que podem interferir na ingestão e utilização da forragem consumida pelos animais (CARVALHO, et al 2021).

A matéria seca (MS) é toda fração do alimento excluída a água ou umidade natural e sua determinação é o ponto de partida para a análise de alimentos, sendo de grande importância, uma vez que a preservação do alimento pode depender do teor de umidade presente no material (CARVALHO et al., 2021). Além disso, a fração de matéria seca é utilizada para estimar a quantidade de nutrientes (carboidratos, proteínas, gorduras, minerais e vitaminas) presente no alimento, que são expressos em base seca por ser uma medida padronizada (DETMANN et al., 2012).

A matéria mineral (MM) ou cinzas, é constituída pelo resíduo inorgânico obtido após a queima da matéria orgânica, a qual é convertida em CO₂, H₂O e NO₂, e eliminada em conjunto com as substâncias voláteis decompostas pelo calor. A porcentagem de MM, é utilizada muitas vezes, para se conhecer a matéria orgânica presente no alimento, fornecendo apenas uma indicação da riqueza em elementos minerais da amostra (AOAC, 1990; SOUZA et al., 2017). Krahl et al. (2020), avaliando o capim Tifton 85, obteve valor de MM em torno de 8%, mesmo conteúdo obtido por Souza (2020) e Delongui & Coelho (2018).

Segundo Serafim et al. (2017) a proteína bruta (PB) é um dos nutrientes fundamentais para a nutrição dos animais. A obtenção da PB ocorre por meio das proteínas vegetais, estas por terem porcentagens de N quase constante (16%), permitem por meio de um fator de correção ($100/16 = 6,25$), a transformação do resultado em proteína bruta. O valor de N é determinado por um método que se baseia em três etapas: digestão, destilação e titulação. (DETMANN et al., 2012; GIRARDI et al., 2021).

Os teores de PB na matéria seca produzida pelo Tifton 85 são muito variáveis e dependem do manejo ao qual essa forrageira é submetida. Normalmente o teor de proteína bruta do Tifton 85 encontrado está na faixa de 14 a 19% (FALK, 2020), sendo que alguns autores demonstram que a concentração é variável ao longo do ano (SANCHES et al., 2015), principalmente por dependerem da temperatura e fotoperíodo, como observado pelos teores de 10% de PB verificados em Souza (2020), 12 a 19% em Sanches et al. (2017), 17% em Olivo et al. (2019) e 11 e 12% de PB obtido por Nascimento (2019).

O conteúdo de PB produzida está indiretamente relacionado com o intervalo de cortes adotado e diretamente correlacionado com aplicações de doses crescentes de N. A obtenção de maiores conteúdos de PB são desejáveis, uma vez que o requerimento protéico de animais, como por exemplo, de ruminantes, é um dos que apresentam maior custo com a suplementação, assim se tornando mais econômica sua obtenção por meio das pastagens.

A porção da matéria seca insolúvel em ácidos e álcali é conhecida como fibras, que possui em sua constituição principalmente celulose, hemicelulose e lignina. O teor de lignina, assim como os de fibra em detergente neutro (FDN) e fibra em detergente ácido (FDA), estão bastante relacionados com o grau de maturidade da planta, desta forma, com o avanço da idade, aumenta o grau de lignificação dos tecidos (HUNOFF et al., 2015).

A célula vegetal é revestida por uma parede celular rígida composta basicamente por celulose, mas em células adultas essa parede sofre um espessamento que pode formar uma segunda parede composta por lignina e hemicelulose. O método de Van Soest et al. (1991) consiste, inicialmente, em separar o conteúdo celular da parede celular. Desta forma, as frações resultantes são denominadas de solúveis em detergente neutro, e são compostas por proteína, nitrogênio não protéico (NNP), lipídeos, pigmentos, açúcares, ácidos orgânicos e pectina, e FDN (constituída basicamente por celulose), N ligado a fibra, hemicelulose e lignina (GIRARDI et al., 2021).

Para os animais ruminantes, esse conjunto de componentes dos vegetais que possui baixa digestibilidade, ou seja, as fibras, promovem ao rúmen equilíbrio em função da ruminação. Grimas (2017), relata que a cada 1000 g, aproximadamente 733 g são de FDN, ou seja, 73,3% da MS deste alimento é fibra. Segundo Rodrigues (2022), a determinação das fibras em plantas forrageiras é uma das melhores formas de se estimar o valor nutritivo e a bromatologia das gramíneas. Sanches et al. (2016) avaliando o capim Tifton 85, encontrou FDN de 76%, enquanto Fioreli et al. (2018) verificou cerca de 69% e Ziech et al. (2015) aproximadamente 73% de FDN.

O conteúdo de fibra determina o consumo voluntário do animal. As dietas

volumosas baseadas na quantidade de fibra proporcionam consistência ao bolo alimentar e desta forma regulam a velocidade de passagem pelo trato digestivo. O maior conteúdo de fibras nas silagens, faz com que a passagem pelo trato digestivo seja lenta, ocasionando baixa digestão e absorção dos nutrientes (REDIN, 2021). De acordo com o mesmo autor, a passagem pelo trato digestivo de forma mais rápida provoca fermentações indesejáveis, alterando o metabolismo do animal, isto ocorre quando o conteúdo de fibras é menor.

O termo extrato etéreo (EE) envolve grande grupo de substâncias insolúveis em água, mas solúveis em solventes orgânicos, denominados extratores (éter etílico, éter de petróleo, clorofórmio, benzeno). Conhecer a fração de EE é relevante na análise de alimentos, pois constitui a fração de maior energia presente no alimento, fornecendo em média 2,25 mais energia que os carboidratos (DETMANN et al., 2012).

Teores baixos para o capim Tifton 85 são esperados, com média de 3%. Segundo Costa et al. (2019) as gramíneas em geral possuem reduzidas concentrações quando comparados a alguns alimentos concentrados, como também observado em Souza (2020) teores de aproximadamente 0,4% de EE na matéria seca do capim Tifton 85.

O EE ou gordura, assim como os carboidratos, é composta de carbono (C), hidrogênio (H) e oxigênio (O) (ARAÚJO, 2018). A dieta dos ruminantes geralmente é composta por baixos teores de EE e, assim, a suplementação em algumas condições, provoca modificações na fermentação ruminal e afeta a ingestão de matéria seca e digestibilidade dos nutrientes, bem como a síntese de metano e amônia e a eficiência microbiana (REDIN, 2021). O uso de fontes de gordura na dieta pode incrementar a produção de leite, podendo ainda apresentar efeitos benéficos sobre a reprodução (CHESINI, 2022).

A determinação do EE, na maioria dos casos, é obtida através da extração com solventes, como por exemplo a utilização de éter, em aparelho do tipo Soxhlet, seguida da remoção por evaporação ou destilação do solvente empregado (MONTOVANI, 2019). O resíduo obtido é constituído por lipídeos e todos os compostos que, nas condições da determinação, possam ser extraídos pelo solvente. Estes conjuntos incluem os ácidos graxos livres, ésteres de ácidos graxos, as lecitinas, as ceras, os carotenóides, a clorofila e outros pigmentos, além dos esteróis, fosfatídios, vitamina A e D, óleos essenciais , etc. (MEDEIROS, 2021).

Os carboidratos não fibrosos (CNF) constituem componentes de pressupostos de composição de alimentos calculados por diferença. Embora não sejam analisados diretamente, esses possuem importância direta na interpretação das características

nutricionais de alimentos e dietas ofertadas para animais ruminantes e não ruminantes Para avaliação quantitativa de alimentos na Estação Experimental de Weende no século XIX, foram adotados quatro grupos de compostos químicos como análises laboratoriais usuais para alimentos: MM, PB, FB e EE (DETMANN et al., 2012).

A partir do desenvolvimento do conceito analítico de fibra insolúvel em detergente neutro (FDN) proposto por Van Soest na década de 1960, novas perspectivas foram geradas para a avaliação quantitativa dos alimentos e dietas para animais ruminantes. A substituição da FB pela FDN apresenta um entendimento nutricional mais concreto e amplo de alimentos e dietas. Com isso, a quantificação dos carboidratos não fibrosos (CNF) pode ser obtida de acordo com a adaptação de Hall (2000), sendo $CNF = 100 - [\%PB + \%FDN + \%EE + \%MM]$ (COSTA et al., 2020).

Os alimentos não possuem a mesma capacidade de dar suporte às funções de manutenção, crescimento, reprodução e lactação (SESSIM, 2020). As características peculiares das frações nutritivas constituintes e os alimentos consumidos pelos ruminantes, são transformados pelos microrganismos ruminais. Por isso a determinação da energia do alimento é tão importante, pois permite a obtenção de formulações de dietas mais precisas e conseqüentemente maior eficiência do sistema de produção, com valores preditos mais próximos da exigência real do animal (CAVALCANTI et al., 2019).

A concentração de energia bruta (EB) das dietas pode ser obtida por intermédio da Equação 1, proposta por Nutrient (2001):

$$EB \left(\frac{Mcal}{Kg} MS \right) = 5,6PB + 9,4EE + 4,2FDN + 4,2CNF \quad (1)$$

Onde,

MS= matéria seca (%);

PB= proteína bruta (%MS);

EE= extrato etéreo (%MS);

FDN= fibra em detergente neutro (%MS);

CNF= carboidrato não fibroso (%MS).

2.3 Influência da adubação nitrogenada nas culturas forrageiras

A adubação de pastagem tem como objetivo atender as demandas nutricionais das plantas e sua manutenção e tornar as condições do sistema solo-planta-animal favorável para o bom desenvolvimento das forrageiras e dos animais (POMPOLIM, 2022).

A reposição de nitrogênio, fósforo e potássio são importantes para o

desenvolvimento das gramíneas forrageiras, pois eles são responsáveis pela síntese de compostos orgânicos, eficiência no uso da água, maximização das reações enzimáticas, translocação dos carboidratos, aparecimento e desenvolvimento de perfilhos, número e tamanho das folhas e colmos (MORAIS et al., 2016; ONGARATTO et al., 2021).

Dentre os macronutrientes, o nitrogênio tem influência no número, tamanho, peso e taxa de aparecimento de perfilhos e folhas, e alongamento do colmo. Todos esses fatores são de extrema importância na produção de massa seca e valor nutritivo da forrageira, resultando em maiores índices zootécnicos (FERNANDES & COALHO, 2018).

A busca por uma produção de forragem de maior qualidade pode ser obtida pela associação do manejo correto do pastejo à prática de adubação, principalmente com o uso de nitrogênio. De maneira geral o uso do elemento nitrogênio influencia de forma positiva na produção de matéria seca, na composição dos teores de fibra, síntese de proteínas e é importante para intensificação dos sistemas de produção animal, aumentando a produtividade e com consequência elevando a taxa de lotação animal (TIECHER et al., 2016).

O nitrogênio é o principal nutriente para a manutenção da produtividade das pastagens pois é constituinte das proteínas, e assim maximiza o rendimento da matéria seca das gramíneas forrageiras (DUPAS et al., 2016; GALINDO et al., 2018).

A maioria das pastagens no Brasil recebe pouca ou nenhuma adubação, a aplicação de N em forragens pode permitir impactos positivos e significativos na produtividade das pastagens, na sustentabilidade agropecuária e redução dos impactos ambientais. (TAFFAREL et al., 2016; BORGES et al., 2017).

Segundo Huf (2018), a produção de folhas novas e a eficiência fotossintética, ou seja, a formação da parte aérea da planta, é favorecida pelo uso de adubação nitrogenada.

A utilização de potássio (K) também vem sendo utilizada e, segundo Feller et al., (2022), a adubação combinada entre nitrogênio e potássio, proporciona maiores valores médios de produtividade de massa verde e massa seca.

O K é o segundo nutriente mais requerido pelas gramíneas, sendo essencial para altos rendimentos, qualidade e sanidade das plantas, exercendo função regulatória, participando como ativador de enzimas, contribuindo na manutenção do potencial osmótico e abrindo ou fechando os estômatos. A deficiência de K para o gênero *Cynodon* facilita o surgimento de manchas nas folhas e ataque de fungos, favorecendo a redução na qualidade do feno produzido (ZAPPAROLI, 2014).

É importante destacar que a maior eficiência no uso de adubação nitrogenada, bem

como a resposta na produção animal, está relacionada aos demais nutrientes presentes no solo, que deverão estar em níveis adequados (GOMES et al., 2015), à época do ano (IWAMAMOTO et al., 2014), assim como às condições ambientais favoráveis como temperatura, água e luz (CAMPOS et al., 2016), além do manejo correto das pastagens (BERNARDI & BARETTA, 2018).

Motta (2019) observou que a combinação de nitrogênio e potássio proporciona maior desenvolvimento do capim Mombaça, sendo a relação nitrogênio:potássio de, aproximadamente, 2:1 a que proporciona o maior desenvolvimento do capim. Patzlaff et al. (2020) verificou que o uso da dose de 391 kg de N.ha.ano⁻¹ proporciona maior produção de massa verde, massa seca, maior taxa de acúmulo de forragem e maior capacidade de suporte, enquanto metade dessa dose de N resulta em maior teor de matéria seca.

Viçosi et al. (2020) ao avaliar a resposta do capim Tifton 85 submetido a fontes de adubos nitrogenados e cortes a cada 30 dias, observou que a relação folha colmo aumenta em função número de cortes, enquanto a massa seca por perfilho diminui. Em relação ao teor de proteína bruta, a adubação nitrogenada promove aumento de proteína nas folhas, com aumento de até 164%, e a produtividade do capim Tifton 85 decresce em função do número de cortes.

Em Nascimento (2019), o cultivo do capim Tifton 85 quando submetido a cinco doses de nitrogênio (0, 75, 150, 225 e 300 kg ha⁻¹), promoveu maiores valores de nitrogênio e de proteína bruta no segundo corte (40 dias), quando as unidades experimentais foram adubadas com 225 kg.ha⁻¹. Os teores de FDN e FDA apresentaram os melhores valores na ocasião do terceiro corte que se deu aos 60 dias.

A frequência de utilização da forrageira é outro fator que determina a produção e a qualidade da forragem do *Cynodon*. Assim como cortes mais frequentes resultam em menor produção de matéria seca, porém de maior valor nutritivo do que cortes menos frequentes, que proporcionam produções mais elevadas de matéria seca, porém de qualidade inferior. Além disso, deve-se considerar que a frequência de utilização pode interferir na persistência das forrageiras. Se for praticado um manejo com realização de cortes muito frequentes, a população de plantas forrageiras diminui e a de invasoras aumenta (FALK, 2020).

2.4 Aspectos gerais da visão artificial

A visão é um dos sentidos presentes no corpo humano que possibilita a importante função de captar as informações presentes no ambiente por meio da observação de imagens, que promovem o reconhecimento e diferenciação de locais, cores, objetos e texturas. Com o

desenvolvimento da tecnologia, nos últimos anos, estudos foram direcionados para atribuir essa competência em sistemas de computadores (RÖPER, 2019).

A visão computacional consiste em um corpo de conhecimentos que busca a modelagem artificial da visão humana com o objetivo de reaplicar suas funções, por meio do desenvolvimento de softwares e hardwares avançados (MARCEL, 2018).

De acordo com SAS (2019), as primeiras experiências sobre visão computacional ocorreram com o uso das primeiras redes neurais, utilizadas para detectar os limites de um objeto e para classificar objetos simples em categorias como círculos e quadrados.

Em uma definição simples e abrangente, um sistema de visão artificial é aquele capaz de obter, processar e interpretar imagens (Pode citar um livro de processamento de imagens). Estes sistemas foram desenvolvíveis com o objetivo de tentar imitar o raciocínio humano, em qualquer campo onde se faça necessário o reconhecimento de padrões visuais (BAESSO et al., 2020).

A visão computacional é a área da ciência que estuda e atua no desenvolvimento de teorias e metodologias voltadas à obtenção automática de informações pertinentes contidas em imagens. Estas informações proporcionam o reconhecimento, manipulação e classificação de objetos que compõem uma imagem, contribuindo para o avanço no desenvolvimento de máquinas inteligentes (ARAÚJO, 2019).

Visando imitar a cognição humana e a capacidade do ser humano em tomar decisões de acordo com as informações presentes em imagens, as pesquisas desenvolvidas utilizando a visão computacional também auxiliam a resolução de problemas de alta complexidade (RODRIGUES, 2015; BAESSO et al., 2020). O uso de tecnologias da área de visão computacional estão sendo utilizadas em áreas distintas como: aeronáutica, astronomia, medicina, multimídia, robótica, industrial, sistemas produtivos, entre outras (RUDEK et al., 2011).

No contexto agrícola, a visão computacional vêm sendo aplicada na estimação de safra (TEIXEIRA, 2015) e na avaliação não invasiva de alimentos (FRACAROLLI et al., 2020), detecção de doenças e pragas (GALVÃO et al, 2018) e componente essencial em sistemas robóticos (SANTOS et al., 2020). Também são observados diversos estudos sobre detecção da qualidade de frutos (SANAEIFAR et al., 2015; SA et al., 2016; SANTOS et al., 2020), detecção de animais (BARBEDO et al., 2019) e sintomas de doenças e pragas (FERENTINOS, 2018; BARBEDO, 2019).

Segundo Duckett et al. (2018), a visão computacional deve viabilizar o desenvolvimento de inúmeros equipamentos agrícolas, como máquinas pequenas e

altamente inteligentes capazes de reduzir desperdício e impacto ambiental, proporcionando viabilidade econômica e aumento da sustentabilidade dos alimentos.

As pesquisas utilizando técnica de processamento e análise de imagens digitais permitem a padronização em velocidades muito superiores às obtidas por processos manuais ou mecânicos. Desta forma, obter dados qualitativos e quantitativos sem a necessidade de contato físico vem se mostrando cada vez mais adequado (SILVA, 2015).

O desenvolvimento de aplicações com visão computacional requer plataformas computacionais complexas, além de programas especializados e conhecimento na área (KAUFMAN & VILAS BOAS, 2019). De acordo com os mesmos autores, as plantas submetidas a algum tipo de estresse podem exibir uma série de sintomas como manchas coloridas ou raias nas folhas, nos caules e nas sementes. Esses sintomas visuais alteram continuamente a cor, a forma e o tamanho das folhas à medida que a doença avança. Identificar os meios de combater pragas na agricultura precocemente é um caminho para melhorar a produção e a qualidade do produto final.

Um sistema de visão computacional busca encontrar um resultado para um problema e assim permitir uma máquina “enxergar” o ambiente. Entretanto, para que esse processo ocorra são necessárias três características: base de dados; velocidade de processamento para análise em tempo real; e a capacidade de trabalhar sob condições variadas. Quando se trata do sistema de visão computacional, dois níveis de abstração são normalmente determinados: processamento de imagens (baixo nível) e análise de imagens (alto nível) (GONZALEZ & WOODS, 2008; ARAÚJO, 2019; SANTOS, 2018).

2.5 Processamento digital de imagens

O processamento digital de imagens consiste em um conjunto de técnicas, geralmente dividido em etapas, tais como: aquisição, pré-processamento, segmentação, extração de características, e reconhecimento e interpretação, cada etapa estando associada a uma base de conhecimento (BARBOSA, 2017).

2.5.1 Aquisição de imagens

Na etapa de aquisição da imagem uma câmera transforma a imagem analógica em digital e os aspectos de projeto envolvidos nesta etapa são: condições de iluminação, velocidade de aquisição, resolução, entre outros. A iluminação influencia o processo de limiarização (segmentação), alterando o histograma da imagem original e eliminando eventualmente regiões de vale entre dois picos, que poderia ser utilizado para definir um

limiar. A não uniformidade da iluminação pode ser compensada utilizando a projeção do padrão de iluminação em uma superfície refletora branca, de forma a normalizar a imagem utilizando o limiar escolhido (BARBOSA, 2017).

No processo de aquisição de uma imagem digital são realizadas três etapas: rastreamento, amostragem e quantização.

No rastreamento, o endereço de cada pixel da imagem é identificado. Na etapa de amostragem, é obtido a medida da intensidade de luz de cada pixel, ou mais precisamente, o nível de cinza do pixel. Enquanto na quantização, os níveis de cinza obtidos são representados por um valor inteiro. Desta forma, é possível gerar uma matriz (Castleman, 1996) a qual terá tamanho $N \times M$ pixels (N : linhas e M : colunas) de valores de pixel $p(x, y)$ inteiros positivos, que indicam a intensidade de cor em cada posição (x, y) da imagem (GONZALEZ & WOODS, 2008). A Figura 1 apresenta uma imagem monocromática e a sua representação digital.




Figura 1. Representação de uma imagem monocromática e sua representação digital.

Fonte: Queiroz & Gomes (2014) adaptado por (Gonçalves, 2015).

2.5.2 Pré-processamento de imagens

Na etapa de pré-processamento o objetivo é melhorar a qualidade da imagem, ou seja, corrigir imperfeições e aprimorar a qualidade dos dados adquiridos na aquisição de imagens, para que as etapas posteriores de processamento sejam realizadas de forma mais eficiente. A identificação do objeto é facilitada durante a etapa de exclusão de características do objeto a ser reconhecido, por meio de métodos específicos, por exemplo, a aplicação de destaques de contornos, bordas e destaque de figuras geométricas. A aplicação desses métodos exclui informações não úteis e que possam vir a atrapalhar o trabalho de

reconhecimento (RODRIGUES, 2015).

2.5.3 Segmentação de imagens

Durante a etapa de segmentação, a imagem é dividida em unidades, ou seja, em objetos de interesse que a compõem. Técnicas de processamento de imagens como a detecção de bordas, afinamento, operadores morfológicos e detecção de regiões, podem ser utilizadas nesta etapa. Segundo Barbosa (2017), algoritmos específicos para identificação de formas (linhas, curvas, e outras formas que podem ser parametrizadas) em imagens, cores ou intensidades também são utilizados para conduzir o processo de extração dos objetos de interesse da imagem.

2.5.4 Extração de Características

A extração de características é o processo que define a forma de representação e descrição dos dados, visando obter características úteis que possam ajudar nos processos de distinção entre objetos. A representação constitui-se em determinar se os objetos da cena serão representados por suas fronteiras ou por uma região completa. A representação por fronteira é utilizada quando se tem interesse nas dimensões, forma, cantos ou pontos de inflexão. Quando se pretende analisar as características de propriedade interna, como cor e textura, utiliza-se a representação por regiões (GONZALEZ & WOODS, 2008).

As informações selecionadas das imagens e consideradas importantes para o que se deseja analisar serão adicionadas a um vetor de características. Um vetor de características é uma interpretação numérica resumida de uma imagem ou parte dela, representando suas particularidades mais significativas. O vetor de características é um vetor n-dimensional contendo esses valores. Assim, os dados representativos de uma imagem podem ser armazenados para sua utilização em distintos processos de classificação (SOARES, 2008; ARAÚJO, 2019).

2.5.5 Classificação e reconhecimento de padrões

O trabalho de reconhecimento de padrões tem o propósito de realizar a identificação de objetos (padrões) em um número de classes ou categorias. Este pode ser realizado a partir de duas etapas: o pré-processamento e o reconhecimento propriamente dito (THEODORIDIS & KOUTROUMBAS, 2008). Na etapa de reconhecimento e interpretação os dados obtidos na imagem são avaliados, onde cada objeto é rotulado, resultando assim, na caracterização do conjunto de dados (SOUSA, 2015). O objeto só pode ser reconhecido

se de forma prévia for conhecido seu atributo. Não há como reconhecer algo desconhecido, ou seja, que não tenha sido previamente armazenado em um banco de dados (TRUCCO & VERRI, 1998).

2.6 Aplicação da visão computacional na agricultura

A partir de imagens digitais é possível realizar o monitoramento constante de anomalias na cultura e avaliar sua variabilidade espacial para intervenção (SANTOS et al., 2020). O uso de tecnologias de processamento de imagens de forrageiras tem sido empregado com o objetivo de identificar reais necessidades de manejo, obter as características da cultura e avaliar atributos de qualidade (WEZEL et al., 2014). Há também diversos trabalhos utilizando processamento de imagens por meio de análises espectrais, com a utilização de câmeras fotográficas convencionais (GUPTA et al., 2014; ANDRADE, 2015; MESTRE, 2017; XUE et al., 2017; SRIDEVY et al., 2018; XIE, 2018; SAFA et al., 2019).

A detecção e a classificação de sintomas de doenças, pragas e deficiências nutricionais de plantas em imagens são de enorme interesse na agricultura. A utilização das forrageiras de forma adequada, bem como o seu correto manejo, tende a incrementar a produtividade da pastagem e, como consequência, permite aumentos em produtividade animal (SANTOS et al., 2020).

A demanda por tecnologias de baixo custo tem impulsionado o desenvolvimento de métodos alternativos, de fácil utilização por pequenos e médios produtores. A utilização de câmeras digitais vem ganhando espaço nesse cenário, por apresentar vantagens como fácil manuseio, baixo treinamento, além de ser um método rápido, econômico e não invasivo para tomada de decisão (MANCIN, 2019).

Alguns estudos como de Vergara-Diaz et al. (2016), Zheng et al. (2018), Sridevy et al. (2018), Hallik et al. (2017) e Mancin (2019) apontam que a identificação de nutrientes em plantas, utilizando processamento de imagem já são realizados para diversas culturas com resultados satisfatórios.

2.7 Câmeras

Os sensores de imagem são dispositivos semicondutores fabricados através de processos de microeletrônica, que geram cargas quando o feixe de luz passa pela lente, incide sobre a superfície do sensor, sendo processado por um circuito eletrônico específico e formando assim a imagem digital (SOUZA & CARDOZA, 2012).

As imagens digitais podem ser obtidas por meio de equipamentos eletrônicos

baseados em detectores CCD (do inglês, *Charge Coupled Device*) ou CMOS (do inglês, *Complementary Metal Oxide Semiconductor*) para captura de imagens (FERNÁNDEZ-OLIVERAS et al., 2013), sendo encontrados, por exemplo, em câmeras de máquinas fotográficas digitais (DAMASCENO et al., 2015).

Segundo Carvalho et al. (2003) o sistema de aquisição de imagens digitais gera a representação de uma cena por meio de algum tipo de sensor cuja saída é analógica. Essa saída é convertida em um conjunto de sinais discretizados que são armazenados e processados por um computador.

Um sistema de aquisição básico é composto por um conjunto de lentes, um material fotossensível e um sistema de gravação final da imagem. No caso das imagens digitais, o material fotossensível é o sensor CCD que possui funcionamento baseado no efeito fotoelétrico (RÉ, 2005).

O CCD, é um sensor fotossensível usado em escâneres planos e máquinas fotográficas digitais. Ele é formado por pequenos elementos chamados fotodiodos (células sensíveis à luz), que correspondem, cada um, a um pixel da imagem (GALLETI & SOARES, 2016).

Um dos fatores mais importantes em relação ao sensor CCD é o tamanho, que irá definir a qualidade da imagem produzida. Quanto maior o número de pixels, melhor será a qualidade de resolução (MORENO et al., 2016). Quando os pixels não recebem luz suficiente, o resultado é o que chamamos de ‘ruído’, a presença de salpicos de cores que não pertencem à fotografia (MARTINS, 2012).

Quando a luz atinge os fotodiodos, estes transformam a energia luminosa em pequenos impulsos elétricos, assim, quanto maior a quantidade de luz que atinge o fotodiodo, maior será o impulso gerado. O CMOS apresenta funcionamento muito parecido com o do CCD usado nas câmeras digitais, porém, apesar de ser um chip retangular com milhares de fotodiodos distribuídos em sua superfície, cada fotodiodo possui um transistor que transforma as cargas elétricas imediatamente em sinais digitais, o que faz com que o processamento dos impulsos elétricos gerados seja mais rápido (GALLETI & SOARES, 2016).

2.8 Imagem Digital

A palavra “imagem” corresponde à imitação ou representação visual de algo. Uma vez que a representação visual é capturada com uma cor, quando não há presença de luz, se torna impossível representar algo que se possa interpretar. A imagem digital pode ser

considerada uma representação de uma matriz numérica bidimensional onde cada seguimento pontual corresponde a um pixel (MEDEIROS et al., 2018).

Uma imagem digital pode ser criada a partir de softwares de desenho ou adquirida por meio de algum dispositivo. O aperfeiçoamento de recursos gráficos, formas e cores variadas resultaram ao longo do tempo em padrões (formatos) diferentes de imagens. A maneira como esta imagem é armazenada no computador define o padrão do arquivo. Os padrões mais comuns são: bmp (bitmap), gif (graphics interchange format), png (portable network graphic) e jpeg (joint photographic experts group) (MARTINS, 2015).

Na análise de imagens digitais, o reconhecimento da cena e mensuração das características dimensionais são obtidas a partir da contagem ou frequência dos pixels. Desta forma, é possível obter medidas de área e comprimento de objetos, além de atributos como padrões de cores e texturas (TEIXEIRA et al., 2006).

Os pixels representam um ou mais valores, que podem ser interpretados por diversos sistemas de cores ou representar um índice para uma tabela de cores. Uma imagem obtida a partir de uma câmera digital é uma matriz com dimensões correspondentes a sua resolução (BARBOSA, 2017).

Segundo Gonzalez & Woods (2010), a imagem digital nada mais é do que a conversão para representação discreta (digital) do que existe na representação contínua (real). Essa representação discreta ocorre pela organização da matriz de pontos para cada tipo de onda, totalizando três matrizes, uma para cada componente de cor vermelho, verde e azul. Shimabukuro & Ponzoni (2017) descrevem que a imagem digital pode ser compreendida como uma cena vista em uma determinada região de comprimento de onda que se torna representada digitalmente como uma matriz de números.

Uma imagem digital (u) é descrita matematicamente como uma matriz com M linhas e N colunas, em que cada entrada u_{ij} (pixel) está associada à intensidade luminosa na posição (i,j) . conforme Equação 2 (PERSECHINO & ALBUQUERQUE (2015).

$$u = \begin{bmatrix} u_{11} & u_{12} & \dots & u_{1N} \\ u_{21} & u_{22} & \dots & u_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ u_{M1} & u_{M2} & \dots & u_{MN} \end{bmatrix} \quad (2)$$

Dessa forma, a imagem é caracterizada por duas componentes: iluminação e reflexão. Sendo a luz um fenômeno físico que ao interagir com o sistema visual humano gera uma “sensação de cor”, a iluminação representa a quantidade de luz incidente na cena que está

sendo vista, enquanto a reflexão representa a quantidade de luz refletida pelos objetos na cena (GONZALEZ & WOODS, 2006).

A captura de comprimentos de ondas de luz (radiação eletromagnética) podem gerar uma imagem. Quando é incidida luz branca sobre um corpo de cor verde, por exemplo, todas as outras cores do espectro visível são absorvidas nele, refletindo desta forma apenas o verde e tornando possível distinguir sua cor (GONZALES & WOODS, 2010; MANCIN, 2019).

2.8.1 Espaço de cor RGB

Segundo Meneses et al. (2012), o termo cor é usado para referir-se a um aspecto da experiência sensorial de visão e tem sua definição como a percepção humana à combinação de dois ou mais comprimentos de onda do espectro eletromagnético na região da luz visível que são refletidos em uma superfície (DAMASCENO et al., 2015).


O modelo RGB é o mais comum dos espaços de cor, tendo em vista também que qualquer cor é expressa sobre a junção das cores vermelho (R), verde (G) e azul (B). Esse modelo baseia-se no mecanismo de formação de cores do olho humano, o qual relaciona a combinação de radiações monocromáticas das três cores primárias (vermelho, verde e azul), tornando-se então a formação de cores como um processo aditivo (GONZALEZ & WOODS, 2008; SOLOMON & BRECKON, 2011). Desse modo, cada canal de cor pode ser formado por um conjunto de até 8 bits dependendo da quantização, resultando em uma imagem de 2, 4, 16, 24 bits ou 16,7 milhões de cores (DAMASCENO et al., 2015).

Existem vários comprimentos de onda do espectro eletromagnético, entretanto nem todos são visíveis ao olho humano. Segundo Gonzalez & Woods (2010), os comprimentos visíveis ao olho humano correspondem a faixa de aproximadamente 400 nm a 700 nm (0,4 a 0,7 μm). Ao longo deste intervalo de comprimento de onda a luz refletida de qualquer objeto ou “corpo” possibilita a distinção de uma grande quantidade de cores através das combinações das três cores básicas, dentro de seus respectivos comprimentos, sendo o azul (450 – 495 nm), o verde (495 – 570 nm) e o vermelho (620 – 750 nm) (GONZALES & WOODS, 2010).

Como o ser humano consegue observar somente algumas cores primárias na sua forma natural, as demais cores são resultantes da combinação entre as três cores básicas – vermelho, verde e azul, também conhecido pela sigla RGB, formada pelo nome das cores na língua inglesa *red*, *green* e *blue*, respectivamente (MANCIN, 2019).

Os valores de R, G e B são representados geometricamente utilizando um cubo de cores (Figura 2). Os eixos representam as três cores R, G e B e pela combinação destas é

obtida a cor do pixel.



Intensidade zero nos três vértices

Figura 2. Representação cúbica do sistema de cores RGB para construção de imagens coloridas. Fonte: Figueiredo (2005).

Em análise de imagens no sistema RGB, para cada uma das três cores são utilizadas as intensidades de 0 a 255 (válido para a quantização em 8 bits), sendo o valor (0,0,0) equivalente a cor preta (ausência de cor), enquanto o valor (255,255,255) ou (1,1,1), quando normalizada, equivale à interseção das três cores primárias, formando a luz branca (ANDRADE, 2015).

A enorme variação de cores ocorre através da combinação dos valores de R, G e B com seus valores possíveis de intensidade. Como por exemplo, ao correlacionar as cores R, G e B nas três dimensões (X, Y, Z), quando os três vértices estiverem na intensidade zero, a cor preta será formada e, quanto mais próximo desse ponto terá tons escuros. À medida que se distanciam do ponto zero, apresentam tonalidade mais clara até se atingir a cor branca (GONZALES & WOODS, 2010).

2.8.2 Região do espectro NIR

A região do infravermelho próximo, ou Near Infrared (NIR) (760 - 1200 nm) é o intervalo em que ocorrem interações importantes do espectro com os níveis de energia dos átomos, sendo um dos meios mais poderosos para se classificar uma vegetação saudável, uma vez que a radiação é refletida por plantas saudáveis e absorvida pela água (LIMA, 2020).

De acordo com Silva (2016), um filtro óptico pode ser adaptado em câmera RGB permitindo a passagem de radiação na faixa espectral do infravermelho próximo (NIR). Desta forma, a banda do infravermelho próximo (NIR), pode ser extraída da banda do vermelho (R) de imagens adquiridas com câmera RGB modificada para infravermelho.

Assim, o processamento a partir de imagens falsa cor infravermelho (IRG) de baixo custo, é composta por: 1ª. banda infravermelho próximo (I), 2ª. banda vermelho (R) e 3ª. banda verde (G).

A câmera Mapir Survey 3 é um modelo que vem sendo utilizado para capturar imagens de materiais altamente refletidos na região do infravermelho próximo (760 – 1200nm), como a vegetação. Além da região do infravermelho próximo, a câmera Mapir Survey 3 captura as imagens refletidas nas bandas R (450 – 495 nm) e G (495 – 570 nm). As imagens desta câmera são comumente calibradas em uma imagem de índice e, em seguida, uma coloração é aplicada para mostrar o contraste entre vegetação saudável e pobre em saúde.

Recentemente, diversas aplicações da câmera Mapir Survey 3 RGNIR tem sido observadas, como em estudos visando avaliar a capacidade de sensor RGNIR para prever parâmetros biofísicos e estimar a demanda evapotranspirativa na cultura do milho (SANTOS, 2019), a comparação de imagens multiespectrais para a análise de mudanças estruturais em área de floresta seca (SANTOS, et al, 2021), avaliação de teores físicos em genótipos de alface vermelha com uso de índices colorimétricos e fenotipagem de alto rendimento (CLEMENTE, et al, 2021).

2.9 Espaço eletromagnético e índices de vegetação

Cada tipo de célula e tecido da planta tem propriedades específicas na absorção e reflexão de certos comprimentos de onda, mostrando assim diferentes aplicabilidades para cada banda do espectro (LI et al., 2014). Por exemplo, na banda da luz visível (400 - 700 nm), devido à absorção da luz por parte da clorofila, a planta tem baixa reflexão. No entanto, na banda do infravermelho-próximo (700 - 1200 nm) a reflexão da planta é muito maior (Figura 3). Em seguida será apresentada uma seleção de trabalhos que usam imagens no espectro de luz visível, imagem de fluorescência e espectrometria no infravermelho próximo.




Figura 3. Reflectância das plantas no espectro eletromagnético. Fonte: Mestre, (2017).

A aquisição de imagem a partir do espectro visível da luz é o método convencional das câmeras digitais, com grande variedade de modelos e preços, esta técnica é a mais aplicada e a mais simples, usada principalmente para a determinação da área, estudo da morfologia da planta e detecção de sintomas (BARBEDO, 2016; BARBEDO et al., 2016). Por apenas obter informação fisiológica da planta, pode ser difícil obter resultados viáveis devido à sobreposição entre folhas (LI et al., 2014).

O termo assinatura espectral refere-se a como ocorre a variação da reflectância de um objeto para cada comprimento de onda (MIRANDA, 2011). Matos et al. (2018) relata que no processo de fotossíntese de uma folha, na medida em que a radiação eletromagnética da luz solar – na faixa visível do espectro, atinge a folha, as moléculas de clorofila – um dos principais pigmentos fotossintéticos, entram em ação para refletir o comprimento de onda do verde, porém reflete numa proporção extremamente menor a quantidade de azul e de vermelho (Figura 4).

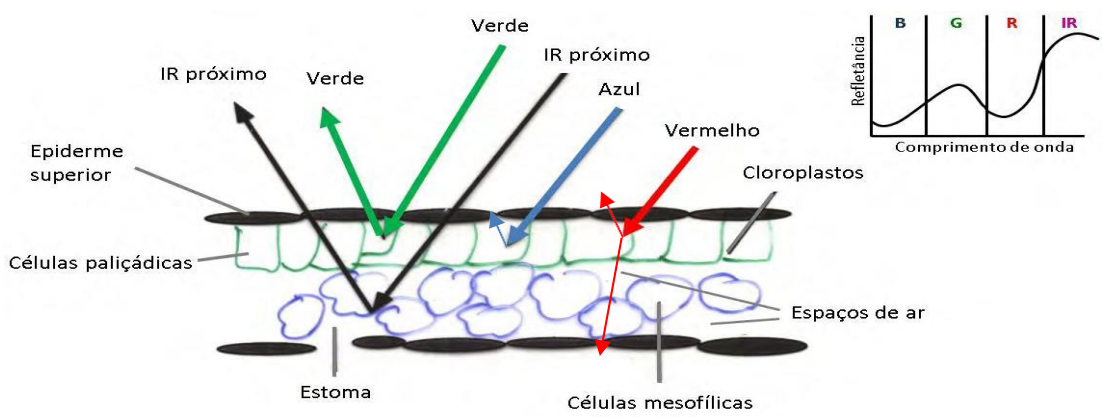


Figura 4. Diagrama esquemático da absorção e reflexão dos diferentes comprimentos de onda pela folha. Fonte: Mestre (2017).

Essa diferença de reflectância espectral dos comprimentos de onda sobre uma mesma folha de planta pode ser aplicada na avaliação da concentração de suas moléculas, pois a clorofila é altamente correlacionada com o teor de N na planta (MANCIN, 2019).

Os índices de vegetação foram criados com base nessas respostas espectrais das plantas em relação a radiação (SHIRATSUCHI et al., 2014), sendo chamados de transformações espectrais desenvolvidas para aprimorar a contribuição das propriedades da vegetação (DIOGO, 2020). São resultados de operações matemáticas entre imagens, transformando os dados a partir da combinação pixel a pixel entre duas ou mais imagens monocromáticas de bandas diferentes a partir de uma regra matemática pré-definida. Atualmente, existem diversos índices espectrais utilizados na agricultura e na avaliação de processos específicos, como processos fotoquímicos relacionados a fotossíntese ou estimativa do conteúdo da pigmentação de folhas (LIMA, 2020).

Segundo Meneses e Almeida (2012), os índices de vegetação são relações entre a reflectância obtida em diferentes bandas espectrais que tem como objetivo realçar as variações de densidade da cobertura vegetal. Na vegetação, a principal banda de absorção é a que se encontra no comprimento de onda de 650 nm, região do espectro visível onde se localiza a luz vermelha; e a região do espectro em que ocorre o maior nível de reflectância se encontra na região do NIR, entre os comprimentos de onda de 760 nm a 1200 nm (JACKSON & HUETE, 1991).

A variação da clorofila permite a geração dos índices, por meio da alteração no tom do verde decorrente da sua concentração nas folhas das plantas, sendo que o N é o principal elemento para sua síntese celular. Como a variação do verde está altamente relacionada ao N, o seu monitoramento se torna importante para a agricultura de precisão realizar aplicações mais localizadas e específicas. Dentro deste cenário, índices são amplamente utilizados para monitorar, analisar e mapear variações temporais e espaciais na estrutura da vegetação, bem como certos parâmetros biofísicos (MANCIN, 2019).

O monitoramento de plantas tem como objetivo medir os vários parâmetros das plantas relacionados com o crescimento, adaptação e identificação de irregularidades na mesma. Estas medidas são geralmente realizadas através do estudo da morfologia da planta, características da folha ou da fruta e fotossíntese (LI et al., 2014). Métodos baseados em processamento digital de imagem permitem quantificar zonas da planta, sendo fontes primárias para o estudo do seu monitoramento (Mestre, 2017). Em Lobet et al. (2013) é apresentada uma base de dados de aplicações de processamento digital de imagem que foram desenvolvidas para a análise de plantas.

2.10 Análise de componentes principais aplicadas na avaliação de imagens digitais

A análise de componentes principais (ACP), é uma técnica matemática da análise multivariada que possibilita investigações com um grande número de dados, cujos principais objetivos são extrair as informações mais importantes de uma tabela de dados, reduzir o conjunto de dados e simplificar a descrição da matriz de dados (Hotelling, 1933). Desta forma, estuda a importância de cada dado coletado durante o estudo e possibilita descartar os valores que pouco contribuem para explicar os resultados da pesquisa (KOUSARI et al., 2019).

A análise multivariada apresenta métodos estatísticos utilizados em situações nas quais as diferentes variáveis são apresentadas ao mesmo tempo e em cada unidade da amostra. As variáveis são correlacionadas entre si e quanto maior o número de variáveis, mais complexa torna-se a análise por métodos comuns de estatística univariada (MARTINI 2018).

Quando a ACP é utilizada, as variáveis são representadas pelas suas respectivas PCs (Principal Componente). A ACP apresenta cada amostra como um ponto no espaço das componentes principais, sendo assim, é possível relacionar as distâncias destes pontos ao conjunto de pontos que formam as classes. Permitindo selecionar as amostras que possuem menores distâncias e associá-las à uma classe (SILVA et al., 2019).

Entre os componentes principais, o primeiro possui a maior variância, o segundo possui a segunda maior, e assim sucessivamente. Este procedimento permite construir índices que possibilitam o agrupamento de indivíduos com o maior grau de similaridade (BARBOSA, 2018).

O método da análise de componente principal explica a estrutura de variâncias-covariâncias através de combinações lineares das variáveis originais, simplificando a estrutura dos dados de modo que a diversidade, influenciada a princípio por um conjunto p -dimensional, possa ser avaliada por um complexo bi ou tridimensional de fácil interpretação geométrica (ABREU et al., 2020). Segundo Morrisson (1976), o primeiro componente principal (Y_1) de um conjunto de p variáveis, X_1, X_2, \dots, X_p , contidas no vetor $X^T = (X_1, X_2, \dots, X_p)$ é definido como a combinação linear (Equação 3):

$$Y_1 = b_{11}X_1 + b_{21}X_2 + \dots + b_{p1}X_p = b'_{1}X, \quad (3)$$

cujos coeficientes b_{i1} são elementos do vetor característico b_1 , associado à maior raiz

característica (λ_1) da matriz de covariância amostral, S , das variáveis X_i 's. Os autovalores (ou raízes características) ordenados, ou seja, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p \geq 0$, são as variâncias amostrais dos componentes principais.

A técnica envolve a matriz de covariância amostral S ou a matriz de correlação R , uma vez que distinta das aplicações envolve esta última, pois, frequentemente, as variáveis têm escalas, apresentando então uma necessidade de padronização. O grau de influência que cada variável X_j tem sobre a componente Y_i é determinado por sua correlação (Equação 4), definida por:

$$Corr(X_j, Y_i) = R_{X_j, Y_i} = b_{1j} \cdot \frac{\sqrt{Var(Y_i)}}{\sqrt{Var(X_j)}} = \sqrt{\lambda_1} \cdot \frac{b_{1j}}{\sqrt{Var(X_j)}} \quad (4)$$

As variáveis padronizadas, Z_1, \dots, Z_p , são expressas por $Z_j = (X_j - \mu_j) / \sigma_j$, com $j = 1, \dots, p$. A contribuição do j -ésimo componente na explicação da variação total pode ser expressa pela Equação 5:

$$Contr Y_j = \frac{Var(Y_j)}{\sum_{j=1}^p Var(Y_j)} = \frac{\lambda_j}{\sum_{j=1}^p \lambda_j} \quad (5)$$

Para a determinação do número de componentes principais a serem utilizadas na análise, pode-se utilizar o critério da porcentagem da variância acumulada. Este critério considera manter os componentes significativos de modo que o seu conjunto explique uma porcentagem pré-definida da variedade global, a um nível de explicação de pelo menos 70% da variabilidade total dos dados (BARBOSA, 2018).

O uso de sistemas de classificação automatizados vêm sendo cada vez mais utilizado pela indústria e agricultura, com o objetivo de reduzir os custos com mão de obra e potencializar a capacidade produtiva (BODHE, 2012; SILVA et al., 2019). Ferraz et al., (2020), desenvolveu um mecanismo de predição de propriedades físicas de duas variedades de soja por meio de imagens digitais, utilizando PCA e modelagem por Redes Neurais Artificiais (RNA). A classificação de diferentes espécies de pimentas a partir da análise de imagem empregando o modelo não paramétrico de classificação PCA foi utilizado por Silva, et al., 2019, enquanto Chacon (2022) estimou o estágio de maturação, volume e massa do mamão (*Carica papaya L.*) por meio de processamento de imagens para classificação automatizada.

Recentemente, trabalhos envolvendo uso de imagens digitais e PCA também

foram desenvolvidos para descritores de sementes de maracujazeiro (FERREIRA et al., 2018), análise nutricional de nitrogênio em *Brachiaria brizantha* cv. Xaraés (MANCIN 2019), estabilidade de produtos lácteos (LEAL, 2019), controle de qualidade de farinha de trigo (CORDEIRO et al., 2020), avaliação da qualidade de tomates (BELLO et al., 2020), diagnóstico nutricional da rúcula para nitrogênio (SILVA, 2021), entre outros.

A visão artificial vêm se apresentando como uma alternativa aos métodos tradicionais de classificação, com o objetivo de medir ou estimar parâmetros, garantindo objetividade, praticidade, rapidez, eficiência, baixo custo e segurança no processo de classificação. O número de estudos relacionados ao processamento de imagens e sistemas de visão computacional também vem sendo explorado na agricultura para avaliar a qualidade nos processos de colheita e pós-colheita (ALKREEM & KARIM, 2021; ALOSAIMI et al., 2021; ANANTHANARAYANA et al., 2020; BIFFI et al., 2021; CHACON, 2022).

3 MATERIAL E MÉTODOS

3.1 Caracterização da área experimental

O experimento foi conduzido em uma área de produção de capim Tifton 85 (*Cynodon* spp.) na Fazenda FenoRio localizada nas dependências da UFRRJ em Seropédica-RJ, com coordenadas geográficas de Latitude -22,7414 e Longitude -43,7053. O clima da região, segundo a classificação de Köppen (1948), é do tipo Aw, caracterizado por um clima tropical com estação seca.

Antes do início do experimento, foi realizado um corte de uniformização para padronizar as condições do experimento, a uma altura de 0,05 m do solo. Também foi realizada uma aplicação à lanço de adubo (proporção 25N.0P.25K), em todas as unidades experimentais. O adubo foi pesado no local, com o auxílio de uma balança e a aplicação foi realizada manualmente. A área experimental é apresentada na Figura 5.



Figura 5. Área experimental localizada na Fazenda FenoRio - UFRRJ.

As unidades experimentais foram dispostas no delineamento Blocos Inteiramente Casualizados, sendo constituídas por 4 parcelas (tratamentos) de 50m² (10 x 5m²) e 4 subparcelas (idades de corte) de 12,5m² (5 x 2,5m²) com 3 repetições (blocos), sendo as parcelas formadas pelas doses de adubo (0, 100, 200 e 300 kg.ha⁻¹). Em cada subparcela foram realizadas 3 leituras (amostras de imagens). Desta forma, totalizando 48 unidades experimentais e área experimental total foi de 0,963 ha, conforme

delineamento experimental apresentado na Figura 6.




Figura 6. Delineamento experimental para aquisição das imagens.

Para melhor compreensão, na Figura 7 são apresentados os significados das siglas utilizadas no delineamento experimental.

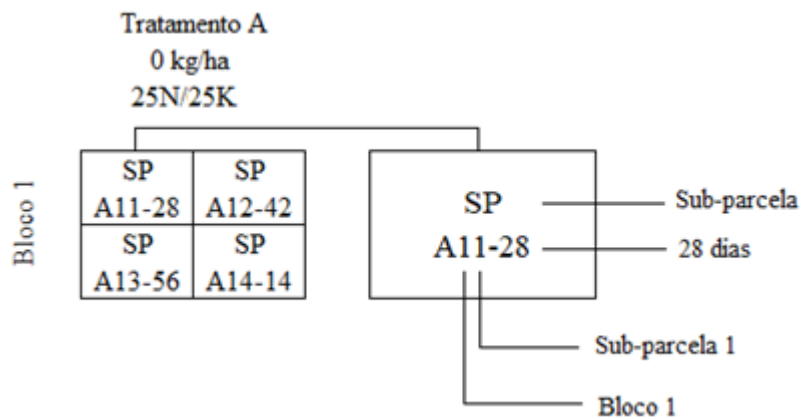


Figura 7. Nomenclatura utilizada no delineamento experimental para aquisição das imagens.

3.2. Caracterização das condições ambientes durante o experimento

As análises foram realizadas em quatro épocas: 14, 28, 42 e 56 dias após o corte de uniformização (DCU). Durante o experimento foram coletados os dados meteorológicos através dos registros disponibilizados pela Estação Meteorológica Embrapa, localizada em Seropédica/RJ (coordenadas geográficas de Latitude -22.7414 e Longitude -43.7053).

Os dados meteorológicos entre o DCU (06 de dezembro de 2021) e o último dia de coleta (31/01/2022) foram analisados pelos parâmetros diários de temperatura máxima e mínima, umidade máxima e mínima, quantidade de precipitação, velocidade do vento e radiação.

Conforme observado na Figura 8, durante o período experimental, as temperaturas diárias de máxima e mínima, variaram entre 32 e 20°C, respectivamente. A umidade diária variou entre 90 e 43%. Com relação à precipitação, o período foi marcado por poucas chuvas, sendo o maior registro, ocorrido no dia posterior à adubação e DCU, com aproximadamente 3,18 mm. A velocidade do vento foi em média 1,67 m/s, enquanto a radiação apresentou média de 1354 KJ/m².

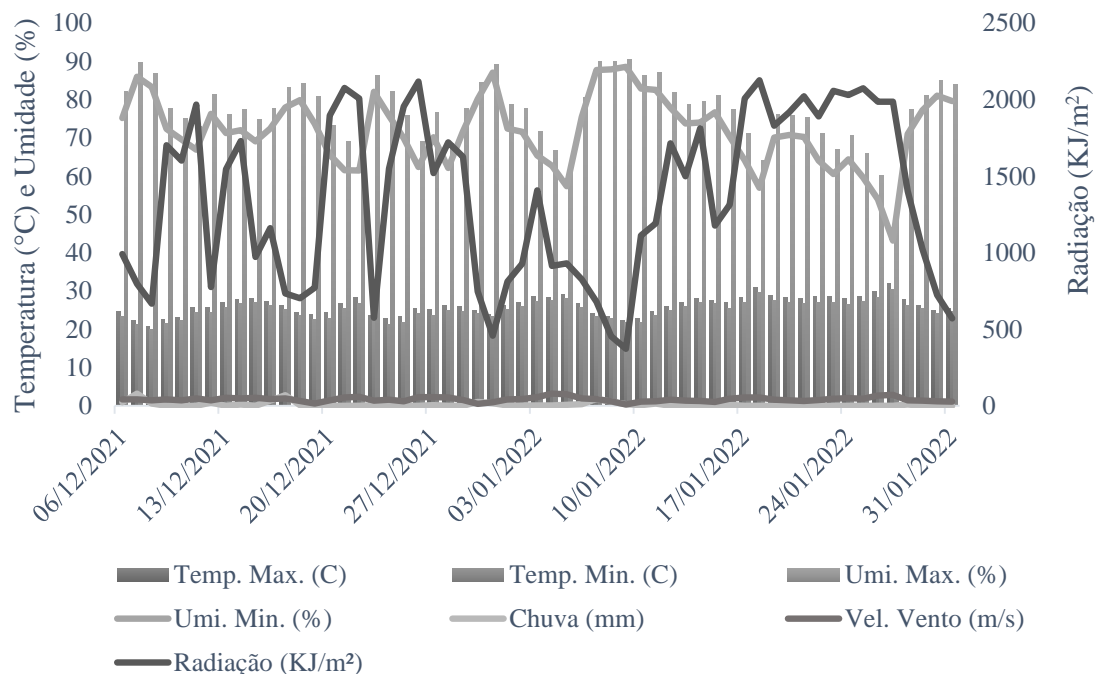


Figura 8. Dados meteorológicos entre o DCU (06 de dezembro de 2021) e o último dia de coleta (31/01/2022) registrados pela Estação Meteorológica Embrapa, localizada em Seropédica/RJ.

A radiação solar no momento da coleta das imagens é apresentada na Tabela 1. As maiores radiações foram registradas nos horários das coletas dos 14 e 42 DCU. Como a presença de luz influencia a captura das informações presente na cena, possivelmente, nessas duas datas, a presença de maior radiação no momento da coleta, permitiu maiores sensibilidades no registro das informações contidas nas imagens RGB e RGNIR.

Tabela 1. Radiação (KJ/m²) nas datas e horários de coletas das imagens RGB e RGNIR.

Datas da coleta	Dias de coleta	09:00	10:00	11:00	12:00
20 de Dezembro/2021	14 DCU	121,60	849,90	1715,90	2526,70
03 de Janeiro/2022	28 DCU	63,10	200,70	817,80	1459,20
17 de Janeiro/2022	42 DCU	34,90	599,30	1434,80	2197,40
31 de Janeiro/2022	56 DCU	5,30	60,90	208,50	762,70

DCU- dias após o corte de uniformização.

3.3 Obtenção do acúmulo de forragem em campo

O acúmulo de forragem foi obtido em campo em cada época de corte. Para sua obtenção, foram coletadas três amostras de capim. No procedimento em campo foi realizado a coleta de amostra ao acaso em cada subparcela, com o auxílio de um gabarito de coleta com área de 1 m² (1 x 1m) ao qual foi depositado sobre a unidade experimental de forma aleatória (Figura 9A). O material contido dentro do gabarito foi colhido e armazenado em saco plástico identificado, com boa vedação e conduzido ao Laboratório de Pesquisa Multiusuários do Grupo de Energias Renováveis e Alternativas Rurais (LabGerar), localizado no Instituto de Tecnologia da UFRRJ, onde foi pesado com o auxílio de uma balança analítica de precisão. Após a pesagem, as amostras foram colocadas no pátio para secagem natural até atingirem peso constante (em média 72 horas), conforme Figura 8B.




Figura 9. A) Gabarito de coleta de 1m² para coleta das amostras; B) Amostras para obtenção do acúmulo de forragem.

Após a secagem, foram calculados os valores de matéria seca total, estimados para valores equivalentes em kg.ha⁻¹. Os valores de matéria seca foram obtidos pelo método gravimétrico entre a razão do peso final da amostra após secagem e o peso inicial da amostra, conforme (AOAC, 1995).

3.4 Obteção dos parâmetros de qualidade do Tifton 85

A mensuração dos parâmetros de qualidade (matéria mineral, proteína bruta, fibra em detergente neutro, extrato etéreo, carboidrato não fibroso e energia bruta) é dada a partir de amostras de matéria seca. Optou-se para este fim, coletar a matéria seca separadamente, uma vez que era necessário obter uma quantidade mínima para realizar as análises em laboratório e maior exigência no controle da qualidade da forragem.

Para obtenção desta matéria seca foram coletadas 10 amostras simples em pontos ao acaso dentro de cada subparcela. Estas amostras simples foram homogenizadas formando uma amostra composta de 0,5kg de mesmo nível de adubação para um mesmo bloco. Desta forma, para cada época de coleta (14,26,42,56 DCU) foram obtidas 9 repetições de acúmulo de forragem para cada nível de adubação (3 repetições por bloco). As amostras compostas foram levadas ao Laboratório do Departamento de Nutrição Animal e Pastagem do Instituto de Zootecnia da UFRRJ (Figura 10), para secagem em estufa de ventilação forçada de ar, com temperatura a 55 °C por 72 h (GARDNER, 1986).




Figura 10. A) Amostras de capim Tifton 85 úmidas pós pesagem; B) Amostras de capim Tifton-85 na estufa de ventilação forçada de ar.

Após a secagem, as amostras foram pesadas novamente (Figura 11A), moídas em moinho tipo Willey (Figura 11B), passadas em peneiras com crivo de um milímetro e armazenadas em potes plásticos identificados e com boa vedação.



Figura 11. A) Amostras de capim Tifton 85 pesadas após secagem na estufa; B) Moinho Tipo Willey utilizado para moer as amostras de capim Tifton 85.

Para obtenção dos parâmetros de qualidade do capim Tifton 85 em diferentes idades de corte, foram utilizadas as amostras de matéria seca em estufa armazenadas nos potes plásticos identificados. No Laboratório do Departamento de Nutrição Animal e Pastagem do Instituto de Zootecnia, foram realizadas as seguintes análises bromatológicas, segundo Detmann et al (2012): matéria seca, matéria mineral, proteína bruta, fibra em detergente neutro e extrato etéreo. Com os parâmetros obtidos em laboratório, foram estimados os parâmetros de carboidratos não fibrosos (DETMANN et al., 2006) e energia bruta (MACHADO et al., 2012).

3.5 Obtenção das imagens digitais

3.5.1 Aparato experimental

Os aparatos experimentais (tripés, braços articulados e câmeras) foram utilizados em campo, para aquisição das imagens (amostras) em cada uma unidade experimental, conforme Figura 12A. Para controle e padronização da coleta das amostras, foi utilizado um nível de bolha e um suporte de 1,5m de altura para ajuste lateral e vertical da câmera (Figura 12B). As configurações do aparato experimental foram mantidas constantes em todos os dias de coleta.



Figura 12. A) Unidade experimental formada pelo tripé, braço articulado e câmera; B) Controle e padronização da coleta das amostras com ajuste lateral e vertical.

Foram utilizadas duas câmeras digitais, acopladas individualmente em um aparato experimental. A câmera RGB (Canon S100 RGB) apresentou capacidade de aquisição nos comprimentos de onda nas bandas azul (450 – 495 nm), verde (495 – 570 nm) e vermelho (620 – 750 nm). A câmera GNIR (Mapir Survey 3) com capacidade de aquisição nas bandas verde (495 – 570 nm), vermelho (620 – 750 nm) e infravermelho próximo (700 – 1200 nm).

As imagens com a câmera RGB foram configuradas para captura com resolução de 3648x2432 pixels, ISO1600, white balance automático e com altura de coleta de 1,5m. Enquanto a câmera RGNIR, foi configurada para realizar as capturas de imagens com resolução de 4000x3000 pixels, ISO200, white balance automático e altura de coleta de 1,5m.

3.5.2 Processamento das imagens digitais e cálculo dos índices espectrais

Foram obtidas 3 imagens em cada subparcela, totalizando 36 imagens por época de corte (sendo 9 imagens para cada nível de adubação), para cada tipo de câmera. As intensidades associadas a cada imagem representaram a intensidade média de cada banda que compunha as imagens. As imagens RGB foram recortadas para 5472x812 pixels (Figura 13A e 13B) e as imagens em RGNIR para 4000x1460 pixels (Figura 13C e 13D), com o objetivo de realçar a região de interesse (ROI) e retirar as hastes do tripé e seu efeito de sombra sobre a área, que foram capturadas na cena.



Figura 13. A) Amostra de imagem capturada com a câmera RGB aos 14 dias e dimensão de 5472x812 pixels; B) Amostra de imagem capturada com a câmera RGB aos 56 dias e dimensão de 5472x812 pixels; C) Amostra de imagem capturada com a câmera RGNIR aos 14 dias e dimensão de 4000x1460 pixels; D) Amostra de imagem capturada com a câmera RGNIR aos 56 dias e dimensão de 4000x1460 pixels.

Os valores de intensidade média das imagens RGB e RGNIR foram obtidos em uma rotina computacional desenvolvida em Python 3.10. O programa foi desenvolvido

especificamente para esta pesquisa e foi composto basicamente por três funções denominadas: “nomeImagem”, ”fatoresRGB” e “fatoresNIR”. Em sua interface gráfica o programa apresenta a possibilidade do usuário escolher o tipo de tratamento (A= 0 kg.ha⁻¹, B= 100 kg.ha⁻¹, C= 200 kg.ha⁻¹ e D= 300 kg.ha⁻¹) que foi realizado, as identificações do bloco (1,2 e 3), do sub bloco (1,2,3 e 4), dos DCUs (14, 28, 42 e 56) em que foi realizado a coleta e o tipo de imagem a ser analisada (RGB e RGNIR), como apresentado na Figura 14.




Figura 14. Interface gráfica do programa no Python para obtenção dos valores de RGB e RGNIR.

A rotina computacional (denominada “Beta1”) foi adicionada em uma pasta contendo as imagens coletadas, as quais foram renomeadas de acordo com a nomenclatura utilizada no delineamento experimental. Esta etapa pode ser visualizada na Figura 15.




Figura 15. Pasta contendo as imagens coletadas e a rotina computacional no Python.

A função “nomeImagem” é ativada ao clicar no comando “Mostrar Nome” (Figura 14). Nela o usuário é capaz de testar o nome da imagem e ver se a mesma está selecionada corretamente antes de iniciar os cálculos (Figura 16).

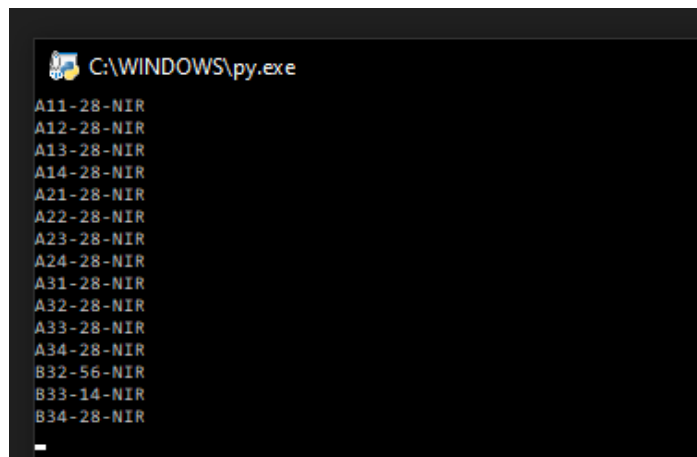


Figura 16. Janela que apresenta a resposta do comando “Mostrar Nome” onde o usuário é capaz de testar o nome da imagem .

A função “fatoresRGB” é ativada ao clicar no botão “Calcular RGB” (Figura 14). Esta função é subdividida em outras funções como o “RGBCalculator”, que realiza a leitura da imagem e calcula as médias RGB retornando os valores para a função “Registro”, que cria um arquivo do tipo .txt com o nome da imagem, salvando os valores médios de RGB na pasta que contém as imagens.

A função “fatoresNIR” é ativada ao clicar no botão “Calcular RGNIR” (Figura 14). Essa função também é dividida em subfunções que reciclam a função “fatoresRGB”. Logo, neste comando, a função calculator é denominada de “RGNIRCalculator”, em que há substituição da banda B pela banda NIR. Assim, a função é subdividida em funções que realizam a leitura da imagem, calcula as médias dos valores de R,G e NIR, e registra

em arquivo do tipo .txt (Figura 17).

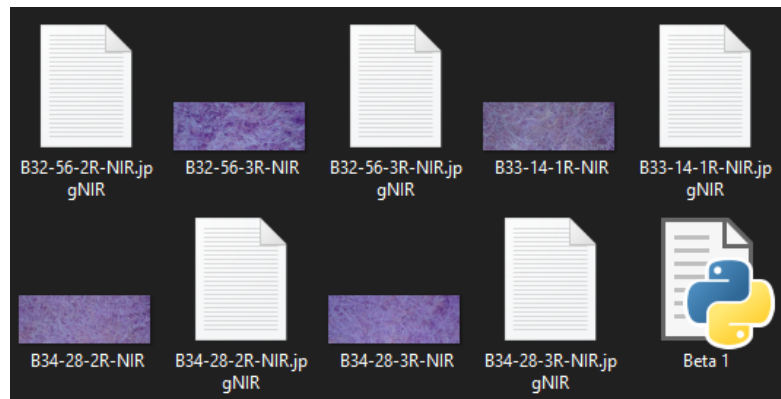


Figura 17. Resultado do cálculo das funções em arquivo .txt contendo os valores médios de intensidade das imagens.

Neste arquivo .txt, foi registrado os valores médios de intensidade RGB e RGNIR para a respectiva imagem coletada (Figura 18).




Figura 18. Interface gráfica do arquivo .txt com os valores médios de intensidade calculados para as imagens RGB e RGNIR.

A partir das intensidades médias de RGB e RGNIR de cada imagem, foram calculados índices espectrais (Tabela 2).

Tabela 2. Índices espectrais calculados a partir das imagens na região do visível e infravermelho próximo.

Equação	Referência Bibliográfica
Índices espectrais RGB	
$PPR = (G - B) / (G + B)$	Metternicht (2003)
$NDGRI = (G - R) / (G + R)$	Tucker (1979)
$GR = G/R$	Sena Jr et al. (2007)
$EVD = (2G - R - B) / (R + G + B)$	Sena Jr et al. (2007)
Índices espectrais RGNIR	
$NDVI_r = (NIR - R) / (NIR + R)$	Rouse et al. (1973)
$NDVI_g = (NIR - G) / (NIR + G)$	Gitelson et al. (1996)
$RNIR = R / NIR$	Richardson & Wiegand (1977)
$GNIR = G / NIR$	Baush & Duke (1996)
$EVI = NIR + (6R) - (7,5B) + 1$	Huete et al. 1994
$RATIO = NIR / R$	Rouse et al. 1974
$TVI = \sqrt{[(NIR - R) / (NIR + R)] + 0.5}$	Deering et al. (1975)
$NRVI = (RNIR - 1) / (RNIR + 1)$	Eastman (1998)

R = banda vermelha; G = banda verde; B = banda azul; NIR = infravermelho próximo; RATIO = índice de vegetação; PPR = Relação de pigmento da planta; NDGRI = Diferença normalizada verde-vermelho; GR = Relação simples verde-vermelho; EVD = Excesso de verde normalizado; NDVI_r = Índice da diferença normalizada; NDVI_g = Índice da diferença normalizada do verde; RNIR = Relação entre vermelho - infravermelho próximo; GNIR = Relação entre verde - infravermelho próximo; EVI = Índice de vegetação melhorada; RATIO = Índice de Vegetação; TVI = Índice de Vegetação Transformada; NRVI = Índice de vegetação de proporção normalizada.

3.6 Análise dos resultados

3.6.1 Análise dos dados obtidos pelos parâmetros de qualidade da forragem

Primeiramente, foi realizada uma avaliação da resposta média dos valores dos parâmetros de qualidade por meio da análise da tendência em função dos dias. Os dados foram submetidos à uma análise de variância (ANAVA), da análise de regressão linear e o teste de hipótese *p*-valor a 0,05 de probabilidade, realizados no software SISVAR. Os valores não significativos (>0,05) foram submetidos a uma análise de regressão quadrática e *p*-valor a 0,05 de probabilidade de se observar um valor da estatística de teste maior ou igual ao encontrado.

Também foi avaliada a resposta do acúmulo de forragem (kg.ha⁻¹) e a taxa de acúmulo de forragem (kg.ha⁻¹.dia⁻¹) do capim Tifton 85 para cada nível de adubação ao longo dos dias. A taxa de acúmulo foi dada por dia, logo os valores encontrados em cada idade de corte foram divididos pelo número de dias até a coleta de acordo com a Equação 6.

$$\text{Taxa de acúmulo de forragem} = \frac{\text{acúmulo de forragem (kg/ha)}}{\text{Dias}} \quad (6)$$

A base de dados de acúmulo de forragem e taxa de acúmulo de forragem foram formadas pelos dados coletados aos 28, 42 e 56 dias. Devido a inconsistências experimentais no momento da realização da pesagem das amostras, os dados para 14 dias após o corte de uniformização não foram utilizados para avaliação destes parâmetros.

3.6.2 Análise de componentes principais para avaliação dos índices espectrais

Em cada bloco foram coletadas 3 imagens, totalizando 9 imagens para cada nível de adubação em cada DCU (36 imagens em cada época de corte). Devido a presença de valores de intensidade de cor discrepantes, foi realizada a seleção das 5 imagens que apresentaram valores de banda G mais próximos da média para as imagens de RGB e das 5 imagens que apresentaram valores de banda NIR mais próximos da média para as imagens de RGNIR. Assim, para cada nível de adubação analisou 5 imagens em cada DCU (20 imagens para cada época de corte).

Realizou-se uma análise descritiva dos índices espectrais para cada época de corte avaliando os seguintes parâmetros: média, mediana, máximo, mínimo, desvio padrão, assimetria, curtose e coeficiente de variação. A análise descritiva foi realizada no software SISVAR.

A assimetria $|A|$ foi avaliada considerando os dados simétricos para $|A| < 0,15$, assimétrica moderada para $0,15 \leq |A| < 1$ e assimétrica forte para $|A| \geq 1$ (ANDRIOTTI, 2003). Já a curtose foi classificada da seguinte forma: curtose = 3 (mesocúrticas), tem-se o mesmo achatamento que o da distribuição normal; curtose > 3 (leptocúrtica), a distribuição apresenta uma curva mais alta (afunilada) e concentrada se comparado a distribuição normal; e curtose < 3 (platicúrtica) a função distribuição é mais “achatada” se comparada a distribuição normal (ANDRIOTTI, 2003). Os coeficientes de variação (CV) foram considerados altos (CV > 60,1%), médios (12,1 a 60%) e baixo (< 12%)

segundo classificação proposta por Warrick e Nielsen (1980).

A análise de componente principal (ACP) foi realizada no Software Past (Versão 4.02), com o objetivo de extrair os índices espectrais mais relevantes e reduzir o conjunto de informações da matriz de dados originais. O conjunto de índices espectrais gerados pelas imagens RGB e RGNIR foram avaliados separadamente.

Para cada conjunto de índices, foi avaliada a porcentagem explicativa e porcentagem explicativa acumulada de cada componente principal (PC). Foram selecionados os PCs com poder explicativo acumulado de no mínimo 70% da variância dos dados. A correlação dos índices espectrais com cada PC gerado pelas imagens RGB e RGNIR foi avaliada.

O procedimento da análise de PCA permite construir índices que possibilitam o agrupamento de indivíduos com o maior grau de similaridade, neste caso, as combinações lineares dos dados, que são determinados para cada componente principal, são chamadas de scores (BRIGANTE, 2022).

Uma vez que o PC1 em geral é o mais representativo na PCA, os scores associados a este componente foram utilizados para avaliar a relação dos índices espectrais e parâmetros de qualidade das forragens. Os coeficientes associados aos índices espectrais que apresentaram maior correlação com outros componentes principais foram desconsiderados do cálculo do scores. Este procedimento gerou uma nova componente principal, chamada de PC1 ajustada.

Os scores do PC1 ajustado foram relacionados com os valores dos parâmetros bromatológicos a partir de modelos de regressão linear simples e quadrático simples. A qualidade da regressão foi avaliada pelo coeficiente de regressão (R^2).

A regressão linear simples e quadrática simples também foi utilizada para avaliar a relação entre o acúmulo de forragem e a taxa de acúmulo de forragem.

4 RESULTADOS E DISCUSSÃO

4.1 Parâmetros bromatológicos do capim Tifton 85

A determinação da matéria seca representou a fração do alimento onde estão os nutrientes. Desta forma, os parâmetros bromatológicos do capim Tifton 85 foram apresentados em percentual (%) da fração de matéria seca (MS). Para este estudo, os parâmetros bromatológicos representam o percentual de matéria mineral (MM), proteína bruta (PB), fibra em detergente neutro (FDN), extrato etéreo (EE), carboidratos não

fibrosos (CNF) e energia bruta (EB), respectivamente, presente na matéria seca do capim Tifton 85 em função dos dias de corte para cada dose de adubação.

A MM apresentou maiores teores aos 28 dias em todas as doses de adubação (Figura 19). O teor de MM do capim Tifton 85 apresentou aumento nas idades de 14 para 28 dias e queda até os 56 dias. A dose de $100 \text{ kg} \cdot \text{ha}^{-1}$ (25N/0,25K) propiciou teores mais altos de MM no capim Tifton 85 aos 28 e 42 dias.




Figura 19. Matéria Mineral (%MS) do capim Tifton 85 em função dos dias para cada tipo de adubação.

Em relação aos teores de PB (Figura 20), nota-se uma queda significativa entre os intervalos de corte. Os tratamentos com $100, 200$ e $300 \text{ kg} \cdot \text{ha}^{-1}$ teve efeito positivo aos 14, 28 e 42 dias, quando comparado à ausência de aplicação de adubo. De acordo com Taffarel (2016), a ausência ou baixa dose de fertilização nitrogenada em pastagens reduz os teores de PB, como é observado neste experimento.




Figura 20. Proteína Bruta (%MS) do capim Tifton 85 em função dos dias para cada tipo de adubação.

A maior dose de adubo aplicada ($300 \text{ kg} \cdot \text{ha}^{-1}$) propiciou maior teor de proteína bruta aos 14 e 28 dias, confirmando que a PB no capim Tifton 85 responde bem à adubação nitrogenada (TAFFAREL et al., 2016). Em Nascimento (2019), os tratamentos foram constituídos de cinco doses de nitrogênio (0, 75, 150, 225 e 300 Kg ha^{-1}), usando-se como fonte a ureia aplicada após cada corte (20, 40 e 60 dias), e as melhores médias de proteína bruta também foram observada nas maiores doses, 225 e $300 \text{ kg} \cdot \text{ha}^{-1}$ com 11 e 12%, respectivamente. Ainda, a PB também teve um decréscimo no terceiro corte realizado aos 60 dias após o corte de uniformidade do capim, tendo como menor média 9%. Valores de PB semelhantes foram encontrados por Taffarel et al. (2014), variando de 12 a 16%, e Sanches et al. (2017) entre 12 a 19%, ambos avaliando os efeitos de doses de nitrogênio na cultura do capim Tifton 85.

Weirich (2015), verificou 9% de PB no capim Tifton 85. O autor atribuiu o baixo teor de PB ao estágio vegetativo avançado no qual foi colhido a forrageira, ressaltando que cortes em intervalos menores propiciam teores mais elevados de PB. Andrade et al. (2018), analisaram os teores de PB do feno de capim Tifton 85, em diferentes idades na sua rebrota e evidenciaram que aos 28 dias os teores de PB eram de 12,3%, enquanto no corte aos 49 dias, possuíam teores de 7,5%.

Os valores obtidos neste estudo aos 14 e 28 dias estão acima do conteúdo crítico para o consumo animal, de 7% de PB presente na MS (Martínez, (2017); Silva & Nascimento Junior, (2006), Deetman, et. al (2014). Enquanto as idades de 42 e 56 dias apresentaram valores médios próximos à este conteúdo crítico.

O teor de FDN (Figura 21) teve incremento de fibras de acordo com o avanço do

estádio de maturação. As doses de 200 e 300 kg.ha⁻¹ demonstraram que houve efeito da adubação no teor de FDN. O mesmo comportamento foi observado por Sanches et al. (2017), quando avaliado o capim Tifton 85 em diferentes doses de adubação obtendo valores de 72% a 79%.




Figura 21. Fibra em Detergente Neutro (%MS) do capim Tifton 85 em função dos dias para cada tipo de adubação.

Em estudo conduzido por Quaresma et al. (2011) foram encontradas médias com valores de 79% a 83%. Andrade et al. (2018), obteve aos 28 dias de rebrota do feno de Tifton 85, teores de FDN de 71,6%, enquanto no corte aos 49 dias, foi observado 73,3% .

Na Figura 22, encontra-se os valores da fração de EE, que correspondem aos lipídeos ou gorduras presente no capim Tifton 85. Aos 14 e 28 dias, foi observado o efeito nos teores de EE a partir das doses de adubação, indicando que maiores valores podem ser encontrados nesta fase de maturação quando utilizada a adubação nitrogenada. Também foi possível observar que a adubação de 200 e 300 kg.ha⁻¹ apresentou comportamento similar e variação pouco significativa entre elas ao longo do estágio de maturação. Costa et al. (2019), também observou teores baixos para o capim Tifton 85, com média de 3%. Segundo o mesmo autor, esse valor pode ser considerado aceitável para as plantas forrageiras, visto que gramíneas em geral possuem reduzidas concentrações quando comparados a alguns alimentos concentrados.




Figura 22. Extrato Etéreo (%MS) do capim Tifton 85 em função dos dias para cada tipo de adubação.

Os valores de CNF (Figura 23) variaram de 3,5 a 7,0% aos 14 dias e atingiram valores abaixo de 2% aos 56 dias do estágio de maturação. Estes valores foram inferiores ao encontrado por Carvalho (2012), sendo relatado valores médios de 6,7% e 5%, obtidos nas idades de 43 e 84 dias, respectivamente. Os CNF possuem rápida degradação ruminal e tem maior aporte energético para o desenvolvimento dos microrganismos ruminais (ROMÃO et al., 2013). Podem ter influência negativa no rúmen, podendo levar um desequilíbrio do pH (ALVES et al., 2016; SILVA et al., 2019).




Figura 23. Carboidratos não fibrosos (%MS) do capim Tifton 85 em função dos dias para cada tipo de adubação.

Segundo Corrêa et al. (2020), os valores de CNF podem variar em função das condições ambientais e fertilidade do solo em que cada forrageira foi submetida durante o

seu desenvolvimento. Ao avaliar o efeito da adubação nitrogenada, foi possível observar que as doses aplicadas apresentaram valores inferiores aos 28 dias e superiores aos 42 dias, quando comparado ao capim não adubado. Os valores de CNF abaixo de 2% aos 56 dias podem ser correlacionados com a maior fração de FDN encontrada neste estágio de maturação mais avançado do capim, que promove o aumento das fibras, comportamento também observado em Valadares Filho et al., (2006), Carvalho (2012) e Sanches et al. (2017).

Os valores médios apresentados na Figura 24, apontaram efeito da adubação na EB presente no capim Tifton 85 em todas as idades de corte, quando comparado à ausência de adubação. A adubação nitrogenada promoveu aumento de EB nas idades de 14 e 28 dias, enquanto as idades de 42 e 56 dias indicaram valores inferiores ao capim não adubado.

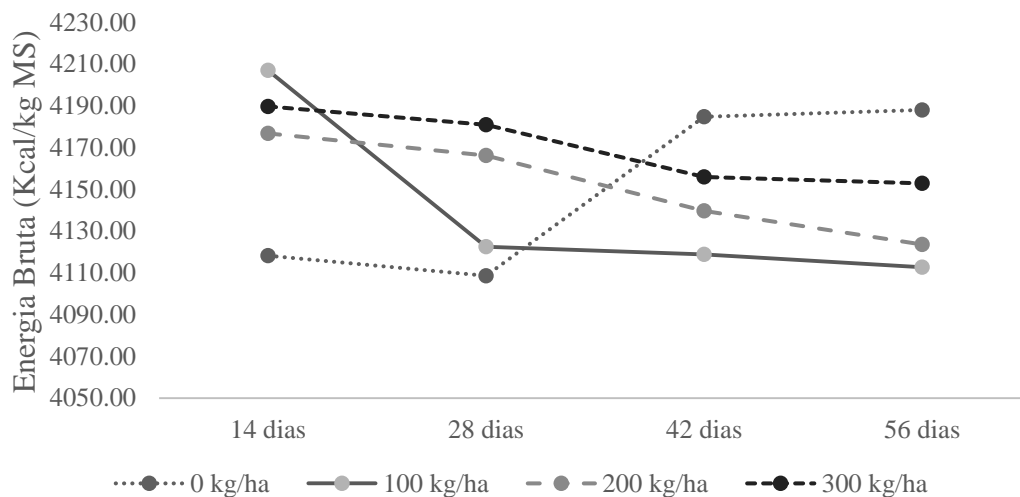


Figura 24. Energia Bruta (Kcal/kgMS) do capim Tifton 85 em função dos dias para cada tipo de adubação.

Neste estudo, observou-se valor médio de EB em 4150 Kcal/kgMS para o Tifton 85, valores estes inferiores aos relatado por Pinto (2019) de 4580 Kcal/kgMS e 4910 Kcal/kgMS para feno e silagem pré-secada de Tifton 85, respectivamente. Entretanto, valores similares são encontrados em Landim (2018) de 4150 Kcal/kgMS.

Cavalcanti et al. (2019) obteve 4050 Kcal/kgMS ao avaliar o capim *Andropogon gayanus*, Valadares et al. (2006) apresentaram valores de EB do capim *Brachiaria decumbens* de 4680 Kcal/kgMS e do capim *Brachiaria brizantha* de 3860 Kcal/kgMS. Enquanto Teixeira et al. (2015) e Martins et al. (2020) relataram valor médio de EB de 4030 Kcal/kgMS e 4033Kcal/kgMS, respectivamente, para o capim elefante verde.

Tendo em vista a resposta dos parâmetros bromatológicos ao longo dos dias,

analisou-se a relação linear e quadrática destes fatores. Os parâmetros nutricionais PB, FDN e EB apresentaram relação linear (p -valor $\leq 0,05$) ao longo dos dias para todas as doses de adubação (Tabela 3). A MM apresentou relação linear em função dos dias (p -valor $\leq 0,05$) quando aplicada dose de 300kg/ha, enquanto o EE apresentou relação para as adubações 0 e 300 kg.ha⁻¹. O CNF apresentou relação linear em função dos dias para os tratamentos com adubação 0 e 200 kg.ha⁻¹.

Tabela 3. Regressão linear para os parâmetros de qualidade para cada dosagem de adubação em função dos dias de avaliação.

	0 kg.ha ⁻¹		100 kg.ha ⁻¹		200 kg.ha ⁻¹		300 kg.ha ⁻¹	
	R ² (%)	p-valor (b ₁)	R ² (%)	p-valor (b ₁)	R ² (%)	p-valor (b ₁)	R ² (%)	p-valor (b ₁)
MM	8,16	0,44 ^{ns}	12,97	0,19 ^{ns}	1,29	0,80 ^{ns}	67,82	0,00 ^s
PB	23,59	0,01 ^s	86,46	0,00 ^s	90,34	0,01 ^s	93,82	0,00 ^s
FDN	82,47	0,00 ^s	73,97	0,01 ^s	96,73	0,00 ^s	86,37	0,00 ^s
EE	38,15	0,03 ^s	12,11	0,4 ^{ns}	14,78	0,5 ^{ns}	65,55	0,02 ^s
CNF	99,30	0,00 ^s	6,23	0,21 ^{ns}	60,84	0,00 ^s	34,38	0,10 ^{ns}
EB	75,83	0,01 ^s	68,61	0,03 ^s	97,64	0,03 ^s	92,02	0,03 ^s

P- Produtividade; MM – Matéria Mineral; PB – Proteína Bruta; FDN – Fibra em Detergente Neutro; EE Extrato Etéreo; CNF – Carboidrato Não-Fibroso; ED – Energia Bruta; R² - Coeficiente de determinação; ^{ns} – não significativo; ^s – significativo; b₁ – coeficiente de regressão.

Os parâmetros de qualidade que não apresentaram relação linear significativa (p -valor $> 0,05$), foram submetidos a uma avaliação por meio de uma regressão quadrática simples. A regressão em a partir de uma função quadrática se justificou pelo fato do pico de produção da cultura ocorrer em épocas intermediárias, antes da fase final do experimento. Como observado na Tabela 4, houve relação significativa para a resposta de MM na dose 300 kg.ha⁻¹, EE nas doses 0 e 300 kg.ha⁻¹, e CNF nas doses 0 e 200 kg.ha⁻¹.

Tabela 4. Regressão Quadrática para os parâmetros de qualidade para cada dosagem de adubação em função dos dias de avaliação

	0 kg.ha ⁻¹		100 kg.ha ⁻¹		200 kg.ha ⁻¹		300 kg.ha ⁻¹	
	R ² (%)	p-valor (b ₁)	R ² (%)	p-valor (b ₁)	R ² (%)	p-valor (b ₁)	R ² (%)	p-valor (b ₁)
MM	14,49	0,31 ^{ns}	22,41	0,10 ^{ns}	0,12	0,94 ^{ns}	73,15	0,00 ^s
EE	27,12	0,05 ^s	3,18	0,66 ^{ns}	25,37	0,38 ^{ns}	73,94	0,01 ^s
CNF	97,88	0,00 ^s	8,42	0,16 ^{ns}	51,08	0,00 ^s	32,02	0,11 ^{ns}

Matéria Mineral; EE Extrato Etéreo; CNF – Carboidrato Não-Fibroso; R² - Coeficiente de determinação; ^{ns} – não significativo; ^s – significativo; b₁ – coeficiente de regressão.

4.2 Acúmulo de forragem e taxa de acúmulo de forragem do capim Tifton 85

O acúmulo do capim Tifton 85 nos dias de coleta de 28, 42 e 56 dias após o DCU, nas diferentes doses de adubação, são apresentados na Figura 25. Observou-se o efeito positivo da adubação ao longo de todos os dias de coleta, em que os menores acúmulos de forragem foram verificados nas áreas que não receberam adubo, enquanto os maiores valores foram encontrados em resposta ao maior nível de adubação aplicada (300 kg.ha⁻¹). O maior acúmulo de forragem foi observada aos 42 dias após o DCU, também na dose de 300 kg.ha⁻¹.

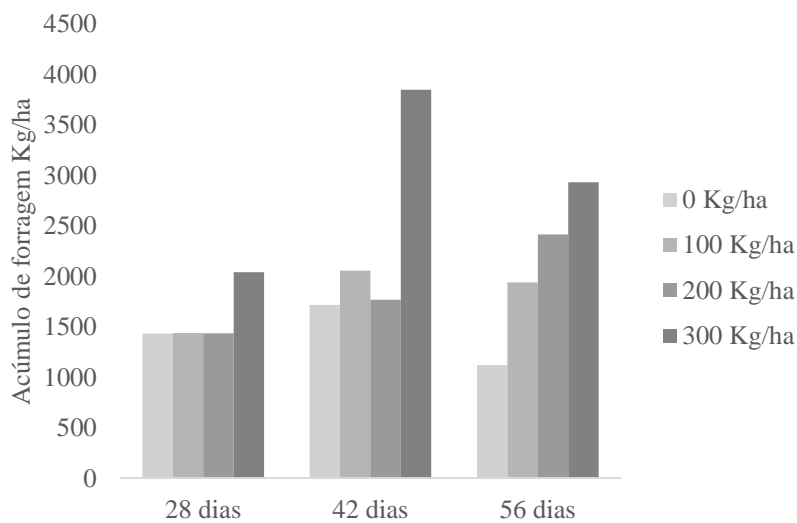


Figura 25. Acúmulo de forragem (kg.ha⁻¹) do capim Tifton 85 aos 28, 42 e 56 dias após o DCU em função dos níveis de adubação.

Diversas pesquisas realizadas com capim Tifton 85 têm verificado o aumento imediato na produção de forragem a partir da adubação nitrogenada. Delongui & Coelho (2022), em estudo com 6 adubações (0, 50, 100, 200, 300 e 400), verificaram maior produção de forragem nas doses de 300 e 400 kg.ha⁻¹. Schaeffer et al. (2021), encontrou diferenças significativas quando utilizada as doses de 100 e 200 kg.ha⁻¹, comparado à ausência de adubação nitrogenada. Enquanto Andrade et al. (2018), verificou que o feno de capim Tifton 85 adubado com 300 kg.ha⁻¹ de N e colhido até os 37 dias de rebrota, resulta em maior produção de matéria seca de feno.

Sendo a taxa de acúmulo de forragem do capim Tifton 85, o acúmulo de forragem em kg.ha⁻¹ por dia, foi observado o mesmo comportamento, com resposta positiva para a maior dose de adubação (300 kg.ha⁻¹) nas três idades de corte avaliada e a maior taxa verificada aos 42 dias quando aplicado 300 kg.ha⁻¹ de adubo, conforme Figura

26.




Figura 26. Taxa de Acúmulo diária ($\text{kg}\cdot\text{ha}^{-1}/\text{dias}$) do capim Tifton 85 aos 28, 42 e 56 dias após o DCU em função dos níveis de adubação.

Ainda, é possível observar que, aos 28 dias os tratamentos com adubação de 0, 100 e 200 $\text{kg}\cdot\text{ha}^{-1}$ promoveram respostas muito próximas para o acúmulo de forragem e sua taxa diária. Enquanto aos 42 dias, a dose de 300 $\text{kg}\cdot\text{ha}^{-1}$ propiciou uma taxa de acúmulo de forragem aproximadamente duas vezes maior quando comparado às demais doses. Aos 56 dias verificou-se crescimento linear do acúmulo de forragem e taxa de acúmulo diária, à medida que aumentou a dose de adubo aplicada.

4.3 Avaliação dos índices espectrais a partir da análise de componentes principais

Na Tabela 5 é apresentada a análise descritiva dos índices espectrais obtidos através das intensidades colorimétricas das imagens RGB em cada época avaliada (DCU). Sendo o desvio padrão uma medida de dispersão dos dados em torno da média amostral, observou-se um baixo desvio padrão em todos os índices espectrais avaliados para as imagens RGB, indicando que os dados estão próximos da média. Quanto à assimetria, os dados de 56 dias para o índice PPR, apresentou assimetria forte ($A \geq 1$), enquanto os demais índices, apresentaram comportamento simétrico.

Tabela 5. Análise descritiva dos dados dos índices espectrais das imagens RGB.

Dias	Média	Mediana	Máximo	Mínimo	DesPad.	Assimetria	Curtose	C.V.(%)
Índice Relação de Pigmento da Planta (PPR)								
14	0,20	0,21	0,25	0,16	0,03	-0,14	-0,66	12,93
28	0,27	0,27	0,30	0,24	0,02	-0,26	-0,86	7,44
42	0,30	0,30	0,35	0,26	0,03	0,10	-0,93	9,87
56	0,30	0,30	0,35	0,28	0,02	1,21	0,49	8,10
Índice Diferença Normalizada Verde - Vermelho (NDGRI)								
14	0,06	0,05	0,14	0,00	0,05	0,43	-0,96	80,32
28	0,08	0,08	0,10	0,06	0,01	0,47	-0,97	15,70
42	0,07	0,07	0,12	0,04	0,02	0,44	-0,15	32,34
56	0,06	0,05	0,08	0,04	0,01	0,63	-0,34	21,13
Índice Relação Simples Verde - Vermelho (GR)								
14	1,13	1,11	1,33	0,99	0,11	0,59	-0,69	9,63
28	1,16	1,16	1,21	1,08	0,04	-0,75	0,56	3,31
42	1,16	1,15	1,27	1,08	0,06	0,51	-0,26	4,79
56	1,12	1,11	1,16	1,07	0,03	0,07	-0,37	2,37
Índice Excesso de Verde Normalizado (EVD)								
14	0,19	0,20	0,31	0,11	0,06	0,38	-0,70	33,52
28	0,23	0,24	0,26	0,18	0,02	-0,64	0,15	10,74
42	0,25	0,26	0,29	0,19	0,03	-0,54	-0,94	13,90
56	0,23	0,23	0,27	0,21	0,02	0,40	-0,06	7,47

Continuando a análise da Tabela 5, observou-se a presença de variabilidade nos dados para todos os índices obtidos, sendo o índice de vegetação NDGRI o que apresentou maior variabilidade espacial na banda do visível, em todas as idades de corte. Os dados apresentaram assimetria moderada e curtose platicúrtica, indicando que os dados estão mais distribuídos, de forma achatada, que a distribuição normal.

Em relação ao CV, foi observado altos valores aos 14 dias (80,32%) e médios nas demais idades de corte indicando que houve resposta nos tratamentos (adubações) em função dos dias de coleta. A maior variação pelo índice NDGRI foi encontrada na fase inicial do estágio de maturação. O índice GR apresentou baixo CV para todas as idades de corte analisada, indicando um conjunto de dados homogêneo. O mesmo comportamento dos dados foi observado no índice EVD para os dias 28 e 56, com baixo CV nos dados.

A análise descritiva para índices espectrais obtidos nas imagens RGNIR (Tabela 6), também possibilitaram observar que estes índices apresentaram baixo desvio padrão,

indicando que os valores obtidos estão distribuídos próximo da média. Os dados coletados na idade de corte de 56 dias, utilizados na obtenção dos índices NDVIr e RNIR, apresentaram valores de curtose platicúrtica (<3) que indicam ser relativamente fácil obter valores que não se aproximam da média e vários múltiplos do desvio padrão. Quando avaliado o CV, a idade de corte aos 56 dias apresentou baixo coeficiente (7,44%), enquanto as idades de 14, 28 e 42 dias, indicaram CV médio para ambos os índices espectrais.

Tabela 6. Análise descritiva dos dados dos índices espectrais das imagens RGNIR – Parte 1.

Dias	Média	Mediana	Máximo	Mínimo	Des Pad	Assimetria	Curtose	C.V.
Índice da diferença normalizada do vermelho (NDVIr)								
14	0,10	0,11	0,15	0,05	0,04	-0,28	-1,51	36,70
28	0,14	0,14	0,16	0,11	0,02	-0,57	-1,03	13,65
42	0,10	0,09	0,17	0,04	0,04	0,21	-1,16	39,62
56	0,16	0,16	0,18	0,13	0,01	-0,74	0,99	7,44
Índice da diferença normalizada do verde (NDVIg)								
14	0,17	0,19	0,22	0,07	0,05	-0,75	-1,21	32,17
28	0,22	0,23	0,26	0,16	0,03	-0,55	-0,97	14,88
42	0,18	0,17	0,25	0,13	0,04	0,71	-0,79	22,61
56	0,22	0,22	0,25	0,19	0,02	0,05	-1,02	9,01
Índice entre a relação do vermelho e infravermelho próximo (RNIR)								
14	0,81	0,80	0,90	0,74	0,06	0,40	-1,61	7,38
28	0,76	0,75	0,81	0,73	0,03	0,92	-0,69	3,91
42	0,83	0,85	0,96	0,71	0,08	-0,08	-0,93	9,57
56	0,72	0,73	0,73	0,70	0,01	-1,50	1,70	1,35
Índice entre a relação de verde e infravermelho próximo (GNIR)								
14	0,72	0,68	0,87	0,64	0,08	0,83	-1,16	11,50
28	0,64	0,63	0,72	0,59	0,04	0,62	-0,83	6,92
42	0,70	0,71	0,78	0,60	0,06	-0,51	-1,04	8,21
56	0,65	0,64	0,68	0,60	0,03	-0,06	-0,96	4,12

De acordo com o CV os índices NDVIr e NDVIg, apresentaram maior variabilidade na banda do infravermelho próximo quando comparado aos índices RNIR e GNIR. Indicando que estes índices conseguiram identificar maior resposta dos níveis de adubação em função dos dias de coleta.

Na análise dos demais índices espectrais obtidos pela imagem RGNIR (Tabela

7) pôde-se perceber que o índice EVI, apresentou curtose platicúrtica (<3) em todas as idades de corte. O estágio mais avançado da cultura (56 dias) obteve CV baixo, enquanto as demais idades apresentaram CV médio. As maiores variações pelo índice EVI foram encontradas aos 14 e 42 dias, com CV de 35,81% e 51%, respectivamente.

Tabela 7. Análise descritiva dos dados dos índices espectrais das imagens RGNIR – Parte 2.

Dias	Média	Mediana	Máximo	Mínimo	Des Pad	Assimetria	Curtose	C.V.
Índice de vegetação melhorada (EVI)								
14	0,03	0,03	0,05	0,02	0,01	0,21	-1,14	35,81
28	0,04	0,05	0,05	0,03	0,01	-0,99	-0,46	14,87
42	0,03	0,03	0,05	0,01	0,02	0,20	-1,26	51,00
56	0,05	0,05	0,05	0,05	0,00	1,15	-2,44	3,68
Índice de vegetação (RATIO)								
14	1,24	1,25	1,35	1,11	0,09	-0,29	-1,57	7,04
28	1,32	1,34	1,38	1,24	0,05	-0,76	-0,88	3,76
42	1,22	1,20	1,41	1,05	0,12	0,27	-1,00	9,49
56	1,38	1,38	1,43	1,33	0,02	-0,26	2,34	1,80
Índice de vegetação transformada (TVI)								
14	0,78	0,78	0,81	0,74	0,02	-0,41	-1,51	2,99
28	0,80	0,80	0,81	0,78	0,01	-0,85	-0,88	1,49
42	0,77	0,76	0,82	0,72	0,03	0,06	-0,81	3,99
56	0,81	0,81	0,82	0,80	0,01	-0,09	-0,19	0,91
Índice de vegetação de proporção normalizada (NRVI)								
14	-0,10	-0,11	-0,05	-0,15	0,04	0,31	-1,54	34,05
28	-0,14	-0,14	-0,11	-0,16	0,02	0,57	-1,03	13,64
42	-0,10	-0,09	-0,02	-0,17	0,05	-0,09	-0,89	49,07
56	-0,16	-0,16	-0,13	-0,18	0,01	0,74	0,99	7,44

Os índices RATIO e TVI, apresentaram curtose platicúrtica, com dados simétricos para todas as idades de corte, exceto para o índice RATIO aos 42 dias, com assimetria moderada. Todas as idades de corte apresentaram CV baixo ($<12\%$), indicando que os dados coletados por estes índices apresentam maior homogeneidade e menor variabilidade espacial em função das doses de adubação.

Quando avaliado o índice NRVI, observou-se que as idades de corte de 14, 28 e 42 dias, apresentaram coeficiente de variação médio, com CV de 34,05%, 13,64% e 49,07%, respectivamente. Neste sentido, a idade de corte aos 56 dias apresentou menor

variabilidade dos dados dos índices espectrais capturados pela banda do infravermelho próximo.

A Figura 27 apresenta o box plot dos índices espectrais obtidos com as imagens RGB. Segundo Soares (2014), o índice PPR, informa o aspecto vegetativo da planta, ou seja, o nível de verde (pigmentação) que ela apresenta. Os valores mais baixos de PPR verificados aos 14 dias, indicam a presença mais amarela apresentada pelas imagens. Isto, possivelmente, pelo estágio de desenvolvimento da planta, com menor volume e tamanho e pela maior captura da refletância do solo. Enquanto os valores aos 56 dias, quando comparado aos 42 dias de coleta, podem ter sido menores pelo estágio de vegetação mais avançado, com maior presença de fluorescência da planta.




Figura 27. Box plot dos índices espectrais PPR, NDGRI, GR e EVD obtidos pelas imagens RGB em função dos dias de coleta.

Segundo Cambraia Filho (2019), o índice NDGRI, que utiliza as faixas espectrais do verde e do vermelho, podem servir como indicador de crescimento e desenvolvimento das plantas. Foi observado que o índice NDGRI apresentou maior amplitude na distribuição dos valores obtidos aos 14 dias, indicando a idade de corte com maior diferenciação na fração de vegetação, biomassa verde e indicador de fenologias vegetais do capim Tifton 85, em função dos níveis de adubação.

Os valores obtidos para o índice GR, que relaciona de forma simples a reflectância espectral nas bandas verde e vermelho, indicaram maior variabilidade dos dados nos dias 14 e 42 dias. Com relação ao EVD, índice utilizado principalmente para facilitar a discriminação do material verde (vegetal) em relação ao solo (BAESSO et al., 2020), observou-se a maior amplitude nas idades de 14 e 42. O índice EVD apresentou menor amplitude na variação dos valores de 28 e 42 dias, podendo indicar as idades com maior dificuldade para distinção do efeito da adubação quando utilizado este índice.

O índice NDVIr utiliza as reflectâncias na banda visível do vermelho e no infravermelho próximo, segundo de Lemos et al. (2018), valores mais próximos a 1, indicam maior cobertura vegetal e quanto mais próximo de -1, menor será a cobertura vegetal. Ainda, quanto mais verde o dossel, mais radiação na faixa do vermelho é absorvida pelas clorofilas, enquanto no infravermelho próximo essa absorção é quase nula e reflectância e transmitância são elevadas, por causa das reflectâncias múltiplas das estruturas foliares internas. Além do vigor, essa resposta também pode estar relacionada com estresses bióticos ou abióticos, aos quais a planta pode estar submetida.

Na Figura 28 os índices NDVIr e NDVIg apresentaram valores positivos, indicando uma vegetação mais sadia, vigorosa e não estressada, pela maior reflectância na faixa do espectro visível e alta reflectância no infravermelho próximo Mello et al. (2020), enquanto valores mais negativos de NDVI expressam baixo vigor ou estresse da planta, apresentando um aumento na reflectância na região do visível e diminuição no infravermelho próximo. As idades de corte de 14 e 42 dias, apresentaram a maior amplitude dos dados, enquanto a idade de 56 dias apresentou valores com menor variabilidade dos dados.




Figura 28. Box plot dos índices espectrais NDVIr, NDVIg, RNIR e GNIR obtidos pelas imagens RGNIR em função dos dias de coleta.

A relação da banda do espectro visível do vermelho e infravermelho próximo pelo índice RNIR, indicou que aos 14 e 42 dias, pela amplitude dos dados, maior variabilidade dos dados. Aos 56 dias, a baixa amplitude verificada, pode ser um indicativo de que esta data apresenta dificuldades para diferenciar os níveis de adubação.

Os índices espectrais RNIR e GNIR, são razões simples entre bandas do espectro visível e a banda do infravermelho próximo. A presença de índices mais altos é refletida pelo status mal nutrido da planta, enquanto índices menores, correspondem à plantas mais bem nutridas (CHICATI et al., 2017). O índice GNIR, apresentou aos 14 dias, maior sensibilidade para diferenciar os níveis de adubação, dada a maior amplitude verificada.

Este indicativo é importante pois se trata de uma fase inicial de desenvolvimento da planta, sendo possível identificar as possíveis anomalias (falta de nutrientes), antes das mesmas apresentarem sintomas visíveis da falta de adubação.

O índice de vegetação melhorada (EVI), apresentou maior amplitude nos dados coletados aos 14 e 42 dias, enquanto na coleta aos 56 dias, o índice quase não apresentou variação (Figura 29). Comportamento similar foi observado no índice RATIO, entretanto, foi observado uma amplitude maior nos dados coletados aos 56 dias, quando comparado ao índice anterior. A maior amplitude dos dados de 14 e 42 dias, pode ser um indicativo de melhor estágio de desenvolvimento para diferenciar as respostas dos níveis de adubação.




Figura 29. Box plot dos índices espectrais EVI, RATIO, TVI e NRVI obtidos pelas imagens RGNIR em função dos dias de coleta.

Os índices TVI e NRVI apresentaram baixa amplitude nos dados coletados aos 56 dias, confirmando, assim como os índices anteriormente apresentados, que a coleta de dados aos 56 dias pode não ser o melhor estágio de desenvolvimento para avaliar o efeito da adubação nitrogenada.

4.5 Avaliação da relação entre os índices espectrais e os parâmetros de qualidade por meio da ACP

A análise do poder explicativo dos PCs, gerados a partir dos conjuntos de índices espectrais obtidos pelas imagens RGB e RGNIR (Tabela 8), demonstrou que os índices obtidos pelas imagens RGB geraram um PC1 com poder explicativo de 90,89% para os dados coletados aos 14 DCU, 94,10% para 28 DCU, 56,38% para 42 DCU e 76,45% para 56 DCU. Uma vez que, com exceção da época 42 DCU, as demais épocas tiveram a variância predominantemente explicada pela PC1 (Porcentagem Explicativa Acumulada - PEA% > 70%), concluiu-se que foi possível reduzir a um componente, o conjunto total de índices espectrais RGB.

Tabela 8. Porcentagem explicativa e porcentagem explicativa acumulada dos componentes principais gerados pelos índices RGB e RGNIR para cada dia avaliado.

	Imagens RGB		Imagens RGNIR		
	PC1	PC2	PC1	PC2	
14 dias					
PE%	90,89	09,10	PE%	95,58	04,35
PEA%	90,89	99,99	PEA%	95,58	99,93
Autovetor	0,019	0,002	Autovetor	0,033	0,001
28 dias					
PE%	94,10	05,90	PE%	89,18	10,78
PEA%	94,10	99,99	PEA%	89,18	99,96
Autovetor	0,003	0,000	Autovetor	0,004	0,001
42 dias					
PE%	56,38	43,61	PE%	93,44	06,40
PEA%	56,38	99,99	PEA%	93,44	99,84
Autovetor	0,006	0,004	Autovetor	0,029	0,002
56 dias					
PE%	76,45	23,55	PE%	60,22	39,77
PEA%	76,45	99,99	PEA%	60,22	99,99
Autovetor	0,002	0,000	Autovetor	0,002	0,001

PE% - porcentagem explicativa; PEA% - porcentagem explicativa acumulada.

Ao analisar os índices espectrais obtidos pelas imagens RGNIR, a PC1 obteve poder explicativo de 95,58% para os dados coletados aos 14 DCU, 89,18% para 28 DCU, 93,44% para 42 DCU e 60,22% para 56 DCU. Com exceção da época 56 DCU, as demais épocas tiveram a variância predominantemente explicada pela PC1 (PEA% > 70%), desta forma, sendo possível reduzir o conjunto total de índices espectrais RGNIR, a um único componente.

A análise da correlação entre os índices espectrais RGB e RGNIR e os PCs de mais relevância para cada época (Tabela 9 e Tabela 10), possibilitou avaliar quais índices foram influentes no cálculo dos scores PC1. Visando aumentar o poder explicativo dos PC1 associados as épocas as quais o poder explicativo foi abaixo de 70%, descartou-se os índices que apresentaram baixa correlação com estes CPs. Desta forma, para o conjunto RGB aos 42 DCU, os índices PPR e EVD, que estavam mais correlacionados com PC2, foram retirados. Este procedimento também foi realizado para os dados referentes aos 56 DCU dos índices espectrais obtidos pelas imagens RGNIR, em que foram retirados os índices NDVIg e GNIR.

Tabela 9. Correlação entre os componentes principais de maior relevância e os índices espectrais RGB.

PC	PPR	NDGRI	GR	EVD
14 dias				
PC 1	0,23	1,00	1,00	0,91
PC 2	0,97	-0,06	-0,08	0,41
28 dias				
PC 1	0,89	0,98	0,98	0,99
PC 2	0,46	-0,17	-0,18	0,14
42 dias				
PC 1	-0,50	0,96	0,97	0,09
PC 2	0,87	0,28	0,25	1,00
56 dias				
PC 1	0,26	0,98	0,98	0,88
PC 2	0,97	-0,19	-0,18	0,48

PPR – Relação de pigmento da planta; NDGRI – Diferença normalizada verde-vermelho; GR – Relação simples verde-vermelho; EVD – Excesso de verde normalizado.

Tabela 10. Correlação entre os componentes principais de maior relevância e os índices espectrais RGNIR.

PC	NDV _{Ir}	NDV _{Ig}	RNIR	GNIR	EVI	RATIO	TVI	NRVI
14 dias								
PC 1	0,99	0,97	-0,99	-0,97	0,98	0,98	0,99	-0,99
PC 2	0,16	-0,26	-0,15	0,25	0,18	0,19	0,16	-0,16
28 dias								
PC 1	0,97	0,89	-0,97	-0,89	0,97	0,97	0,97	-0,97
PC 2	0,23	-0,46	-0,23	0,46	0,23	0,23	0,23	-0,23
42 dias								
PC 1	1,00	0,81	-0,99	-0,82	1,00	0,99	0,99	-1,00
PC 2	0,10	-0,58	-0,09	0,57	0,10	0,10	0,09	-0,10
56 dias								
PC 1	-0,01	-1,00	0,01	1,00	-0,01	-0,01	-0,01	0,01
PC 2	1,00	0,00	-1,00	0,01	1,00	1,00	1,00	-1,00

NDV_{RI} – Índice da diferença normalizada do vermelho; NDV_{Ig} – Índice da diferença normalizada do verde; RNIR – Índice entre a relação do vermelho e infravermelho próximo; GNIR – Índice entre a relação de verde e infravermelho próximo; EVI – Índice de vegetação melhorada; RATIO – Índice de vegetação; TVI – Índice de vegetação transformada; NRVI – Índice de vegetação de proporção normalizada.

4.6 Relação entre os índices espectrais e os parâmetros de qualidade em cada dia de análise

A partir dos ajustes realizados nos componentes principais, com a retirada dos índices espectrais que estavam correlacionados com a PC2, foram obtidos os coeficientes associados aos componentes principais de cada índice, que apresentaram poder explicativo maior que 70%. Os coeficientes do PC1 (ajustado) possibilitaram observar os índices espectrais com maior peso no cálculo dos scores, que formaram os novos valores dos índices espectrais representados pela ACP.

A Tabela 11 apresenta os coeficientes gerados para cada índice espectral das imagens RGB, os quais foram utilizados no cálculo dos scores. O índice GR apresentou maiores coeficientes em todas as idades analisadas, indicando que este índice possui maior influência para o cálculo dos scores da PC1 ajustada.

Tabela 11. Coeficientes gerados para o cálculo dos scores do Componente Principal 1 (CP1) para as imagens RGB.

PC1	PPR	NDGRI	GR	EVD
14 dias	0,063	0,369	0,864	0,338
28 dias	0,372	0,310	0,717	0,502
42 dias	*	0,387	0,922	*
56 dias	0,129	0,366	0,826	0,409

PPR – Relação de pigmento da planta; NDGRI – Diferença normalizada verde-vermelho; GR – Relação simples verde-vermelho; EVD – Excesso de verde normalizado; * - índices retirados para obtenção da PC1 ajustada.

Para as imagens RGNIR na idade de corte de 14 e 28 dias, os índices espectrais GNIR e RATIO, que relacionam as bandas G e R, respectivamente, com a banda na região do infravermelho próximo, foram as que mais influenciaram no cálculo dos scores do PC1 ajustado. Com relação aos 42 dias, os índices de maiores pesos foram o RNIR e o RATIO, enquanto para a idade de corte de 56 dias, o cálculo dos scores teve maior peso pelos índices EVI, RATIO e NRVI, como apresentado na Tabela 12.

Tabela 12. Coeficientes gerados para o cálculo dos scores do Componente Principal 1 (CP1) para as imagens RGNIR.

PC 1	NDVIR	NDVIg	RNIR	GNIR	EVI	RATIO	TVI	NRVI
14 dias	0,230	0,343	-0,390	-0,534	0,075	0,558	0,150	-0,230
28 dias	0,239	0,333	-0,372	-0,448	0,084	0,638	0,150	-0,239
42 dias	0,276	0,199	-0,453	-0,285	0,092	0,694	0,177	-0,276
56 dias	0,249	*	0,342	*	-0,426	-0,534	0,077	0,590

NDVIR – Índice da diferença normalizada do vermelho; NDVIg – Índice da diferença normalizada do verde; RNIR – Índice entre a relação do vermelho e infravermelho próximo; GNIR – Índice entre a relação de verde e infravermelho próximo; EVI – Índice de vegetação melhorada; RATIO – Índice de vegetação; TVI – Índice de vegetação transformada; NRVI – Índice de vegetação de proporção normalizada; * - índices retirados para obtenção da PC1 ajustada.

A utilização de métodos de modelagem de características espectrais para mensurar parâmetros físico-químico de forragens, também vem sendo estudado por outros autores. Santos et al. (2020), utilizou o método de correlação simples entre o índice NDVI e os parâmetros de altura de plantas e a produção de massa seca de lâminas foliares, colmo e material morto da *Urochloa brizantha* cv. *Marandu* em função de doses de nitrogênio, por meio de sensor óptico e imagens digitais. A escolha da equação de regressão foi realizada com base no coeficiente de determinação (R^2), na significância da regressão e de seus coeficientes, testados ao nível de 1% e 5% de significância.

Dias et al. (2019), também avaliou a *Urochloa brizantha* cv. *Marandu* por meio do índice NDVI, em função de doses de adubação nitrogenada. Os autores escolheram a

equação de regressão com base no coeficiente de determinação (R^2), na significância da regressão e de seus coeficientes, testados ao nível de 1% e 5% de significância, e os dados espectrais foram submetidos ao estudo de correlação com as características do dossel da cultura.

A utilização de modelos estatísticos de validação, que facilitem o manejo da pastagem, vem sendo estudado por outros pesquisadores que também observaram a correlação entre índice espectral e produtividade de gramínea (SERRANO et al., 2016; EDVAN et al., 2016).

A reflectância de biomassa em pastagens foi analisada por Tong et al., (2019), com uso de índices espectrais como: índice de vegetação de razão simples (SRVI), índice de vegetação de diferença normalizada (NDVI), índice de vegetação ajustado ao solo (SAVI) e índice de vegetação aprimorado (EVI). A modelagem dos dados foi feita utilizando análise de regressão linear e avaliação com desempenho preditivo da regressão linear múltipla stepwise (SMLR), verificando também resultados positivos.

Com base nos valores ajustados dos PC e a obtenção dos coeficientes dos scores dos índices espectrais, foram obtidas as relações dos índices com os parâmetros bromatológicos do capim Tifton 85. As Figuras 30 e 31, ilustram a relação entre os índices espectrais representados pelo PC1 e os valores de PB obtidos em diferentes dosagens de adubação, com $R^2= 0,605$ com o uso das imagens de RGB e $R^2=0,749$ para as imagens RGNIR. Ainda, o maior pico da relação ocorre aos 28 dias ($R^2 = 0,94$) para os índices espectrais RGB e aos 14 dias ($R^2 = 0,88$) para os índices espectrais RGNIR. Dessa forma, para uma análise mais precoce da cultura, o uso das imagens RGNIR seria o mais indicado.




Figura 30. Relação entre os scores da PC1 dos índices espectrais das imagens RGB e os valores de proteína bruta das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D)56 DCU.




Figura 31. Relação entre os scores da PC1 dos índices espectrais das imagens RGNIR e os valores de proteína bruta das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D) 56 DCU.

Com relação a MM para os índices espectrais RGB, a maior relação quadrática simples ocorreu aos 42 DCU, com $R^2=0,827$ (Figura 32). Sendo considerado o melhor estágio de maturação para obter uma resposta da fração de MM presente na MS do capim Tifton 85.




Figura 32. Relação entre os scores da PC1 dos índices espectrais das imagens RGB e os valores de matéria mineral das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D) 56 DCU.

Observa-se na Figura 33 que, os índices espectrais das imagens RGNIR aos 42 DCU, apresentaram $R^2=0,99$ quando relacionado com a MM. Os 14 DCU e 28 DCU, apresentaram $R^2=0,668$ e $R^2=0,764$, respectivamente. Já a idade de 56 DCU obteve apenas $R^2=0,053$, indicando que a variação de MM pode ser pouco explicada nesse estágio de maturação mais avançado. Os resultados indicaram que para a MM, a melhor idade de corte para gerar modelos de estimativa seria aos 42 DCU, quando utilizado os índices espectrais obtidos com as imagens RGNIR.




Figura 33. Relação entre os scores da PC1 dos índices espectrais das imagens RGNIR e os valores de matéria mineral das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D) 56 DCU.

Ao analisar o parâmetro FDN, as relações obtidas aos 14 DCU apresentaram $R^2 = 0,962$ e $R^2 = 0,863$ para 28 DCU utilizando as imagens RGB, indicando que a fração de FDN no capim Tifton 85 pode ser melhor obtida nestas idades (Figura 34). As imagens RGB coletadas a partir dos 42 DCU, com estágio de desenvolvimento mais avançado, apresentaram menores relações entre seus índices espectrais e o FDN, assim não seriam as melhores datas para obter valores de FDN por meio dos índices espectrais RGB.




Figura 34. Relação entre os scores da PC1 dos índices espectrais das imagens RGB e os valores de fibra em detergente neutro das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D) 56 DCU.

Foi possível observar pela Figura 35 que as idades 14, 28 e 42 DCU, apresentaram R^2 de pelo menos 0,918 para o FDN a partir dos índices espectrais obtidos com as imagens RGNIR. Para este parâmetro bromatológico, os índices espectrais RGNIR possibilitaram maior relação do que os índices espectrais RGB, em todas DCU analisadas, e neste caso seria o mais indicado para obter modelos de estimativas.




Figura 35. Relação entre os scores da PC1 dos índices espectrais das imagens RGNIR e os valores de fibra em detergente neutro das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D) 56 DCU.

Com relação ao parâmetro bromatológico EE, os índices espectrais calculados a partir das imagens RGB, indicaram maior relação aos 42 DCU (Figura 36). Neste estágio de maturação, foi obtido $R^2 = 0,999$. As demais DCU apresentaram R^2 abaixo de 0,366 e assim não seriam as mais indicadas para obter valores desta variável.




Figura 36. Relação entre os scores da PC1 dos índices espectrais das imagens RGB e os valores de extrato etéreo das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D) 56 DCU.

A Figura 37 indica que os índices espectrais obtidos com as imagens RGNIR apresenta alta relação com os valores de EE encontrados nas idades 14, 28 e 56 DCU, com R^2 de pelo menos 0,948 e desta forma poderiam ser utilizados para obter melhores valores de EE presente no capim Tifton 85 nestes estádios de maturação. Também foi possível observar que os índices espectrais RGNIR, apresentaram maiores relações com o EE, do que os índices espectrais RGB, exceto para os 42 dias. Estas relações indicam que para uma análise mais precoce da cultura, o mais indicado seria a utilização dos índices espectrais com as imagens RGNIR.




Figura 37. Relação entre os scores da PC1 dos índices espectrais das imagens RGNIR e os valores de extrato etéreo das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D) 56 DCU.

Em relação ao CNF foi possível observar pela Figura 38 que os índices espectrais obtidos com as imagens RGB, apresentaram relação entre seus dados para as idades de 28 e 42 DCU, com coeficientes de determinação de $R^2 = 0,878$ e $0,721$, respectivamente. Assim, sendo possível obter melhores valores de CNF nestas maturação épocas de corte quando utilizado os índices espectrais RGB.




Figura 38. Relação entre os scores da PC1 dos índices espectrais das imagens RGB e os valores de carboidratos não fibrosos das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D) 56 DCU.

Na Figura 39, observa-se que as idades de 14 e 28 DCU obtiveram R^2 superior a 0,977 entre o CNF e os índices espectrais obtidos com as imagens RGNIR. Ainda, aos 42 DCU, foi obtido $R^2 = 0,762$. Indicando que para os índices espectrais RGNIR, as maiores relações com o CNF podem ser obtidas nas idades de 14, 28 e 42 DCU, sendo possível obter melhores resultados na fase mais inicial de desenvolvimento da cultura.




Figura 39. Relação entre os scores da PC1 dos índices espectrais das imagens RGNIR e os valores de carboidratos não fibrosos das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D) 56 DCU.

Para obter os valores de EB no capim Tifton 85 a partir dos índices espectrais calculados com o uso de imagens RGB, as idades de 42 e 56 DCU apresentaram as maiores relações com R^2 de 0,998 e 0,865, respectivamente (Figura 40). Este resultado demonstra que as maiores relações entre índices espectrais RGB e a EB, podem ser obtidas, nas condições deste estudo, nas idades com o estágio de desenvolvimento da cultura mais avançado.




Figura 40. Relação entre os scores da PC1 dos índices espectrais das imagens RGB e os valores de energia bruta das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D) 56 DCU.

Utilizando os índices espectrais das imagens com a câmera RGNIR (Figura 41), foi obtida maior relação com a EB aos 14 DCU com $R^2 = 0,991$ e 28 DCU com $R^2 = 0,963$. Indicando serem estas idades as melhores para se obter valores mais próximos da média de EB avaliada neste estudo. Os índices espectrais RGNIR obtiveram maiores relação com a EB quando comparado aos índices espectrais RGB, e neste caso, seria o mais indicado para este parâmetro bromatológico.




Figura 41. Relação entre os scores da PC1 dos índices espectrais das imagens RGNIR e os valores de energia bruta das amostras de capim Tifton 85: A) 14 DCU ; B) 28 DCU; C) 42 DCU e D) 56 DCU.

Além de parâmetros bromatológicos, os índices espectrais também podem se relacionar com atributos ligados ao acúmulo de forragem da cultura, como observado por Domingues (2017), ao avaliar o efeito da adubação nitrogenada na *Uroclhoa brizantha* cv. *BRS paiaguás* por meio de clorofilômetro e imagens digitais, e encontrar relações capazes de estimar sua produtividade; e Simões et al., (2015) ao avaliar a adubação nitrogenada em dosséis de *Cynodon spp.*, utilizando análise de imagens, verificou que tanto o NDVI quanto o índice de cobertura verde podem ser utilizados como indicadores de produtividade do capim Tifton 85.

Na Figura 42 é possível verificar que os índices espectrais analisados no presente estudo também apresentaram relação com parâmetros como o acúmulo de forragem e a taxa de acúmulo do capim Tifton 85. Ainda, indicando que a idade de corte aos 42 DCU possibilitou maior relação entre os índices espectrais das imagens RGB e o acúmulo de forragem do capim Tifton 85, com $R^2 = 0,705$. As idades de corte de 28 e 56

DCU, apresentaram coeficiente de determinação de 0,669 e 0,622, respectivamente.




Figura 42. Relação entre os scores da PC1 dos índices espectrais das imagens RGB e os valores de acúmulo de forragem das amostras de capim Tifton 85: A) 28 DCU ; B) 42 DCU; C) 56 DCU.

Os índices espectrais obtidos com as imagens RGNIR, apresentaram R^2 de pelo menos 0,78 para os 28, 42 e 56 DCU (Figura 44). Sendo a idade de 42 dias considerado o melhor estágio de maturação para obter uma resposta de acúmulo de forragem do capim Tifton 85. Também foi possível observar que os índices espectrais obtidos com as imagens RGNIR, possibilitaram maiores relações com o acúmulo de forragem do que os índices espectrais obtidos com as imagens RGB.




Figura 43. Relação entre os scores da PC1 dos índices espectrais das imagens RGNIR e os valores de acúmulo de forragem das amostras de capim Tifton 85: A) 28 DCU ; B) 42 DCU; C) 56 DCU.

O mesmo comportamento entre os índices espectrais das imagens RGB e RGNIR para o parâmetro de acúmulo de forragem, foi observado para a taxa de acúmulo de forragem, uma vez que a taxa de acúmulo é linearmente dependente do acúmulo de forragem, conforme apresentado nas Figuras 44 e 45. A melhor DCU para avaliar o acúmulo de forragem e a taxa de acúmulo com imagem RGB e RGNIR foram aos 42 dias com $R^2 = 0,705$ e $R^2 = 0,999$, respectivamente. Os índices espectrais RGNIR possibilitaram maior relação com o acúmulo de forragem e a taxa de acúmulo do capim Tifton 85, e seriam os mais indicados para se obter modelos de estimativa para estes parâmetros de qualidade da cultura.




Figura 44. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGB e os valores de taxa de acúmulo de forragem das amostras de capim Tifton 85: A) 28 DCU ; B) 42 DCU; C) 56 DCU.




Figura 45. Relação entre os scores da PC1 dos índices colorimétricos das imagens RGNIR e os valores de taxa de acúmulo de forragem das amostras de capim Tifton 85: A) 28 DCU ; B) 42 DCU; C) 56 DCU.

Como síntese aos resultados das Figuras 30 a 45 , a Tabela 13, apresenta as datas de coleta em que houveram maior relação entre os índices espectrais das imagens RGB e RGNIR, e os parâmetros de qualidade analisados para o capim Tifton 85, sendo as mais indicadas para a avaliação dos parâmetros utilizando os índices obtidos pelas imagens digitais.

Tabela 13. Datas de coleta com maior relação entre os índices espectrais das imagens RGB e RGNIR, e os parâmetros de qualidade do capim Tifton 85.

	Índices espectrais RGB				Índices espectrais RGNIR			
	14	28	42	56	14	28	42	56
	DCU	DCU	DCU	DCU	DCU	DCU	DCU	DCU
Matéria Mineral	○	○	●	○	●	●	●	○
Proteína Bruta	●	●	●	●	●	●	●	●
Fibra Detergente Neutro	●	●	○	○	●	●	●	○
Extrato Etéreo	○	○	●	○	●	●	○	●
Carboidrato não fibroso	○	●	●	○	●	●	●	○
Energia Bruta	○	○	●	●	●	●	○	●
Acúmulo de Forragem	○	●	●	●	○	●	●	●
Taxa de Acúmulo de Forragem	○	●	●	●	○	●	●	●

○ – data com baixa relação encontrada entre índices espectrais e os parâmetros de qualidade; ● – data com alta relação encontrada entre índices espectrais e os parâmetros de qualidade.

Para uma análise mais precoce da cultura, nas condições deste experimento, as imagens RGNIR seriam as mais indicadas para se obter informações sobre a qualidade do capim Tifton 85. Entretanto, para os parâmetros de qualidade que obtiveram altas relações com os índices espectrais tanto para as imagens RGB e RGNIR, a utilização de uma câmera RGB se faz mais indicada, por se tratar de um equipamento de custo menor comparado à uma câmera RGNIR.

De acordo com o propósito desta pesquisa, em avaliar o uso de imagens digitais de capim Tifton 85 para obter relações entre índices espectrais RGB e RGNIR, e os parâmetros bromatológicos da cultura, os resultados reforçam o uso de tecnologias de processamento de imagens de forrageiras para identificar reais necessidades de manejo e acompanhamento de sua qualidade.

A tecnologia de baixo custo, fácil manuseio, não invasiva e mais rápida que as análises laboratoriais tradicionais, apresentada por este trabalho, podem impulsionar o desenvolvimento de métodos alternativos e de fácil utilização por pequenos e médios produtores.

A relação entre os índices espectrais e os parâmetros bromatológicos da cultura, podem permitir que futuramente, estudos possam gerar modelos de estimativas complementares às análises laboratoriais, impactando no manejo e na tomada de decisões para se obter uma forrageira de qualidade, que possa suprir cada vez mais a demanda de setores bovinos como a produção de carne e leite, que possuem impacto direto no setor agropecuário nacional.

5 CONCLUSÃO

Foi possível avaliar os parâmetros de qualidade do capim Tifton 85 com uso de imagens digitais RGB e RGNIR em diferentes idades de corte, por meio de índices espectrais.

Os índices espectrais RGB apresentaram maior variação no efeito da adubação aos 14 dias após o DCU. A PB foi o parâmetro que melhor se relacionou com os índices espectrais quando avaliado as quatro épocas de corte. Aos 14 dias a PB e o FDN apresentaram maior correlação com os índices espectrais RGB; a PB, FDN e CNF com os 28 dias; a MM, EE e EB aos 42 dias; e a PB e EB com o corte aos 56 dias.

Para as imagens RGNIR, os índices espectrais apresentaram maior sensibilidade para avaliar o efeito da adubação aos 14 e 42 dias após o DCU. A PB foi o parâmetro que melhor relacionou com os índices espectrais. Aos 14 e 28 dias os índices espectrais RGNIR apresentaram alta correlação com os parâmetros de qualidade avaliados.

A maior relação com o acúmulo de forragem e taxa de acúmulo de forragem para os índices espectrais RGB, ocorreu aos 14 dias. Para os índices espectrais RGNIR, as maiores relações foram observadas aos 42 e 56 dias. Também pôde ser observado, assim como nos demais parâmetros analisados, que as imagens RGNIR possibilitaram maior relação para avaliar a qualidade do capim Tifton 85.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ALKREEM, M. H., & KARIM, A. A. Feature Selection Using Artificial Bee Colony for Fruit Classification. **Journal of Physics: Conference Series**, v.1818, n.1, p. 012-062, 2021.

ALOSAIMI, W., ALYAMI, H., & UDDIN, M. I. PeachNet: Peach diseases detection for automatic harvesting. **Computers, Materials and Continua**, v.67, n.2, p.1665–1677, 2021.

ALVES, A. R., PASCOAL, L. A. F., CAMBUÍ, G. B., DA SILVA TRAJANO, J., DA SILVA, C. M., & GOIS, G. C. Fibra para ruminantes: Aspecto nutricional, metodológico e funcional. **Publicações em Medicina Veterinária e Zootecnia**, v.10, n.7, p.568–579, 2016.

ANANTHANARAYANA, T., PTUCHA, R., & KELLY, S. C. Deep Learning based Fruit Freshness Classification and Detection with CMOS Image sensors and Edge processors. **IS and T International Symposium on Electronic Imaging Science and Technology**, v.

2020, n.12, p.172-1-172-7, 2020.

ANDRADE, E. C. Processamento digital de imagens como estimativa de teor de N foliar na cultura do milho. 56f. **Dissertação de Mestrado**. Universidade Estadual de Ponta Grossa, 2015.

ANDRADE, W. R. Produção de capim e feno de tifton 85 sob doses de nitrogênio em diferentes dias de rebrotação.74f. **Dissertação de Mestrado**. Universidade Estadual de Montes Claros. 2017.

ANDRADE, WR, SALES, ECJD, MONÇÃO, FP, GOMES, VM, RUFINO, LDDA, & PIRES, DADA . Hay Tifton-85 grass under nitrogen doses in different days of regrowth. **Acta Scie. Anim. Scie.**, v.40, p.37692, 2018.

ANDRIOTTI, J. L. S. Fundamentos de estatística e geoestatística. 165p. **São Leopoldo: Ed. Unisinos**, 2003.

AOAC - Association of Official Analytical Chemists. **Official methods of analysis of the Association of the Analytical Chemists**. 16 ed. Washington, 1995.

ARAÚJO, P. Análise e classificação da qualidade do línter e do óleo de algodão utilizando técnicas de visão computacional. 87f. **Dissertação (mestrado) – Universidade Federal do Ceará**, Campus de Sobral, Programa de Pós-Graduação em Engenharia Elétrica e de Computação, Sobral, 2019.

BAESSO, M.M.; APRILANTI, T.M.G.; ROSSI, F. Visão artificial para a diagnose nutricional do milho cultivado com silicato de cálcio e magnésio em doses ponderais e altas diluições. **Brazilian Journal of Biosystems Engineering**. v. 14, n.1, p. 36-47, 2020.

BARBEDO, J. G. A. Plant disease identification from individual lesions and spots using deep learning. **Biosystems Engineering**, v. 180, p. 96-107, 2019.

BARBEDO, J. G. A., L. V. KOENIGKAN E T. T. SANTOS. Identifying multiple plant diseases using digital image processing. **Biosystems Engineering**. v.147, p. 104– 116, 2016.

BARBOSA, E.M.C. Medições volumétricas para biometria de animais domésticos utilizando nuvens de pontos em câmeras RGB-D. 55f. **Projeto Final de Curso** Departamento de Ciência da Computação do Instituto de Matemática da Universidade Federal do Rio de Janeiro, 2017.

BELLO, T.B.; COSTA, A.G.; SILVA, T.R.; PAES, J.L.; OLIVEIRA, M.V.M. Tomato quality based on colorimetric characteristics of digital images. **Revista Agriamb**. V. 24, n.8, p. 567-572. 2020.

BERNARDI, A., SILVA, A.W.L. E BARETTA, D. Estudo metanalítico da resposta de gramíneas perenes de verão à adubação nitrogenada. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia [online]**. 2018, v. 70.

BIFFI, L. J., MITISHITA, E., LIESENBERG, V., DOS SANTOS, A. A., GONÇALVES, D. N., ESTRABIS, N. V., SILVA, J. DE A., OSCO, L. P., RAMOS, A. P. M., CENTENO, J. A. S., SCHIMALSKI, M. B., RUFATO, L., NETO, S. L. R., JUNIOR, J. M., & GONÇALVES, W. N. Article atss deep learning-based 70 approach to detect apple fruits. **Remote Sensing**, V.13, p. 1–23, 2021. Disponível em: <https://doi.org/10.3390/rs13010054>

BORGES, B. M.; SILVEIRA, M. L.; CARDOSO, S. S.; MOLINE, E. F.; COUTINHO NETO, A. M.; LUCAS, F. T.; MURAOKA, T.; COUTINHO, E. L. Growth, herbage accumulation, and nutritive value of ‘Tifton 85’ bermudagrass as affected by nitrogen fertilization strategies. **Crop Science, Madison**, v. 57, n.6, p. 3333-3342, 2017. Disponível em: DOI: 10.2135/cropsci2016.10.0890.

BRIGANTE, G. R. M. Análise multivariada aplicada na construção de scores de rendimento dos principais jogadores do futebol mundial. **Documento**. Universidade Estadual Paulista (Unesp), 2022. Disponível em: <http://hdl.handle.net/11449/217390>.

CAMPOS, F. P. de; NUSSIO, Carla Maris Bittar; NUSSIO, Luiz Gustavo. Métodos de análise de alimentos. **Editora FEALQ**. [S.l: s.n.], p.135, 2004.

CARDOSO, G.S. Terminação de novilhas em capim Tifton 85 suplementadas com diferentes fontes energéticas. 75f. **Tese de Doutorado**. Universidade Federal de Santa Maria. 2020.

CARVALHO, A. A.; DA SILVA, R. R.; REBELLO; J. M. A.; VIANA, A. F. O mundo das imagens digitais. **Documento**, v. 8, n. 2, p. 167-186, 2003.

CASTLEMAN, K. R. Digital image processing. **NJ - USA: Prentice Hall Press Upper Saddle River**, NJ, USA, 1996. ISBN 0-13-211467-4.

CAVALCANTI, A.C.; SALIBA, E.O.S.; FILHO, C.C.C.; SILVA2, F.A.; SILVA, C.M.R.; MACÊDO, T.M. Partição da energia e produção de metano em ovinos alimentados com feno de *Andropogon Gayanus* colhido em três diferentes idades. Universidade Federal do Espírito Santo, Centro Universitário Norte do Espírito Santo. **Revista de la Facultad de Agronomía, La Plata**. V. 118, p. 99-110, 2019.

CHACON, W.D.C. Estimativa do estágio de maturação, volume e massa do mamão (*Carica papaya* L.) por meio de processamento de imagens para classificação automatizada. 83f. **Dissertação de Mestrado**. 83f. Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia de Alimentos, 2022.

CHESINI, R.G. Efeito da substituição parcial do farelo de soja por farelo de soja tratado termicamente ou DDGS de milho na alimentação de vacas em lactação. 72f. **Tese de Doutorado**. Universidade de São Paulo, 2022.

CHICATI, M.S. ; NANNI, M. R. ; CHICATI, M. L. . Assinatura Espectral do Feijoeiro: Sua relação com parâmetros biofísicos em diferentes doses de nitrogênio. **1. ed. Novas Edições Acadêmicas**, v. 1, p; 119, 2017.

CLEMENTE, A.A.; MACIEL, G.M.; SIQUIEROLI, A.C.S.; GALLIS, R.B.A.; PEREIRA, L.M.; DUARTE, J.G. Fenotipagem de alto rendimento para detectar antocianinas,

clorofilas e carotenóides em germoplasma de alface vermelha. **International Journal of Applied Earth Observation and Geoinformation**. V.103, 2021.

CORDEIRO, L.D. et al. Calibração multivariada e imagens digitais no controle de qualidade de farinha de trigo. **Dissertação de Mestrado**. Universidade Tecnológica Federal do Paraná, 2020.

COSTA, A. S., MAIA, C. P., BARBOSA, D. P., GUIMARÃES, A. K. V., & PONTES, M. L. Composição bromatológica do Sorgo CV. SS-318 em monocultivo e em consórcio com soja, em dois espaçamentos. **Brazilian Journal of Development**, v. 6, n. 10, p. 75852-75862, 2020.

COSTA, A. C. Identificação da maturação de frutos da macaúba por meio de características óticas. 126f. Tese (Doutorado em Engenharia Agrícola). **Universidade Federal de Viçosa**. Viçosa, 2015.

COSTA, E.; MARTINS, M.B.; VENDRUSCOLO, E.P.; SILVA, A.G.D.; ZOZ, T.; BINOTTI, F.F.D.S.; SERON, C.D.C. Greenhouses within the Agricultura 4.0 interface. **Revista Ciência Agronômica**, v. 51, 2021. ISSN 1806-6690. <https://doi.org/10.5935/1806-6690.20200089>.

COSTA, M. L. L., RESENDE, A. S. C., DUARTE, I. N. H., LIMA, N. R., MOREIRA, G. R. Valor nutricional da silagem pré-secada de capim Tifton – 85. **Revista Brasileira de Meio Ambiente**, v.6, n.1, p.26-33, 2019.

CRUZ, C.: Aplicação de algumas técnicas multivariadas no melhoramento de plantas. Dissertação de Doutorado. **Tese (Doutorado)** – Universidade de São Paulo, Piracicaba, 1990.

DAMASCENO, D.; TOLEDO, T. G.; GODINHO, M. S.; SILVA, C. P.; OLIVEIRA, S. B.; OLIVEIRA, A. E. Análise multivariada de imagens na química: um experimento para determinação do pH de águas potáveis. **Quim. Nova**, V. 38, n. 6, p.836-841, 2015.

DELONGUI, R.; COALHO, M. R. Avaliação das características morfogênicas sobre a produção e composição bromatológica do Capim-Tifton 85 submetido a diferentes doses de nitrogênio. **Revista Terra & Cultura: Cadernos de Ensino e Pesquisa**, v. 34, p. 64-73, 2018. ISSN 2596-2809.

DIOGO, A. M.. Análise da distribuição espacial da fenologia de vegetação, precipitação e evapotranspiração, com base em imagens de sensoriamento remoto orbital em Angola. 90f. **Dissertação (Mestrado)**. Universidade Federal do Rio Grande do Sul. Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia. Programa de Pós-Graduação em Sensoriamento Remoto, 2020.

DOMINGUES, A. A. Produtividade do capim Paiaguás submetido a doses de nitrogênio. 42 f. **Dissertação** (Mestrado Profissional em Produção Animal e Forragicultura) - Câmpus Oeste - Sede: São Luís de Montes Belos, Universidade Estadual de Goiás, São Luís de Montes Belos, 2017.

DONATO, D. G. Caracterização espectral de trigo em lavoura comercial e estimativas

biofísicas e qualidade de grãos baseada em quimiometria. 98f. **Tese (Doutorado em Engenharia Agrícola)** - Universidade Estadual do Oeste do Paraná, Cascavel – PR, 2021.

DOS SANTOS, T. C.; ESPERIDIÃO, T. L.; DOS SANTOS AMARANTE, M. AGRICULTURA 4.0. **Revista Pesquisa E Ação**, v. 5, n. 4, p. 122-131, 2019.

DUPAS, E.; BUZETTI, S.; RABÊLO, F. H. S.; SARTO, A. L.; CHENG, N. C.; GALINDO, F. S.; DINALLI, R. P.; NIRO GAZOLA, R. 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**, Lismore, v. 10, n. 9, p.1330-1338, 2016. Disponível em: DOI: 10.21475/ajcs.2016.10.09.p7854.

EDVAN, R.L.; BEZERRA, L.R.; MARQUES, C.A.T.; CARNEIRO, M.S.S.; OLIVEIRA, M.S.S.; OLIVEIRA, R.L.; FERREIRA, R.R. Methods for estimating forage mass in pastures in a tropical climate. **Revista de Ciências Agrárias**, v. 39, n. 1, p.36-45. 2016. DOI: <https://doi.org/10.19084/RCA14100>.

EMBRAPA. Anuário Leite 2020. **Anuário do Leite**, p. 104, 2020. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1124722/anuario-leite-2020-leite-devacas-felizes>.

EMBRAPA. Pecuária de leite no Brasil : cenários e avanços tecnológicos / Duarte Vilela ... [et al.], editores técnicos. – Brasília, DF : **Embrapa**, 2016. 435. ISBN 978-85-7035-644-4.

FELLER, A. A., DE ALMEIDA, U. O., NOGUEIRA, A. E., FERREIRA, L., & DOS SANTOS, F. C. Efeito da Adubação Combinada de Nitrogênio com Potássio na Produção de Capim Brachiaria Humidicola em Cacaúlândia, Rondônia. **Revista Científica da Faculdade de Educação e Meio Ambiente**, v. 13, n. edespmulti, 2022.

FERENTINOS, K. P. Deep learning models for plant disease detection and diagnosis. **Computers and Electronics in Agriculture**, v. 145, p. 311-318, 2018. DOI: 10.1016/j.compag.2018.01.009.

FERNANDES, E.G.; COALHO, M. R.. Efeito de doses crescentes de nitrogênio no desenvolvimento de Brachiaria ruziziensis. **Revista Terra & Cultura: Cadernos de Ensino e Pesquisa**, [S.l.], v. 34, n. esp., p. 189-201, 2018. ISSN 2596-2809.

FERNÁNDEZ-OLIVERAS, A.; POZO, A. M.; RUBIÑO, M. Speckle-based modulation transfer function measurements for comparative evaluation of CCD and CMOS detector arrays. **Optical review**, v. 20, n. 1, p. 41-49, 2013.

FERREIRA, A.F.N.; KRAUSE, W.; FALEIRO, A.C.; MIRANDA, A.F; JUSTINO, A. Seleção de descritores de sementes de maracujazeiro azedoutilizando fenotipagem digital. **Agrarian Academy**. Centro Científico Conhecer - Goiânia, v.5, n.10, 2018.

FIGLIOLI, A. B., ZIECH, M. F., FLUCK, A. C., GEREI, J. C., COL, D., BERNIS, L., ... & COSTA, O. A. D. Valor nutritivo de gramíneas do gênero Cynodon consorciadas com amendoim forrageiro. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia [online]**, v. 70, n. 6, 2018. ISSN 1678-4162. <https://doi.org/10.1590/1678-4162-10048>.

FONTES PCR; ARAÚJO C. Adubação nitrogenada de hortaliças: princípios e práticas com o tomateiro. **Viçosa: UFV**. p.148, 2007.

FONTES, P. T. N., SOUSA, B. M. L., OLIVEIRA JÚNIOR, L. F. G., FAGUNDES, J. L., GALINDO, F. S.; BUZETTI, S.; TEIXEIRA FILHO, M. C. M.; DUPAS, E.; CARVALHO, F. D. C. Manejo da adubação nitrogenada no capim-mombaça em função de fontes e doses de nitrogênio. **Revista de Ciências Agrárias**, Lisboa, v. 41, n. 4, p.31-40, 2018a. Disponível em: <http://www.scielo.mec.pt/pdf/rca/v41n4/v41n4a04.pdf>.

FRACAROLLI, J.A.; PAVARIN, F.F.A; CASTRO, .; BLASCO. Visão computacional aplicada a alimentos e produtos agrícolas. **Revista Ciência Agronômica [online]**. 2020, v. 51, e20207749. Disponível em: <<https://doi.org/10.5935/1806-6690.20200087>>.

GALLETI, L. S.; SOARS, R. V. Captura e tratamento de imagens. 1 ed. **São Paulo: SENAI –SP Editora**, v. 1, p.96, 2016.

GALVÃO, G. VISÃO COMPUTACIONAL PARA DETECÇÃO DE DOENÇAS FÚNGICAS NA AGRICULTURA. **ÚNICA Cadernos Acadêmicos**, v. 2, n. 1, 2018.

GARDNER, A.L. Técnicas de pesquisa em pastagens e aplicabilidade de resultados em sistemas de produção. Brasília: IICA/EMBRAPA-CNPGL, **Série publicações Miscelâneas**, n. 634, p.197, 1986.

GITELSON, A. A., Y. Kaufman, and M. N. Merzlyak. Use of greenchannel in remote sensing of global vegetation from EOS-MODIS, *Remote Sens. Environ*, v.58, p.289 – 298. 1996.

GOMES, E. P. et al. Produtividade de pastagem de capim tifton 85 irrigado e sobressemeada com forrageiras de inverno. **Acta Scientiarum. Animal Sciences, Maringá**, v. 37, n. 2, p. 123-128, 2015.

GOMES, E.S.; BITTAR, D.Y.; SÉRVULO, A.C.O.. PRODUÇÃO DE FORRAGEIRAS DA ESPÉCIE *Panicum maximum* SUBMETIDAS A DOSES DE NITROGÊNIO. **Ipê Agronomic Journal**, v. 4, n. 2, p. 1-8, 2020.

GONÇALVES, J. M.; PERON, H. J. M. C.; COSTA, L. C. D. Fontes alternativas de nitrogênio para intensificação da produção do capim Zuri. **Revista de Ciências Agroveterinárias**, Lages, v. 21, n. 2, p. 107-113, 2022. DOI: 10.5965/223811712122022107. Disponível em: <https://www.revistas.udesc.br/index.php/agroveterinaria/article/view/21146>. Acesso em: 26 jul. 2022.

GONÇALVES, M. I. S. Aplicação de Imagens Digitais e Análise Multivariada para classificação e Determinação de Parâmetros de Qualidade em Plumões de Algodão. **Dissertação (Mestrado) — Universidade Federal da Paraíba**, João Pessoa, 2015.

GONZALEZ, R. C.; WOODS, R. E. Digital Image Processing. **Pearson Education, Inc**, 2008. ISBN ISBN 0-13-168728

GONZALEZ, R. C.; WOODS, R. *Processamento Digital de Imagens*. 3. ed. Sao Paulo: **Pearson Prentice Hall**, 2010.

GUPTA, S. D.; IBARAKI, Y.; TRIVEDI, P. Applications of RGB color imaging in plants. In: **Plant Image Analysis: Fundamentals and Applications**. p.41-62. CRC Press, 2014.

HALLIK, L., KAZANTSEV, T., KUUSK, A., GALMÉS, J., TOMÁS, M., & NIINEMETS, Ü Generality of relationships between leaf pigment contents and spectral vegetation indices in Mallorca (Spain). **Reg Environ Change**, v.17, p.2097, 2109.

HOTELLING, H.: Analysis of a complex of statistical variables into principal component. **The Journal of Educational Psychology**, v. 24, p. 417-441, 1933. 12.

HUETE, A, K DIDAN, T MIURA, E. P. RODRIGUEZ, X GAO E L. G. FERREIRA. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**. V. 83, p. 195–213.2002, doi: 10.1016/S0034-4257(02) 00096-2.

HUETE, A.R. A soil-adjustedvegetation index (SAVI). **Remote Sensing of Environment**, v. 25, p. 295-309. 1988.

HUETE, A.R.; JUSTICE, C.; LIU, H. Development of vegetation and soil indices for MODIS-EOS. **Remote Sens. Environ**, v. 49, p. 224-234. 1994.

JACKSON, R. D.; HUETE, A. R. Interpreting vegetation indices. *Preventive veterinary medicine*, **Elsevier**, v. 11, n. 3-4, p. 185–200, 1991.

KAUFMAN, D.; BOAS, L. L. V. Visão computacional na agricultura: APIs de detecção e reconhecimento de doenças das plantas. **ECCOGS – Revista Digital de Tecnologias Cognitivas**, n. 20, p. 96-112, 2019.

KÖPPEN, W. *Climatologia: con un estudio de los climas de la tierra*. **Fondo de Cultura Econômica. México**. P. 479, 1948.

KRAHL, Gustavo; MASSON, Emerson. PRODUÇÃO DE FORRAGEM EM SISTEMA DE CONSÓRCIO ENTRE AZEVÉNS COM DIFERENTES CICLOS EM SOBRESSEMEADURA AO TIFTON 85. **Seminário de Iniciação Científica e Seminário Integrado de Ensino, Pesquisa e Extensão**, p. e26098-e26098, 2020.

LEAL, K.N.S. Avaliação da estabilidade de produtos lácteos através de análise físico-química, espectroscópica e imagens digitais. **Dissertação (Mestrado)**. 110 f. Universidade Federal de Alfenas, Engenharia Química. Poços de Caldas/MG, 2019.

LEMOS, J.R. et al. Variação temporal de índices de vegetação obtidos por imagens de satélites para indicar a cobertura vegetal da Caatinga da Estação Ecológica de Aiuaba, Ceará-Brasil. **Revista Espacios**, v. 39, n. 34, p. 7, 2018.

LI, L., Q. ZHANG E D. HUANG. “A Review of Imaging Techniques for Plant Phenotyping”. Em: **Sensors** . V14.11, p. 20078–20111, 2014 doi: 10.3390/s141120078.

LIMA, D.C. Metodos para Estimativa de Imagens Nir a partir de imagens de Cameras

RGB. 126f. **Tese** - Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de São Carlos,SP. 2020.

LOBET, G., X. DRAYE E C. PÉRILLEUX. “An online database for plant image analysis software tools”. Em: **Plant Methods** v.9.1, p. 1–8, 2013. doi: 10.1186/1746-4811-9-38.

MANCIN, W.R. Desenvolvimento de software de processamento digital de imagens para análise do status nutricional de nitrogênio em *Brachiaria brizantha*. 60f. **Dissertação de Mestrado**. Faculdade de Zootecnia e Engenharia de alimentos, Universidade de São Paulo.2019.

MARTÍNEZ, E. O. Atributos químicos e físicos do solo e produtividade de capim Tifton 85 em resposta à aplicação de nitrogênio e esterco bovino. Jaboticabal. 59 p. **Tese (doutorado)** - Universidade Estadual Paulista, Faculdade de Ciências Agrárias e Veterinárias, 2017.

MARTINS, C.E.; OLIVEIRA, J.S.; CÓSER, A.C.; JOSÉ, H.R.– Conservação de forrageiras e pastagens. **Documento**.2018.

MARTINS, N. Fotografia: da analógica à digital. **Editora Senac Nacional**, 1. ed., p.280, 2012. ISBN-10: 8574582808

MATOS, E. C. T. D., RODRIGUES, L. A., SOUZA, P. D. A., SILVA, R. V. D., & FARIA Jr, R. T. (2018). Espectroscopia fotoacústica para analisar a fertilidade de solos tratados com biochar e micorriza. *Química Nova*, 41, 989-998. MATOS, Ellen Conceição T. de et al. Espectroscopia fotoacústica para analisar a fertilidade de solos tratados com biochar e micorriza. **Química Nova**, v. 41, p. 989-998, 2018.

MENESES, P. R.; ALMEIDA, T.; ROSA, A. N. C. S.; SANO, E. E.; SOUZA, E. B.; BAPTISTA, G. M. M.; BRITES, R. S. Introdução ao processamento de imagens de sensoriamento remoto. **Brasília: UnB**, p. 01-33, 2012.

MESTRE, D. A. F. Monitorização de crescimento de plantas cultivadas in-vitro usando processamento digital de imagem. 2017. **Dissertação (Mestrado)** - Faculdade de Ciências e Tecnologia, Universidade NOVA de Lisboa, 2017. Disponível em <https://run.unl.pt/bitstream/10362/23415/1/Mestre_2017.pdf>.

METTERNICHT, G. Vegetation Indices Derived from High Resolution Airborne Video studWestgraphy for Precision Crop Management. **International Journal of Remote Sensing**, V. 24, p. 2855-2877, 2003.

MIRANDA, José Iguelmar. Processamento de imagens digitais: métodos multivariados em Java. **Campinas: Embrapa Informática Agropecuária**, p. 400,2011.

MONTOVANI, S.P.G. Composição centesimal de bolo de chocolate em pó enriquecido de ferro com fígado bovino liofilizado. 2019. **Trabalho de Conclusão de Curso** (Bacharelado em Engenharia de Alimentos) – Faculdade de Engenharia, Universidade Federal da Grande Dourados, Dourados, MS, 2019

MORENO, A.S.; BEZERRA, T.S.; DE MELLO, N.D. Câmeras analógicas e digitais: qual oferece melhor qualidade?. **Revista Educação**, Universidade Guarulhos. v.11, n.2, p.19-33, 2016.

MORRISSON, D.: Multivariate statistical method. **McGraw-Hill, McGraw-Hill series in probability and statistics**, 2a ed., 1976.

MOTTA, L.J.M. Qual a relação nitrogênio: potássio adequada para o capim mombaça?. 2019. 23 f. **Trabalho de Conclusão de Curso** (Graduação em Zootecnia) – Universidade Federal de Mato Grosso, Instituto de Ciências Agrárias e Tecnológicas, Rondonópolis, 2019.

NASCIMENTO, M.G.S.; FREITAS, F.M.C. Produção de forragem e relação folha/haste de duas gramíneas com potencial para fenação. CENTRO UNIVERSITÁRIO DE GOIÁS - **Uni-ANHANGUERA CURSO DE AGRONOMIA GOIANA**. 2018.

OLIVEIRA, A.P.P. et al. Respostas do capim-Tifton 85 à aplicação de nitrogênio: cobertura do solo, índice de área foliar e interceptação da radiação solar. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, v.62, p.429-438, 2010.

OLIVO, C. J., QUATRIN, M. P., SAUTER, C. P., SILVA, A. R., SAUTHIER, J. C., & SAUTER, M. P. . Productivity and crude protein concentration of Tifton 85 pasture-based mixed with pinto peanut. **Ciência e Agrotecnologia**, v. 43, p. 1-8, 2019.

PATZLAFF, N.L.; ZULPO, A.P.; ROSSI, D.S.. A importância do uso da dose correta na adubação nitrogenada de tifton 85. **Revista Científica Rural**, v. 22, n. 2, p. 1-12, 2020.

PORFÍRIO, Magno Daniel. Avaliação agronômica e valor nutricional do sorgo forrageiro BRS 658 com diferentes arranjos populacionais. 2019. 67 f. **Dissertação (Mestrado em Zootecnia)** - Universidade Estadual do Oeste do Paraná, Marechal Cândido Rondon, 2019.

QUEIROZ, J. E. R. de; GOMES, H. M. Introdução ao processamento digital de imagens. **Revista Rita**, 2014. Departamento de Sistemas e Computação. Disponível em: <<http://www.dsc.ufcg.edu.br/~hmg/disciplinas/graduacao/vc-2014.1/Rita-Tutorial-PDI.pdf>>

RÉ, P. O ABC das Câmaras CCD. **Revista da Associação Portuguesa de Astrônomos Amadores**, Lisboa, n. 25, p. 22-31, 2005.

RICHARDSON, A.J.; WIEGAND, C.L. Distinguishing vegetation from soil background information. **Photogrammetric Engineering and Remote Sensing**, v.1 n.43, p.1541-1552, 1977.

RODRIGUES, B. U. Reconhecimento do tipo de cacheira utilizando visão computacional e reconhecimento de padrões. Dissertação (Mestrado) — **UNIVERSIDADE FEDERAL DE GOIÁS INSTITUTO DE INFORMÁTICA**, Goiânia, 2015.

ROMÃO, C. O. et al. Fracionamento de carboidratos e degradabilidade ruminal da cana-de-açúcar tratada com óxido de cálcio. **Arquivos Brasileiro de Medicina Veterinária e Zootecnia**, v.65, n.2, p.537–546, 2013.

RÖPER, T.S.. Sistema de visão computacional para otimização de corte de madeira em máquina refiladeira. 76 f. **Dissertação (Mestrado)**. Programa de Pós-Graduação em Mecatrônica do Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina.

ROSSIELLO, R. O. P.; DE OLIVEIRA, A. P. P. ; DA SILVA, C. F.. ; SIMÕES, C. R. ; NETO, E. C. S.; ZONTA, E. REIS, R.A., MOREIRA, A.L., PEDREIRA, M.S. Avaliação da resposta à adubação nitrogenada no capim-Tifton 85, utilizando imagens digitais. **Anais do Congresso Brasileiro de Ciência do Solo**. Natal, Rio Grande do Norte, 2015.

ROUSE, J. W. et al. Monitoring vegetation systems in the great plains with ERTS. In: EARTH RESOURCES TECHNOLOGY SATELLITE-1 SYMPOSIUM, 3., 1973, **Washington. Proceedings**. Washington: NASA, v.1, p.309-317, 1973.

ROUSE, J.W., R.H. HAAS, J.A. SCHELL, D.W. DEERING, J.C. HARLAN. Monitoring the vernal advancement of retrogradation (greenwave effect) of natural vegetation. **NASA/GSFC, Type III, Final Report, Greenbelt, MD, p.371, 1994.**

RUDEK, M.; COELHO, L. dos S.; JUNIOR, O. C. Visão computacional aplicada a sistemas produtivos: Fundamentos e estudo de caso. **Universidade Católica do Paraná, Curitiba - PR, 2011.**

SAFA, M. *et al.* Modelling nitrogen content of pasture herbage using thermal images and artificial neural networks. **Thermal Science and Engineering Progress**, v.11, p.283-288, 2019.

SANCHES, A. C.; GOMES, E. P.; RICKLI, M. E.; FRISKE, E.; FASOLIN, J. P. Productivity and nutritive value of Tifton 85 in summer, with and without irrigation under different nitrogen doses. **Engenharia Agrícola, Jaboticabal**, v.37, n.2, p.246-256, 2017.

SANCHES, A.C. ; GOMES, E.P. ; FASOLIN, J. P.; SOARES, M. R. C. ; DE GOES, R. H. T. B. Produtividade e valor nutritivo do capim Tifton 85 irrigado e sobressemeado com aveia. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande/PB, v.19, n. 2, p. 126-133, 2015.

SANTOS, H.G. dos; JACOMINE, P.K.T.; ANJOS, L.H.C. dos; OLIVEIRA, V.A. de; OLIVEIRA, J.B. de; COELHO, M.R.; LUMBRERAS, J.F.; CUNHA, T.J.F. (Ed.). Sistema brasileiro de classificação de solos. 2.ed. Rio de Janeiro: **Embrapa Solos**, p.306, 2006.

SANTOS, P. M.; WENTZELL, P. D.; FILHO, E. R. P. Scanner digital images combined with color parameters: A case study to detect adulterations in liquid cow's milk. **Food Analytical Methods**. V.5, p.89-95, 2012.

SANTOS, P. V. Metodologia para análise de imagens de baixa resolução, para definição de MUB (Mapa Urbano Básico) para apoio às concessionárias de distribuição. 2018. 78 f. **Dissertação (Mestrado em Ciência da Computação)** - Universidade Federal de Goiás, Goiânia, 2018.

SANTOS, R.A. Demanda hídrica e modelagem de parâmetros biofísicos da cultura do milho a partir do sensor RGNIR a bordo de um VANT. 2019. 69 f. **Dissertação (Mestrado em Engenharia Agrícola)** - Universidade Federal de Viçosa, Viçosa. 2019.

SANTOS, T.T.; BARBEDO, J.G.A.; TERNES, S.; NETO, J.C.; KOENIGKAN, L.V.; SOUZA, X.S. Visão computacional aplicada na agricultura.v6, p.148-164, 2020.

SCHAEFFER, G.H.; MACHRY, E.A.; GUARDA, L.D.. AVALIAÇÃO DO DESENVOLVIMENTO DE GRAMA TIFTON 85 SUBMETIDA A DIFERENTES DOSES E FONTES DE NITROGÊNIO. **Anuário Pesquisa e Extensão Unoesc São Miguel do Oeste**, v. 6, p. e27735-e27735, 2021.

SCHMIDT, G. Tendências tecnológicas na agropecuária. **Avicultura Industrial**, v. 6, n. 1689, p. 24-26, 2019.

SERRANO, J.M.; BARRETO, S.; SHAHIDIAN, S.; SILVA, J.M. Avaliação do sensor óptico de vegetação OptRx® na monitorização da variabilidade espacial e temporal de pastagens. **Revista de Ciências Agrárias**, v. 39 n. 2 p. 261-280, 2016.

SHIMABUKURO, Yosio Edemir; PONZONI, Flávio Jorge. **Mistura Espectral: modelo linear e aplicações**. Oficina de Textos, 2017.

SHIRATSUCHI, L. S; BERNARDI, AC de C.; NAIME, J. de M.; RESENDE, AV de; BASSOI, LH; INAMASU, RY. **Embrapa Solos-Capítulo em livro técnico (INFOTECA-E)**. Agricultura de precisão: resultados de um novo olhar. Brasília, DF: Embrapa, . cap. 4, p. 58-73., 2014.

SILVA, C. F.; Imagens multiespectrais para avaliação de índice de área foliar e massa seca do capim ‘Tifton 85’, sob adubação nitrogenada. **Ciência Rural**, v.45, n.4, 2015.

SILVA, D. J. Análise de alimentos (Métodos químicos e biológicos). **Editora Viçosa: Imprensa Universitária UFV**, 2ed, p.165, 1990.

SILVA, D.R.G.; COSTA, K.A.P.; FRAQUIM, V.; OLIVEIRA, I.P.; BERNARDES, T.F. Doses e fontes de nitrogênio na recuperação das características estruturais e produtivas do capim-marandu. **Revista Ciência Agrônômica**, v. 44, n. 1, p. 184-191, 2013.

SILVA, L.R. Efeito do manejo de secagem e armazenamento sobre o valor nutritivo do feno de *Crotalaria ochroleuca* L., 2022. 88 f. **Tese (Doutorado em Zootecnia)** - Universidade Estadual do Oeste do Paraná, Marechal Cândido Rondon, 2022.

SILVA, P. R. B., et al.. Classificação de Espécies de Pimentas Empregando Análise de Imagens Digitais de Componentes Principais. **Revista Arithmós-Revista da Escola de Ciências Exatas e da Computação**, v. 1, n. 1, p. 18-21, 2019.

SILVA, P.H.S. Diagnóstico nutricional da rúcula para nitrogênio com processamento digital de imagens. 86p. **Tese (Doutorado)**. Unesp – Jaboticabal. 2021.

SILVA, R.S.V. Uso de imagens multiespectrais de baixo custo para classificar níveis de N aplicados ao solo em agricultura de precisão. 56f. **Dissertação (mestrado em Engenharia Agrícola e Ambiental)**. Universidade Federal Rural do Rio de Janeiro, UFRRJ. 2016.

SIMOES,C.R.; ROSSIELLO, R.O.P.; MACHADO, M.G.G.M.L; DASILVA, C.F.. Imagens multiespectrais para avaliação de índice de área foliar e massa seca do capim

'Tifton 85', sob adubação nitrogenada. **Cienc. Rural**, Santa Maria , v. 45, n. 4, p. 697-703, abr. 2015.

SNA – Sociedade Nacional de Agricultura. **Feno: um mercado promissor no mundo e pouco explorado no Brasil**. Revista Online A Lavoura. 2019. Disponível em: <https://alavoura.com.br/pesquisa-inovacao/tecnologia-agricola/feno-um-mercado-promissor-no-mundo-e-pouco-explorado-no-brasil/>. Acesso em: 15/05/2020.

SOARES, H. B. Análise e Classificação de Imagens de lesões da pele por atributos de cor, forma e textura utilizando máquina de vetor de suporte. **Dissertação (Mestrado)** — UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE, Natal- RN – Brasil, 2008.

SOLOMON, C.; BRECKON, T. Fundamentals of Digital Image Processing: A Practical Approach with Examples in Matlab. [S.l.]: **John Wiley and Sons, Ltd**, 2011. ISBN 9780470689776.

SOUSA, A.L.; AMORIM, D.B.; SANTOS, D.S.; SILVA, M.S.; NASCIMENTO, K.B.; RODRIGUES, R. Carboidratos de plantas forrageiras para ruminantes: uma revisão. **Nucleus Animalium**, v.11, n.1. Departamento de Zootecnia, Universidade Federal da Paraíba, Centro de Ciências Agrárias, Campus II, Areia - Paraíba. 2019. DOI: 10.3738/21751463.2945

SOUZA, C. D., LOPEZ, Y., MUNOZ, P., ANDERSON, W., DALL'AGNOL, M., WALLAU, M., & RIOS, E. Natural Genetic Diversity of Nutritive Value Traits in the Genus *Cynodon*. **Agronomy**, v. 10, n. 11, p. 1729, 2020.

SOUZA, J. R. et al. Automatic detection of ceratocystis wilt in eucalyptus crops from aerial images. **IEEE International Conference on Robotics and Automation (ICRA)**, 2015.

SOUZA, L.; CARNEIRO, L.; CANDEIAS, A. L. B. Modelos de cores cmy e yiq no spring e no matlab para análise visual de imagens ikonos e cbers. **XIV Simpósio Brasileiro de Sensoriamento Remoto**, 2009. 25-30 abril, INPE. Disponível em: <<http://marte.sid.inpe.br/col/dpi.inpe.br/sbsr@80/2008/11.15.05.47/doc/7173-7180.pdf>>

SOUZA, M.A. et al. Estudo colaborativo para avaliação dos teores de matéria mineral em alimentos. **Revista Brasileira de Saúde e Produção Animal [online]**. 2017, v. 18, n. 1 [Acessado 26 Julho 2022] , pp. 62-75. ISSN 1519-9940.

SRIDEVY,, S. *et al.* Nitrogen and potassium deficiency identification in maize by image mining, spectral and true colour response. **Indian Journal of Plant Physiology**, v.23, p.91-99, 2018.

TAFFAREL, L. E.; MESQUITA, E. E.; CASTAGNARA, D. D.; GALBEIRO, S.; COSTA, P. B.; DE OLIVEIRA, P. S. R. Tifton 85 grass responses to different nitrogen levels and cutting intervals. **Semina: Ciências Agrárias**, Londrina, v. 37, n. 4, p. 2067-2083, 2016. Disponível em: DOI: <http://dx.doi.org/10.5433/1679-0359.2016v37n4p2067>. Acesso em: 25 ago. 2019.

TAFFAREL, L. E.; MESQUITA, E. E.; CASTAGNARA, D. D.; OLIVEIRA, P. S.; OLIVEIRA, N. T. E.; GALBEIRO, S.; COSTA, P. B.; Produção de matéria seca e valor nutritivo do feno do tifton 85 adubado com nitrogênio e colhido com 35 dias. **Revista**

Brasileira de Saúde e Produção Animal, Salvador, v. 15, n. 3, p. 544-560, 2014.

TEIXEIRA, E. F.; CICERO, S. M.; DOURADO NETO, D. Análise de imagens digitais de plântulas para avaliação do vigor de sementes de milho. **Revista Brasileira de Sementes**, v. 28, n. 2, p. 159-167, 2006.

TEIXEIRA, R.M.A. et al. Suplementação proteica de vacas leiteiras mantidas em pastagem de Tifton 85 durante o período de seca. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia [online]**. 2019, v. 71, n. ISSN 1678-4162. <https://doi.org/10.1590/1678-4162-9805>.

TEIXEIRA, A.M., L. C. GONÇALVES, F. O. VELASCO, G. O. RIBEIRO JUNIOR, W. G. FARIA JUNIOR, D. S. G. CRUZ & D. G. JAYME. Respirometria e emissão de metano por ovinos alimentados com Capim-elefante cortado com diferentes idades. **Bioscience Journal (Online)**, V. 31, p.841-849, 2015.

TESK, C.R.M. Indicadores qualitativos e reservas orgânicas de *Panicum maximum* cvs. Quênia e Tamani, sob intensidades de pastejo. 2018. 102 f. **Dissertação (Mestrado em Zootecnia)** - Universidade Federal de Mato Grosso, Campus Universitário de Sinop, Instituto de Ciências Agrárias e Ambientais, Sinop, 2018.

THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern Recognition*. 4. ed. [S.l.]: Academic Press, 2008.

TIECHER, D. D.; ROCHA, M. G. D.; PÖTTER, L.; SALVADOR, P. R.; BERGOLI, T. L.; MILANESI, G. D. Morphogenesis and structure of Tifton 85 cultivated in subtropical climate and fertilized with nitrogen. **Acta Scientiarum. Animal Sciences**, Maringá, v. 38, n. 4, p.389-393, 2016.

TONG, X.; DUAN, L.; LIU, T.; SINGH, V.P. Combined use of in situ hyperspectral vegetation indices for estimating pasture biomass at peak productive period for harvest decision. **Precision Agriculture**, v. 20, n. 3, p. 477-495, 2019. DOI: <https://doi.org/10.1007/s11119-018-9592-3>.

TRUCCO, E.; VERRI, A. *Introductory Techniques for 3-D Computer Vision*. Edinburgh, UK: **Prentice Hall**, 1998. ISBN 978-0132611084.

TUCKER, C.J., Combinações lineares de infravermelho vermelho e fotográfico para monitorar a vegetação. **Remote Sens. Environ**, 8, 127-150, 1979.

VALADARES FILHO, S.C., D.S. PINA & M.L. CHIZZOTTI. Degradação ruminal da proteína dos alimentos e síntese de proteína microbiana. (Eds.) Exigências nutricionais de zebuínos e tabelas de composição de alimentos BR-Corte. Viçosa, MG: **Suprema Gráfica**, 1:142. (2006).

VERGARA-DÍAZ, O. *et al.* A novel remote sensing approach for prediction of maize yield under different conditions of nitrogen fertilization. **Frontiers in Plant Science**, v. 7, p.666, 2016. Open Access. doi: 10.3389/fpls.2016.00666

VIÇOSI, K.A.; AMORIM, N.B.; BRITO, A.M.S.; CARMANHAN, L.G.B.; PELÁ, A. Comportamento do capim tifton 85 adubado com diferentes fontes de fertilizantes.

Universidade Estadual de Goiás, Câmpus Ipameri, Goiás. **Documento**. 29ª Semana Agronomica do CCAE/UFES - SEAGRO 2018. 17 à 21 de Setembro de 2018, Alegre - ES, Brasil

WARRICK, A. W.; NIELSEN, D. R. Spatial variability of soil physical properties in the field. In: HILLEL, D. Applications of soil physics. **New York: Academic**, cap. 2, p. 319-344, 1980.

WEIRICH, D. T. Uso de vácuo e inoculante na produção de silage de capim Tifton-85. 2015. 71 f. **Dissertação de mestrado**, Universidade Estadual do Oeste do Paraná, Marechal Cândido Rondon, PR, Brasil. 2015.

WEZEL, A. *et al.* (2014). **Agroecological practices for sustainable agriculture: A review**. *Agronomy for Sustainable Development*, v.34, n.1, p.20, 2014.

XIE, C. Q. *et al.* Spectral reflectance response to nitrogen fertilization in field grown corn. **International Journal of Agricultural and Biological Engineering**, v. 11, p.118-126, 2018.

XUE, J; SU, B. Significant Remote Sensing Vegetation Indices: A Review of Developments and Applications. **Journal of Sensors**, v.2017:1353691, 2017.

ZHENG, H. *et al.* Evaluation of RGB, color-infrared and multispectral images acquired from unmanned aerial systems for the estimation of nitrogen accumulation in rice. **Remote Sensing Journal**, v.10, p. 824, 2018.

ZIECH, M.F. *et al.* Valor nutritivo de pastagens de Cynodon consorciadas com amendoim forrageiro no sudoeste do Estado do Paraná. **Acta Scientiarum. Animal Sciences [online]**. 2015, v. 37, n. 3. ISSN 1807-8672. <https://doi.org/10.4025/actascianimsci.v37i3.26872>.